

Modelo inteligente para
la ubicación de fallas en
líneas de distribución con
generación distribuida

Modelo inteligente para la ubicación de fallas en líneas de distribución con generación distribuida

Diego Armando Giral Ramírez, César Augusto Hernández Suárez,
José David Cortés Torres



Resumen

Para asumir los retos de los nuevos sistemas eléctricos, se requiere incorporar estrategias avanzadas. En los últimos años se han propuesto técnicas para localizar fallas en líneas de distribución, en las que la inteligencia artificial ha mostrado buenos resultados por su alto rendimiento y capacidad para dar una respuesta rápida. No existe una solución óptima para el problema de ubicación de fallas; debido a la generalidad de la inteligencia artificial, no es posible caracterizar un algoritmo como la mejor estrategia para este problema. Aunque se han logrado avances prometedores, todavía quedan muchas preguntas por responder. El enfoque constante consiste en identificar los avances en inteligencia artificial para lograr resultados cada vez efectivos.

Palabras clave: fallas de baja impedancia, generación distribuida, red de distribución, inteligencia artificial, algoritmos avanzados.

Abstract

To tackle the challenges of new electrical systems, it is necessary to incorporate advanced strategies. In recent years, various techniques have been proposed to locate faults in distribution lines, where artificial intelligence has shown promising results due to its high performance and ability to provide rapid responses. There is no optimal solution to the fault location problem; due to the broad nature of artificial intelligence, it is not possible to define a single algorithm as the best strategy for this issue. Although significant progress has been made, many questions remain unanswered. The ongoing focus is on identifying advancements in artificial intelligence to achieve increasingly effective results.

Keywords: low-impedance faults, distributed generation, distribution network, artificial intelligence, advanced algorithms.

¿Cómo citar este libro? / How to cite this book?

Giral Ramírez, D. A., Hernández Suárez, C. A. y Cortés Torres, J. D. (2025). *Modelo inteligente para la ubicación de fallas en líneas de distribución con generación distribuida*. Universidad Distrital Francisco José de Caldas-Editorial UD.
<https://doi.org/10.69740/UD.9789587877502.9789587877519>



Agradecimientos

A la fuente de sabiduría que permea el universo agradecemos por habernos brindado la claridad para tomar las decisiones adecuadas, la fortaleza para perseverar ante las dificultades y la inteligencia para encontrar soluciones que han llevado a la exitosa culminación de este proyecto académico. Reconocemos la complejidad y el caos inherentes a nuestro camino y, a través de ellos, encontramos el aprendizaje y el crecimiento necesarios para alcanzar nuestros objetivos.

Este libro es el resultado del proyecto de investigación “Modelo inteligente para la ubicación de fallas de baja impedancia en líneas de distribución con generación distribuida”, identificado con el código 1-53169-628-20 del año 2020. Este proyecto se completó exitosamente gracias al esfuerzo conjunto del equipo de investigadores y al apoyo de la Oficina de Investigaciones y de la Universidad Distrital Francisco José de Caldas, mediante el uso de su infraestructura, equipos y *software*.



© Universidad Distrital Francisco José de Caldas
© Oficina de Investigaciones
© Diego Armando Giral Ramírez,
César Augusto Hernández Suárez,
José David Cortés Torres (autores)

ISBN: 978-958-787-750-2
ISBN digital: 978-958-787-751-9
ISBN ePub: 978-958-787-752-6

DOI: <https://doi.org/10.69740/UD.9789587877502.9789587877519>

Primera edición, marzo de 2025

Líder Unidad de Publicaciones
Rubén Eliécer Carvajalino C.

Gestión editorial
Alejandro Merlano Aramburo

Corrección de estilo
HIPERTEXTO SAS

Diagramación
HIPERTEXTO SAS

Diseño de cubierta
Johana Delgado Macías

Editorial UD

Universidad Distrital Francisco José de Caldas
Carrera 24 n.º 34-37, Bogotá, D. C., Colombia
Teléfono: 6013239300, ext. 6202
Correo electrónico: publicaciones@udistrital.edu.co

Cláusula de responsabilidad

La Editorial UD no es responsable de las opiniones y de la información recogidas en el presente texto. Los autores asumen de manera exclusiva y plena toda responsabilidad sobre su contenido, ya sea este propio o de terceros, declarando en este último supuesto que cuentan con la debida autorización de terceros para su publicación. Igualmente, expresan que no existe conflicto de interés alguno en relación con los resultados de la investigación propiedad de tales terceros. En consecuencia, los autores serán responsables civil, administrativa o penalmente, frente a cualquier reclamo o demanda por parte de terceros, relativa a los derechos de autor u otros derechos que se vulnere como resultado de su contribución.

Todos los derechos reservados

Esta obra no puede ser reproducida sin el permiso previo escrito de la Unidad de Publicaciones de la Universidad Distrital Francisco José de Caldas.
Hecho en Colombia.

Sistema de Bibliotecas de la Universidad Distrital Francisco José de Caldas

Catalogación en la publicación (CEP)

Giral Ramírez, Diego Armando
Modelo inteligente para la ubicación de fallas en líneas de distribución con generación distribuida / Diego Armando Giral Ramírez, César Augusto Hernández Suárez, José David Cortés Torres. -- Primera edición. -- Bogotá : Universidad Distrital Francisco José de Caldas, 2025.
146 páginas : gráficas, diagramas ; 24 cm. (Colección Espacios)

ISBN: 978-958-787-750-2 ISBN digital: 978-958-787-751-9 ISBN ePub: 978-958-787-752-6

1. Distribución de energía eléctrica 2. Impedancia (Electricidad) 3. Localización de fallas eléctricas -- Inteligencia artificial 4. Ingeniería eléctrica -- Métodos de simulación I. Hernández Suárez, César Augusto, autor II. Cortés Torres, José David, autor III. Serie.

621.31924: CDD 23 edición.

Contenido

Introducción	13
1. Fundamentos teóricos	21
1.1. Fallas de baja impedancia	21
1.2. Generación distribuida (GD)	24
1.3. Impactos en la red por la GD	26
1.4. Ubicación de fallas en sistemas de distribución	27
1.5. Trabajos relacionados	38
2. Diseño del modelo inteligente	45
2.1. Etapa 1: sistema de prueba y estudio de cortocircuito	47
2.2. Etapa 2: unidad de terminal de alimentación y función del interruptor	49
2.3. Etapa 3: técnicas de optimización inteligente implementadas	60
2.4. Etapa 4: métricas	72
3. <i>Software</i> de simulación	75
3.1. Menú principal	78
3.2. Sistema de potencia de prueba	80
3.3. Generación distribuida	86
3.4. Ubicación de la falla	87
3.5. Métricas	88
3.6. Diagramas de flujo del <i>software</i> de simulación	90
3.7. Interfaz de App LF-UD	93

4. Evaluación del modelo inteligente	97
4.1. Impacto de la GD en los modelos convencionales	97
4.2. Ubicación de fallas en un único segmento	98
4.3. Ubicación de fallas en múltiples segmentos	116
4.4. Discusión	119
Conclusiones	125
Trabajo futuro	129
Referencias	131
Sobre los autores	145

Introducción

La generación distribuida (GD) es una tecnología que está vinculada a los consumidores a través del sistema de distribución, y tiene un gran potencial de beneficios técnicos, económicos y ambientales. La incorporación de generación en los puntos de demanda produce una variación del flujo de carga y de las corrientes de falla, que cambia los flujos unidireccionales por estructuras bidireccionales y altera las características de las corrientes de fallas de baja impedancia.

Las estadísticas indican que la mayoría de fallas de baja impedancia ocurren en las redes de distribución. De hecho, aproximadamente el 80 % de las fallas en la red de distribución corresponden a fallas en las líneas. Después de que se produce una falla, el esquema de protección debe detectarla y ubicarla de forma rápida y precisa para mantener la seguridad y operación del sistema, evitando daños en los equipos y la propagación a todo el sistema.

Los métodos tradicionales para la ubicación de fallas que se implementan corresponden al método de ondas viajeras y al de impedancia, en donde la inclusión de GD establece nuevos desafíos, por lo que se requiere proponer o adaptar modelos que mejoren el proceso de ubicación. En los últimos años, se han presentado técnicas para situar fallas en líneas de distribución con generación distribuida, donde la inteligencia artificial (IA) ha presentado buenos resultados por su alto rendimiento y capacidad para dar una respuesta rápida durante una falla.

De acuerdo con lo anterior, la pregunta de investigación planteada para este proyecto está enfocada en cómo se puede mejorar la ubicación de fallas de baja impedancia en líneas de distribución con GD a través de un modelo inteligente. El objetivo general es desarrollar un modelo utilizando técnicas

de IA para la ubicación de fallas de baja impedancia en líneas de distribución con generación distribuida.

Con los resultados alcanzados en esta investigación, se realizó la publicación de un artículo en una revista indexada internacional y de un artículo en una revista indexada nacional, un registro de *software*, un curso o taller dirigido a estudiantes de pregrado y el presente libro. El proyecto fue financiado por la Oficina de Investigaciones de la Universidad Distrital Francisco José de Caldas.

El objetivo de la investigación fue desarrollar un modelo utilizando técnicas de IA para la ubicación de fallas de baja impedancia en líneas de distribución con generación distribuida. Para esto, se buscó:

- Desarrollar el ambiente de simulación para el análisis de fallas de baja impedancia en sistemas de distribución utilizando información de equipos, caracterización de los elementos y generación distribuida.
- Desarrollar un modelo basado en IA para la ubicación de fallas en líneas de distribución con generación distribuida utilizando la información del análisis de fallas de baja impedancia del ambiente de simulación.
- Establecer métricas de desempeño para validar el modelo de ubicación de fallas propuesto a través del ambiente de simulación.

La incorporación de generación en los puntos de demanda produce una variación del flujo de carga y de las corrientes de falla; por lo tanto, mejorar los esquemas de diagnóstico de fallas para este tipo de arquitecturas es un factor relevante. La ubicación o localización oportuna de una falla acelera el proceso de restauración, lo que mejora los indicadores de confiabilidad del sistema (Tashakkori *et al.*, 2020). En las redes de distribución, los métodos tradicionales para ubicación de fallas no se pueden aplicar de manera directa, debido a la presencia de líneas no homogéneas, las cargas desequilibradas y los diversos ramales.

Los esquemas de ubicación de fallas en redes de distribución que no utilizan inspección física están diseñados para flujos de potencia unidireccional, planteando un mayor número de desafíos para redes con incorporación de GD (H. Sun *et al.*, 2020) por lo tanto, es necesario desarrollar nuevas técnicas

avanzadas y precisas, que estén en la capacidad de adaptarse a los nuevos retos y a los cambios permanentes en las redes de distribución.

Sobre ubicación de fallas en GD, se han presentado en la literatura diversas técnicas, las cuales se basan en modificaciones de los métodos tradicionales: métodos de ondas viajeras y métodos de impedancia; adicionalmente, durante los últimos años, un considerable número de técnicas basadas en conocimientos se han propuesto para la ubicación de fallas.

La IA es un campo multidisciplinario que se enmarca en estrategias basadas en conocimiento y ha presentado buenos resultados para la solución de este tipo de problemas por su alto rendimiento, adaptación y capacidad para proporcionar una respuesta rápida durante el proceso de ubicación de fallas; sin embargo, requiere de un volumen alto de información para las pruebas de entrenamiento y validación de los diferentes modelos, lo que puede generar características de lenta convergencia y carga computacional elevada.

En la IA, para la ubicación de fallas no existe una técnica que se destaque como la mejor, ya que cada enfoque conlleva un conjunto considerable de ventajas y desventajas, pero se puede plantear un modelo que beneficie una actividad o métrica en específico y que además se ajuste a los retos actuales de los sistemas de distribución.

Para asumir los retos de los nuevos sistemas eléctricos, se requiere incorporar tecnologías electrónicas, eléctricas, de información y de manufactura avanzada, lo que constituye una exigencia para los nuevos modelos de negocio energético, en un sector que en su transición busca integrar la participación de los usuarios finales, fuentes renovables, sistemas de transporte en corriente directa, redes inteligentes, almacenamiento de energía y sistemas de medición (Unidad de Planeación Minero Energética *et al.*, 2018).

La GD representa un cambio en la filosofía de la producción de energía eléctrica, y este enfoque no es nuevo (Naghizadeh *et al.*, 2018); además, su implementación permite asumir los retos de los nuevos modelos de negocio energético (IEEE, 2018; Mer y Patel, 2016; Vaziri *et al.*, 2011). La GD cuenta con una amplia lista de ventajas; sin embargo, puede ocasionar problemas tanto en los sistemas de distribución como en el sistema de transmisión, inconvenientes que dependen de las características específicas del sistema eléctrico de potencia y del nivel de penetración de la GD (De las Casas *et al.*, 2009).

La conexión de GD puede alterar las características del sistema radial, modificando el flujo de carga unidireccional, así como la dirección y la magnitud de las corrientes de cortocircuito, y estas alteraciones tienen como consecuencia un funcionamiento incorrecto del sistema de protección. Además, pueden surgir fallas en los esquemas de sobrecorriente y, en general, variaciones en la operación del sistema, lo que afecta la seguridad, confiabilidad y calidad del suministro de energía entregada (Srinivasa Rao *et al.*, 2019).

Debido a que los ajustes de las funciones de protección tradicionales de la red de distribución pasiva ya no son aplicables con la presencia de GD, se requiere proponer nuevas estrategias en los esquemas de protección para las redes con GD (Cadena *et al.*, 2011; González, 2014; IEEE, 2009; Priya y Geethanjali, 2018; Z. Sun *et al.*, 2021). Estas estrategias deben ser diseñadas para abordar los desafíos específicos que surgen con la integración de GD y garantizar un funcionamiento seguro y confiable del sistema eléctrico.

Los datos estadísticos muestran que la mayoría de las fallas de la red eléctrica ocurren en la red de distribución, y el 80 % de las fallas de la red de distribución son fallas en las líneas (B. Zhang *et al.*, 2019). La inclusión de generación en las redes de distribución plantea nuevos desafíos de estimación de estado en perturbaciones del sistema asociadas a fenómenos de sobrecorriente, como la identificación o ubicación de las corrientes de falla (Fei y Moses, 2019), elementos indispensables para los nuevos esquemas de protección.

En los últimos años, se han propuesto diversos métodos para la ubicación de fallas en líneas de distribución. Los modelos propuestos cuentan con múltiples técnicas, algunas determinísticas y otras probabilísticas, y sus aplicaciones son diversas. Sin embargo, al igual que en muchas áreas de la ingeniería, estas técnicas se ven limitadas por el contexto de aplicación.

En el caso de la ubicación de fallas, los modelos desarrollados suelen enfocar sus esfuerzos en resolver problemas relacionados con arquitecturas centralizadas en sistemas de transmisión y distribución. Por lo tanto, es necesario identificar e implementar estrategias de ubicación de fallas que sean rápidas y precisas cuando se incorpora generación en el lado del usuario final (Alwash *et al.*, 2015).

De acuerdo con los nuevos modelos de negocio energético, y debido a la necesidad de adaptar la operación tradicional de los esquemas de diagnóstico


y protección de las redes de distribución, es importante desarrollar un modelo que permita ubicar fallas de baja impedancia en redes de distribución con GD. Según los elementos y problemas expuestos, la pregunta de investigación planteada para este libro se enfocó en cómo se puede mejorar la ubicación de fallas de baja impedancia en líneas de distribución con GD a través de un modelo inteligente.

Este trabajo utiliza cuatro técnicas de optimización inteligente para la ubicación de segmentos en fallas en líneas de distribución con GD. El objetivo de este trabajo no es modificar las técnicas: la metodología implementada consiste en aplicarlas al problema de ubicación de fallas. Esta investigación no propone una estrategia de optimización metaheurística “novedosa” ni establece mejoras sobre las respectivas estrategias originales (Aranha *et al.*, 2022; Sörensen, 2015). El trabajo permanente es identificar este tipo de estrategias de aprendizaje inteligente y adaptarlas para abordar las tareas complejas que se generan en el análisis de las redes de distribución.

La figura 1 presenta la metodología propuesta para alcanzar los objetivos establecidos. En color gris se presenta la información de entrada, que se caracteriza por el sistema de prueba, la estrategia para el estudio de cortocircuito y el sistema utilizado para la medición de las condiciones de operación.

En color verde se describe el diagrama de bloques del modelo inteligente implementado para la ubicación de fallas en líneas de distribución con GD. Este modelo utiliza funciones matemáticas (*switching function*) que permiten transformar estados de segmentos de línea en estados de operación de los interruptores. Como estrategias de IA, se trabaja con técnicas de optimización inteligente, específicamente con cuatro modelos de optimización metaheurística basados en comportamientos poblacionales: algoritmo de optimización de cebra, algoritmo de búsqueda de cuco, algoritmo de búsqueda de relámpago y algoritmo de búsqueda gravitacional binaria. Estas técnicas son ampliamente utilizadas en la solución de problemas complejos de ingeniería.

Figura 1. Diagrama de bloque de la estrategia propuesta



Fuente: elaboración propia.

A diferencia de las técnicas convencionales, el modelo propuesto no busca la localización de una longitud de falla: se diseñó para identificar segmentos de falla; esta característica está asociada al sistema de medida utilizado, el cual se instala en los interruptores de segmentos para monitorear las condiciones de operación y posteriormente almacenarlos y transmitirlos al centro de control. Como métrica de desempeño, se utiliza la precisión para identificar el segmento de línea en falla y parámetros propios de las técnicas de optimización inteligente (mínimos de la función de acuerdo con el número de iteraciones, el número de iteraciones y el tiempo de simulación).

En color amarillo se describe el diagrama de bloques de App LF-UD, un simulador desarrollado en App Designer de Matlab. El objetivo de App LF-UD es brindar un ambiente de simulación que permita analizar el desempeño de diferentes algoritmos de ubicación de fallas de baja impedancia en líneas de distribución con y sin GD, las estandarizadas y las que propone la comunidad académica de forma permanente.

En su primera versión, App LF-UD incluye únicamente técnicas basadas en impedancia: el método de reactancia simple y el método de Takagi. No obstante, la aplicación se diseñó para incluir de forma sencilla más estrategias de ubicación de fallas. El trabajo futuro es incluir ondas viajeras, técnicas de optimización inteligente, esquemas de ubicación híbridas, entre otras. El simulador se desarrolló como resultado de este trabajo de investigación y fue registrado a nombre de la Universidad Distrital Francisco José de Caldas.

El proyecto de investigación se desarrolló en cuatro enfoques metodológicos secuenciales. En primer lugar, se empleó un enfoque descriptivo para detallar las características de las estrategias de interés. Luego, se utilizó un enfoque analítico para determinar la influencia de cada modelo en el rendimiento de las estrategias de ubicación propuestas. A continuación, se adoptó un enfoque predictivo que buscaba aplicar soluciones de otras situaciones al contexto de interés. Por último, se implementó un enfoque experimental que permitió llevar a cabo pruebas de validación y verificación de los desarrollos realizados (Hernández-Sampieri *et al.*, 2006).

La metodología se estructuró en cuatro etapas. Inicialmente, se realizó la fundamentación teórica, donde se incluyó la revisión y posterior análisis del estado del arte; como resultado de esta primera parte, fueron identificados los aspectos más importantes para el tema de ubicación de fallas, así como las tendencias más relevantes sobre métodos, técnicas y algoritmos.

En segundo lugar, de acuerdo con el análisis de los fundamentos teóricos y el estado del arte, se diseñó un ambiente de simulación para implementar cuatro modelos de optimización metaheurística basados en comportamientos poblacionales; en esta etapa se estableció la metodología de evaluación.

Seguidamente, se desarrolló una herramienta de simulación. Esta herramienta permite analizar el desempeño de diferentes algoritmos de ubicación de fallas de baja impedancia en líneas de distribución, considerando escenarios con y sin GD.

En la cuarta etapa, se llevaron a cabo la generación y el análisis de las métricas de desempeño. Estas métricas proporcionan una evaluación cuantitativa y cualitativa del rendimiento de los algoritmos implementados, contribuyendo así a la evaluación integral de la metodología propuesta.

Por último, este libro es producto de los resultados alcanzados en el proyecto de investigación “Modelo inteligente para la ubicación de fallas de baja impedancia en líneas de distribución con generación distribuida”, financiado por la Oficina de Investigaciones de la Universidad Distrital Francisco José de Caldas. Código del Proyecto SICIUD: 1-53169-628-20. Proyecto presentado en la convocatoria 01-2020: “Apoyo a proyectos de investigación, investigación-creación e innovación de docentes nombrados en periodo de prueba dentro de la planta docente de la Universidad Distrital Francisco José de Caldas”.

A partir de este punto el lector encontrará, en el capítulo 1, los fundamentos teóricos sobre fallas de baja impedancia, GD, impactos en la red por la GD, las técnicas de ubicación de fallas en sistemas de distribución y la revisión de la literatura actual sobre los métodos para esta ubicación. El capítulo 1 describe la metodología utilizada para el modelo inteligente de ubicación de las fallas. El capítulo 3 describe el *software* de simulación desarrollado. El capítulo 4 presenta los resultados y la respectiva discusión. Finalmente, se exponen las conclusiones y el trabajo futuro.

1. Fundamentos teóricos

Esta obra está totalmente enfocada en las técnicas de ubicación de fallas de baja impedancia. El presente capítulo se subdivide en cinco secciones. La primera sección aborda los fundamentos de las fallas de baja impedancia; la segunda se enfoca en los aspectos teóricos de la GD; la tercera presenta los impactos en la red por la GD; la cuarta describe los algoritmos más relevantes para la ubicación de fallas en sistemas de distribución, y la quinta presenta una revisión de la literatura actual.

1.1. Fallas de baja impedancia


En un sistema trifásico, son diversas las clasificaciones que se pueden dar a las perturbaciones de sobrecorriente: se pueden clasificar como fallas en derivación, fallas en serie, fallas simultáneas, fallas simétricas y fallas asimétricas (Goh *et al.*, 2017). Las fallas en derivación, conocidas como fallas de cortocircuito, ocurren cuando hay una conexión no deseada entre el conductor de fase y la fase o el conductor de fase y la tierra.

El estándar americano (IEEE, 2019) y el europeo (International Electrotechnical Commission, 2016) analizan las fallas en derivación y las clasifican en cuatro categorías: falla trifásica, monofásica, bifásica y bifásica a tierra. La figura 2 presenta los tipos de fallas en derivación de acuerdo con el IEEE Std 3002.3™-2018 y la IEC 60909.

Las fallas por cortocircuito son modeladas a través de la conexión de una impedancia de falla Z_f en los puntos de falla F (figura 3). Se dice que una falla es de baja impedancia (*low impedance fault* [LIF]) cuando la conexión se realiza a través de una impedancia de bajo valor. En transmisión, para los estudios

de cortocircuito, la impedancia de falla Z_f se ignora o se toman valores de bajo valor (menores o iguales a $0,01 \Omega$) (Sifat *et al.*, 2017; Tleis, 2019). Para fallas en derivación en líneas de distribución, los valores típicos de impedancia de falla se consideran menores o iguales a 40Ω (Dagenhart, 1999; Mora Flórez y Pérez Londoño, 2016).


Figura 2. Fallas en derivación



Fuente: elaboración propia a partir de IEEE (2019).

Las fallas por baja impedancia generan aumentos en las magnitudes de corriente y disminución en los perfiles de tensión; un valor de corriente de falla por encima de la corriente de carga máxima esperada se define como falla de baja impedancia. Aproximadamente del 85 % al 98 % de las fallas son de baja impedancia (Sifat *et al.*, 2017; Yu y Khan, 1994).

Figura 3. Fallas en derivación caracterizadas a través de la impedancia de falla Z_f



Fuente: elaboración propia a partir de Tleis (2019).

Las fallas bifásicas son más frecuentes que las fallas trifásicas en los sistemas eléctricos, y su corriente de falla es aproximadamente el 87% de la corriente de falla trifásica. Una falla bifásica a tierra se refiere a una falla monofásica que se ha intensificado al involucrar un segundo conductor de fase. En general, las magnitudes de las fallas bifásicas a tierra son mayores que las fallas bifásicas, pero menores que las fallas trifásicas. Para calcular las corrientes de falla en estos casos, es necesario realizar un análisis de las componentes simétricas o de secuencia (J. C. Das, 2016; X.-F. Wang *et al.*, 2010).

El concepto de componentes simétricas, introducido por Charles Legeyt Fortescue, es una de las transformaciones más útiles de la teoría de circuitos eléctricos (Fortescue, 1918). El artículo “Method of symmetrical co-ordinates applied to the solution of polyphase networks” es un hito en el análisis de sistemas de potencia. Las componentes simétricas o de secuencia establecen que “cualquier sistema asimétrico de n vectores puede ser descompuesto en n sistemas simétricos con n vectores, cada uno” (Fortescue, 1918; traducción propia).

La importancia de las componentes simétricas o de secuencia en los sistemas eléctricos creció de manera tan significativa que los datos de los equipos como generadores, líneas y transformadores, entre otros, comenzaron a proporcionarse en forma de componentes de secuencia. Las aplicaciones evolucionaron con el tiempo: estudios de condiciones desequilibradas en máquinas rotativas, cálculos de cortocircuito en sistemas desequilibrados, estabilidad transitoria del sistema, ajustes en los sistemas de protección, entre otros.

Recientemente, debido al aumento de la participación de los recursos energéticos distribuidos en los sistemas de distribución, la transformación de Fortescue se ha utilizado para abordar problemas que involucran diferentes aspectos, desde el modelamiento hasta el análisis y control de las redes de distribución con GD. Después de cien años, las componentes simétricas introducidas por Fortescue siguen siendo una herramienta fundamental (Chicco y Mazza, 2019).

1.2. Generación distribuida (GD)

Los sistemas de energía eléctrica se caracterizan por manejar una estructura centralizada; un sistema de potencia clásico utiliza niveles de alta tensión para la transmisión y redes de media y baja tensión para la distribución. Las redes de distribución se caracterizan por ser pasivas y han funcionado en modo radial debido a la simplicidad de operación, la facilidad de coordinación de los dispositivos de protección y la economía general (Madani *et al.*, 2017).

En la estructura clásica, las fuentes de generación están conectadas al sistema de transmisión y no a la red de distribución; sin embargo, desde 1990, el interés por conectar la generación a la red de distribución ha crecido significativamente (Gaonkar, 2010). La GD es una tecnología a pequeña escala que no cuenta con una definición estándar aceptada. En la tabla 1 se presentan algunas definiciones de GD para diferentes organizaciones internacionales (Adefarati y Bansal, 2016).

Tabla 1. Definición de GD para diferentes organizaciones


Organización	Definición de GD
Instituto de Investigación de Energía Eléctrica (Electric Power Research Institute [EPRI])	La GD se define como unidades de generación a pequeña escala que van desde unos pocos kW hasta 50 MW o dispositivos de almacenamiento de energía. Estas unidades suelen estar ubicadas cerca de las cargas, los puntos de distribución y las subestaciones de subtransmisión.
Consejo Internacional de Grandes Sistemas Eléctricos (International Council on Large Electric Systems [CIGRE])	La GD se define como unidades de generación con una capacidad máxima de entre 50 MW y 100 MW; generalmente están conectadas a la red de distribución, y no están ni centralmente planificadas ni despachadas.
Instituto de Ingenieros Eléctricos y Electrónicos (Institute of Electrical and Electronics Engineers [IEEE])	La GD se define como la generación de electricidad en instalaciones pequeñas que permiten la interconexión en casi cualquier punto de un sistema de energía.
Agencia Internacional de la Energía (International Energy Agency [IEA])	La GD es un tipo de planta de generación que está conectada a la red a niveles de tensión de distribución para atender a un cliente en el sitio y al mismo tiempo brindar soporte a una red distribuida.

Fuente: elaboración propia a partir de Adefarati y Bansal (2016).

La GD puede conectarse a varios niveles de tensión: de 120/230 V a 150 kV. Como se muestra en la figura 4, solo se pueden conectar generadores de baja

potencia a las redes de menor tensión, pero grandes instalaciones, de unos cientos de megavatios, están conectadas a las barras colectoras de los sistemas de distribución de alto voltaje (Jenkins *et al.*, 2014).

Figura 4. Conexión de GD



Fuente: elaboración propia a partir de Giral-Ramírez (2022) y Jenkins *et al.* (2014).

Muchas de las unidades pequeñas integradas en la red de distribución son fuentes de energía renovables, como turbinas eólicas, plantas hidroeléctricas a pequeña escala y paneles fotovoltaicos, pero también se implementan fuentes de energía no renovables de alta eficiencia, como pequeñas plantas combinadas de calor y energía. Las tecnologías implementadas para la GD se pueden clasificar según la fuente de generación y el tipo de almacenamiento (Adefarati y Bansal, 2016; Trujillo *et al.*, 2015).

Se considera que los recursos energéticos distribuidos incluyen todas las formas de generación y almacenamiento de electricidad que están interconectadas al sistema de energía en los niveles de distribución de media y baja tensión (Strezoski *et al.*, 2019).


1.3. Impactos en la red por la GD

La integración de GD genera varios beneficios. Estos beneficios incluyen la reducción de pérdidas en líneas, la minimización de los impactos ambientales, el aumento en los indicadores de eficiencia, la seguridad y prestación del servicio, la disminución en la congestión en la red de transmisión y distribución y la mejora en los perfiles de tensión (Jenkins *et al.*, 2014). Como desventajas, la conexión de generadores en los alimentadores de distribución cambia los flujos unidireccionales por estructuras bidireccionales y altera las características de las corrientes de fallas (figura 5), la sensibilidad del sistema de protección y la confiabilidad de la red.

La tasa de cambio de las corrientes de falla depende de la capacidad de la GD incorporada en el sistema (Gaonkar, 2010). Para el ajuste del sistema de protecciones, se requiere caracterizar el comportamiento de los flujos de las corrientes en función del tipo de falla; por ejemplo, para las fallas trifásicas, en sistemas radiales, la contribución de la red a la corriente de falla total se reducirá por la contribución de la GD. Debido a esta reducción, es posible que el cortocircuito permanezca sin ser detectado, pues la contribución de la red a la corriente de cortocircuito nunca alcanza la corriente de arranque del relé de alimentación.

Los relés de sobrecorriente, así como los relés direccionales y los reconectores, dependen de su funcionamiento para detectar una corriente anormal. Estos problemas dependen del sistema de protección aplicado y, en consecuencia, del tipo de red de distribución (X. Chen y Jiao, 2018; Gaonkar, 2010). En general, los problemas de protección se pueden dividir en tres categorías: problemas de detección de fallas, problemas de ubicación de fallas y problemas de selectividad.

Los esquemas de ubicación de fallas de baja impedancia en redes de distribución están diseñados para flujos de potencia unidireccional, planteando un mayor número de desafíos para las redes con incorporación de GD (H. Sun *et al.*, 2020); por lo tanto, es necesario analizar e identificar técnicas avanzadas y precisas, que estén en la capacidad de adaptarse a los nuevos retos y a los cambios permanentes en las redes de distribución.

Figura 5. Contribución de la GD a las corrientes de falla

Fuente: elaboración propia a partir de Gaonkar (2010).

1.4. Ubicación de fallas en sistemas de distribución


En las redes de distribución con penetración de GD, la ubicación de fallas plantea un mayor número de desafíos. Los métodos tradicionales que se desarrollan no se pueden aplicar de manera directa debido a la variación en las capacidades de cortocircuito, la posición de los sistemas de generación, los flujos de corriente bidireccional, la presencia de líneas no homogéneas, cargas desequilibradas, así como los diversos ramales y laterales (H. Sun *et al.*, 2020).

Con el rápido desarrollo de las redes de distribución, los usuarios han expresado la necesidad de contar con una mayor confiabilidad y calidad en la prestación del servicio eléctrico. Los datos estadísticos respaldan esta preocupación y muestran que la mayoría de las fallas en la red eléctrica ocurren en la red de distribución. De hecho, aproximadamente el 80 % de las fallas en la red de distribución corresponden a fallas en las líneas (B. Zhang *et al.*, 2019).

La ubicación de fallas en líneas de distribución es el primer paso para mantener la seguridad y la operación del sistema (Jiang *et al.*, 2015); después de que ocurre una perturbación, el esquema de protección debe detectar y ubicar la falla para aislar la zona. La respuesta debe ser rápida y precisa, para evitar el daño en los equipos y que la falla se propague a todo el sistema (Goh *et al.*, 2017; X. Chen y Jiao, 2018).

Los esquemas de protección prefieren desconectar las fuentes de GD ante una falla o cualquier otra perturbación para asegurar que no haya contribución a la corriente de falla; sin embargo, la práctica de retirar la GD no es confiable; además, la eliminación no selectiva de la GD no se recomienda ni es aceptable en un mercado de suministro de energía multiservicio (Bahmanyar *et al.*, 2017; Gana *et al.*, 2017; Kumar y Saxena, 2020). En los últimos años, diversos métodos para la ubicación de fallas en sistemas que integran GD se han propuesto: la figura 6 muestra la clasificación de los métodos según las estrategias tradicionales y las basadas en sistemas inteligentes.

Figura 6. Clasificación de los métodos de ubicación de fallas para redes con GD



Fuente: elaboración propia a partir de Bahmanyar *et al.* (2017) y Kumar y Saxena (2020).

1.4.1. Métodos tradicionales

Los métodos tradicionales que se aplican actualmente son los métodos basados en protecciones adaptativas y, de acuerdo con el estándar de la IEEE (2015), los basados en impedancia y de ondas viajeras.

1.4.1.1. Métodos basados en protecciones adaptativas

En los esquemas de protecciones adaptativas, el objetivo es que las funciones de protecciones se ajusten continuamente de acuerdo con el estado del sistema. Los métodos propuestos ajustan la configuración de las protecciones para mantener la coordinación cada vez que una GD se desconecta o se conecta. Siempre que haya un cambio, se recalculan los ajustes del relé y, a través de protocolos de comunicación, se parametrizan las funciones individuales.

El algoritmo de ubicación de fallas se basa en las medidas de corriente en las posiciones de los reconectores y fusibles, y dependiendo del ajuste de


la protección y de las magnitudes de las corrientes, se establece la zona de la falla. Estos esquemas de ubicación de fallas son económicos porque mantienen la estructura de protección tradicional y evitan nuevas inversiones. Sin embargo, este método es efectivo para un bajo nivel de penetración de GD; a un mayor nivel, la corriente de falla cae más allá del ajuste de coordinación reconectador-fusible y el algoritmo de ubicación pierde precisión. Adicionalmente, otro inconveniente es la dependencia de una unidad central para tomar las decisiones (Gana *et al.*, 2017).

1.4.1.2. Normatividad de ubicación de fallas

La ubicación de fallas de baja impedancia en una red de distribución se puede realizar de forma visual o a partir de las mediciones entregadas por los equipos. El diagnóstico visual, aunque ampliamente usado, no está estandarizado, es ineficiente, inseguro y demorado. La ubicación a través de mediciones, de acuerdo con el estándar IEEE C37.114-2014 (IEEE, 2015), es una estrategia tradicional; según los valores medidos, se puede usar el método de ondas viajeras (métodos basados en el uso de corriente y tensiones de alta frecuencia) o el método de impedancia (métodos basados en el uso de corriente y tensiones a frecuencia fundamental) (Barja-Martinez *et al.*, 2021; K. S. M. H. Ibrahim *et al.*, 2021).

En la figura 7 se presentan, de manera resumida, las técnicas y métodos para ubicación de fallas de baja impedancia en las líneas de distribución de acuerdo con el estándar IEEE C37.114-2014 (IEEE, 2015).

Figura 7. Técnicas y métodos para ubicación de fallas en las líneas de distribución de acuerdo con el estándar IEEE C37.114-2014



Fuente: elaboración propia.


1.4.1.3. Método basado en impedancia

En un sistema de potencia de media, baja y alta tensión, la impedancia característica es sensible a las variaciones de carga. Se puede ubicar una falla observando la reducción de tensión dentro de una operación y luego aplicarla en el cálculo de la impedancia del sistema. Los algoritmos basados en impedancia utilizan fasores de voltaje y corriente de frecuencia fundamental (60 Hz) registrados por relés digitales, registradores de fallas digitales y otros dispositivos electrónicos inteligentes (IED), durante una falla, para estimar la impedancia aparente entre el IED y la ubicación de la falla de cortocircuito.

Los algoritmos que estima la distancia de la falla a partir de las mediciones de uno de los extremos de la línea se definen como algoritmos basados en impedancia de un solo extremo, y los que utilizan mediciones en más de un extremo de una línea se denominan algoritmos basados en impedancia de extremos múltiples (S. Das *et al.*, 2021). La figura 8 muestra el circuito simple del método basado en la impedancia. La medida para encontrar la distancia de la falla desde el nodo de medición fd es el valor de la impedancia por unidad de la línea del sistema de distribución.

La ventaja del método basado en la impedancia es que es más barato en comparación con el método de onda viajera, pues solo requiere datos de medición de la línea de distribución. Los datos deben registrarse con frecuencia, con el fin de monitorear el sistema de energía eléctrica. La principal desventaja es la inexactitud en la ubicación de la falla por la reconfiguración del sistema cada vez que una fuente de GD se desconecta o se conecta, lo que genera que el método proporcione estimaciones múltiples de la ubicación de la falla (Dadary y Afrakhte, 2017; Goh *et al.*, 2017).

Se pueden utilizar variaciones del método, como la conversión de la reactancia aparente estimada de la línea a la distancia y el método equivalente de Thevenin para calcular el voltaje y la corriente de falla (International Electrotechnical Commission, 2016).

Figura 8. Método basado en impedancia

Fuente: elaboración propia a partir de IEEE (2015).


1.4.1.4. Método de onda viajera

La ubicación de la falla con la tecnología de onda viajera (figura 9) utiliza el tiempo ($t1$ y $t2$) que le toma a una onda viajar desde el punto de falla (f_d) hasta el punto de referencia fijo (nodo A), donde se toma la medición (IEEE, 2015).

Los algoritmos de ubicación de fallas de ondas viajeras, por otro lado, se alejan de la frecuencia de operación del sistema y utilizan las ondas de alta frecuencia generadas por las fallas para determinar la ubicación. El método registra los nodos desde donde se transmite la onda y donde se refleja. La suma del periodo de la onda que viaja a la falla y la que se refleja en el nodo de registro se mide para identificar la ubicación de la falla.

La ventaja de este método es que la variación de carga, la presencia de bancos de condensadores en serie y la alta resistencia a tierra no afectan la precisión de la técnica. De forma similar al método de impedancia, las técnicas de ubicación de fallas de ondas viajeras también se pueden clasificar en algoritmos de un terminal y dos extremos. La desventaja del método es que el equipo y los dispositivos utilizados en la técnica son muy caros, como el GPS y los sensores de captura de forma de onda transitoria.

Figura 9. Método de onda viajera



Fuente: elaboración propia a partir de IEEE (2015).

En las categorías de ondas viajeras y basadas en impedancia, se han desarrollado varios algoritmos de ubicación de fallas. Si bien todos los algoritmos tienen el mismo objetivo, que es encontrar la falla con la mayor precisión, cada uno de ellos hace diferentes suposiciones y usa diferentes datos para llegar a este resultado. ¿Cuál es el mejor algoritmo de ubicación de fallas? Desafortunadamente, no existe una respuesta única. La respuesta correcta es que depende. Depende de los datos disponibles para la ubicación de la falla, el sistema al que se aplicará el algoritmo y las características de la falla (S. Das *et al.*, 2021).

1.4.2. Métodos basados en conocimientos


El diagnóstico, identificación y ubicación de fallas en las redes de distribución es un importante factor. Para satisfacer la demanda se necesitan técnicas más avanzadas y precisas, que permitan adaptarse a los nuevos retos del sistema de distribución, como la incorporación de la GD y el aumento de la participación de recursos energéticos distribuidos. Por la estructura, por las amplias aplicaciones y por los excelentes resultados obtenidos en diferentes áreas de la ingeniería, los métodos basados en conocimiento corresponden a la ciencia de la computación que puede resolver los nuevos retos en la ubicación de fallas.

La IA es un campo interdisciplinar que combina distintas ramas de la ciencia, como la estadística, la programación y la filosofía. Su objetivo principal es diseñar y desarrollar entidades artificiales capaces de resolver problemas

utilizando algoritmos inspirados en el comportamiento humano. Hablar sobre IA es cada vez más complejo porque a menudo se usa junto con (o incluso de manera intercambiable) los términos aprendizaje automático (ML) y aprendizaje profundo (DL).

Como se muestra en la figura 10, el DL es un subconjunto del ML, que en sí mismo es un subconjunto de la IA. El ML es un campo importante en la IA que proporciona a los sistemas la capacidad de aprender a realizar tareas desde la experiencia (es decir, datos de entrenamiento). El ML se enfoca en desarrollar algoritmos capaces de acceder a los datos y utilizarlos para aprender de manera autónoma. El DL es una rama del ML que emplea redes neuronales artificiales para modelar y resolver problemas, y permite la extracción de patrones y características en datos de alta dimensionalidad.


Figura 10. Subconjunto de la IA



Fuente: elaboración propia.

Un considerable número de técnicas basadas en la IA se han propuesto en la literatura para el análisis de sistemas de potencia; sin embargo, no hay ningún algoritmo que sea mejor para un problema general. La IA se orienta según el problema por solucionar. La figura 11 presenta una propuesta de organización jerárquica de los algoritmos de aprendizaje, resaltando sus interdependencias (Barja-Martínez *et al.*, 2021; K. S. M. H. Ibrahim *et al.*, 2021).

Figura 11. Organización jerárquica de los algoritmos de IA



Fuente: elaboración propia a partir de Barja-Martinez *et al.* (2021), Giral-Ramírez (2022) y M. S. Ibrahim *et al.* (2020).

Las máquinas de aprendizaje son un subcampo de la IA y de las ciencias de la computación que han evolucionado desde el reconocimiento de patrones hasta analizar la estructura de los datos y ajustarlos a modelos que los usuarios pueden comprender y replicar. Esto se considera el punto de partida para el desarrollo de servicios basado en datos en el sector eléctrico. La figura 12 presenta una serie de aplicaciones del ML en el futuro de las redes eléctricas.

No obstante, en la literatura existen numerosas técnicas disponibles; algunas de ellas son completamente nuevas y surgen de ideas propias de los autores para solucionar problemas específicos, y otras se basan en enfoques híbridos. Las estrategias de hibridación siguen el principio de *no-free-lunch* (Wolpert y Macready, 1997), donde se analizan las ventajas y desventajas de dos o más estrategias, para luego combinarlas de tal manera que el algoritmo resultante sea superior a los individuales (Hernández *et al.*, 2017; Shi *et al.*, 2018).


Figura 12. Aplicaciones del ML en el futuro de las redes eléctricas



Fuente: elaboración propia a partir de Sharifzadeh *et al.* (2021).

En el área de IA utilizando técnicas de optimización, se han realizado numerosos trabajos sobre el diseño de algoritmos para problemas específicos con diferentes antecedentes y objetivos. Según los enfoques de la investigación, los trabajos principales sobre algoritmos de optimización inteligente se pueden dividir en diferentes grupos. La figura 13 presenta una propuesta para la taxonomía de algoritmos de optimización inteligente (Bkassiny *et al.*, 2013).

Figura 13. Taxonomía de algoritmos de optimización inteligente



Fuente: elaboración propia a partir de F. Tao *et al.* (2016).

La tabla 2 presenta algunos ejemplos de las técnicas basadas en conocimientos para la ubicación de fallas en líneas de distribución con GD.

Tabla 2. Técnicas basadas en conocimientos

Título de la publicación	Técnica implementada	Referencia
“Chaotic Particle Swarm Optimization Algorithm for fault location of distribution network with DG”	Particle Swarm Optimization Algorithm	Chang <i>et al.</i> (2022)
“Fault location and restoration of microgrids via particle swarm optimization”	Particle Swarm Optimization Algorithm	Lin <i>et al.</i> (2021)
“A fault location method for active distribution network with DGs”	Binary Particle Swarm Optimization Algorithm	Bao <i>et al.</i> (2021)
“Fault location of distribution networks based on multi-source information”	Binary Particle Swarm Optimization Algorithm	W. Li <i>et al.</i> (2020)
“Fault section location of active distribution network based on wolf pack and differential evolution algorithms”	<i>Wolf pack and differential evolution algorithms</i>	H. Yang <i>et al.</i> (2020)
“Precise fault location in distribution networks based on optimal monitor allocation”	Algoritmo óptimo de asignación de monitorización	H. Sun <i>et al.</i> (2020)
“Single phase fault diagnosis and location in active distribution network using synchronized voltage measurement”	Red neuronal <i>wavelet</i>	T. Zhang <i>et al.</i> (2020)
“Fault location in microgrids: A communication-based high-frequency impedance approach”	Máquinas de soporte vectorial (SVM)	Beheshtaein <i>et al.</i> (2019)
“Detection and localization of faults in smart hybrid distributed generation systems: A Stockwell transform and artificial neural network-based approach”	Detección: transformada de Stockwell Ubicación: redes neuronales artificiales	Lala <i>et al.</i> (2019)

Título de la publicación	Técnica implementada	Referencia
“Assessment of fault location methods for electric power distribution networks”	Inferencia difusa basada en red adaptativa	Yellagoud y Talluri (2018)
“Fault identification based on artificial immunological systems”	Sistemas inmunológicos artificiales (AIS)	Sonoda <i>et al.</i> (2018)
“Application of improved quantum genetic algorithm in fault location of distribution network”	Algoritmo genético cuántico	X. Wang <i>et al.</i> (2018)

Fuente: elaboración propia a partir de Giral-Ramírez (2022).

El principio de *no-free-lunch* establece que no existe una técnica que proporcione los mejores resultados para todos los casos. De acuerdo con el problema específico por resolver, cada técnica cuenta con un conjunto de ventajas y desventajas. La ubicación de fallas utilizando métodos de IA genera nuevos retos debido a que requiere datos de entrenamiento y validación, junto con equipos de procesamiento robustos (Darab *et al.*, 2019; Maruf *et al.*, 2018). Los principales desafíos con respecto a la posible implementación de técnicas inteligentes para la ubicación de fallas son los siguientes:

- La calidad y selección de la información para el entrenamiento y validación de los modelos.
- Información de entrenamiento y validación limitada o inexacta.
- Lenta convergencia en el proceso de entrenamiento, de acuerdo con los criterios del modelo por implementar.
- Reentrenamiento cada vez que hay cambios en el estado del sistema.
- Carga de computación elevada.
- No solo es importante que proporcionen buenos resultados y resuelvan tareas complejas, sino que también deben ser diseñadas para ser eficientes.

1.5. Trabajos relacionados

Los antecedentes se analizan desde tres enfoques: ubicación de fallas en líneas de distribución; técnicas de IA y optimización para ubicación de fallas en redes de distribución, y técnicas de IA para análisis de fallas en GD. Se identificaron investigaciones relevantes que relacionan algunos de los enfoques descritos. El análisis inicia con una descripción general de las publicaciones, para luego dar una descripción particular de cada una de ellas desde sus objetivos, metodología, resultados y herramienta de simulación utilizada.

En el área de ubicación de fallas en líneas de distribución, se describen tres publicaciones y el estándar IEEE. Es fundamental presentar como antecedente el estándar IEEE C37.114-2014 (IEEE, 2015), guía para determinar la ubicación de fallas en líneas de transmisión y distribución en corriente alterna. Este documento presenta la descripción de los enfoques tradicionales y las técnicas de medición utilizadas en los dispositivos modernos para la ubicación de fallas: métodos basados en impedancia de uno y dos terminales y el método de onda viajera.

Respecto a las publicaciones, durante los últimos años se encuentran diversas metodologías que describen algunas técnicas, como las transformadas de *wavelet* y los sistemas de monitoreo, entre otras; además, se realizan propuestas para mejorar el modelo basado en ondas viajeras. He *et al.* (2018) proponen un esquema de protección adaptativo para la ubicación de fallas monofásicas utilizando ondas viajeras, mientras que Nuthalapati y Sinha (2019) analizan la ubicación de fallas de alta impedancia a través del sistema de comunicación.

Los resultados obtenidos en cada uno de los trabajos permiten identificar que las estrategias seleccionadas para el ajuste de los respectivos modelos cuentan con buenos rendimientos; sin embargo, no presentan análisis comparativos con otros tipos de estrategias. Nuthalapati y Sinha (2019) estudian la viabilidad de implementar la estrategia para redes inteligentes, pero no validan cuantitativamente la afirmación.

Por otro lado, Sharma *et al.* (2018) utilizan la transformada de Stockwell para obtener un clasificador; aunque el análisis realizado se puede extrapolar a la ubicación de fallas, los resultados presentados están enfocados en la

clasificación de las fallas. En general, los tres trabajos presentados utilizan casos de estudio radiales, y los modelos no son evaluados para flujos de corrientes bidireccionales.

A continuación, se describen las tres publicaciones citadas para el área de ubicación de fallas en líneas de distribución.

Nuthalapati y Sinha (2019) analizan las fallas que no tocan el suelo, y resaltan las falencias de los actuales sistemas de ubicación para caracterizar este tipo de perturbaciones. La ubicación de fallas de alta impedancia en los sistemas de distribución es poco utilizada actualmente. El problema radica en que los sistemas de identificación utilizan como criterio el incremento de la magnitud de corriente, pero una falla de alta impedancia no causa un cambio considerable en el flujo de corriente, por lo que no es fácilmente detectable.

En la actualidad, la solución para identificar o ubicar estas fallas corresponde al diagnóstico visual por parte del servicio de mantenimiento o por los usuarios. Para identificar y caracterizar estas fallas en las redes, los autores proponen un modelo basado en *frequency power line carrier communication guardian*. La técnica implementada es un circuito radial con un alimentador, una línea de distribución y un sistema de monitoreo; para ello, se incorporan al sistema dos transformadores de medida, cuatro interruptores, un condensador de acoplamiento y un controlador lógico programable, y como herramienta de simulación se utilizan Matlab y PSCAD.

He *et al.* (2018) analizan los esquemas de protección de sobrecorriente para fallas en derivación en sistemas de distribución; específicamente, evalúan las desventajas de las ondas viajeras para el análisis de las fallas monofásicas. Los autores desarrollan un modelo adaptativo de la técnica de ondas viajeras, lo que le permite al modelo propuesto identificar con precisión la falla monofásica a tierra de otras fallas de cortocircuito. El sistema implementado es un circuito radial con dos nodos y una línea de distribución, y la simulación se realiza a través de un esquema de protección para la función de sobrecorriente.

Sharma *et al.* (2018), por su parte, analizan de forma global el uso de procesamiento de señales y técnicas para la identificación de fallas en líneas de distribución, para lo cual presentan una corta descripción basada en

referencias bibliográficas sobre la transformada de *wavelet*, la transformada de *wavelet* discreta (DWT), la transformada de Hilbert Huang y la transformada de Gabor. Específicamente, los autores proponen un algoritmo que descompone la señal de tensión y corriente a través de la transformación de Stockwell; de esta descomposición obtienen la matriz S y utilizan los valores medios de la matriz como índice de falla. El estudio se llevó a cabo en Matlab, utilizando el sistema de prueba de bus IEEE-13.

En el área de técnicas de IA y optimización para la ubicación de fallas en redes de distribución, se describen tres publicaciones que trabajan en conjunto los dos enfoques y que tienen relación con la presente propuesta de investigación. Veerasamy *et al.* (2019) implementan la DWT, y como técnicas de clasificación, cinco estrategias: AI, Bayes, redes neuronales multicapa, sistemas de inferencia adaptativa neurodifusa (ANFIS) y máquinas de soporte vectorial (SVM). Khaleghi *et al.* (2018) implementan la transformada de *wavelet* y ANFIS para localizar zonas de fallas transitorias; a su vez, Aslan y Yağan (2016) usan redes neuronales artificiales con propagación hacia atrás para la ubicación de fallas en líneas aéreas.

Veerasamy *et al.* (2019) utilizan análisis estadísticos para comparar diferentes estrategias de clasificación, lo que permite establecer ventajas y desventajas de los diferentes modelos implementados. Khaleghi *et al.* (2018) y Aslan y Yağan (2016) no presentan discusiones sobre otras posibles técnicas de IA ni incluyen propuestas para el análisis de sistemas bidireccionales de corriente. Actualmente, son diversas las técnicas de IA y de optimización que pueden aportar resultados eficientes al proceso de ubicación de fallas.

Veerasamy *et al.* (2019) incorporan métricas estadísticas, y Khaleghi *et al.* (2018) usan métricas de desempeño basadas en la carga computacional y los tiempos de ejecución, características relevantes para este tipo de estrategias; sin embargo, en el área de análisis de fallas, este tipo de métricas son poco estudiadas, como se identifica en Aslan y Yağan (2016) donde se analiza el desempeño del modelo, pero no su tiempo de respuesta: el objetivo es ubicar la falla en el menor tiempo posible.

A continuación, se describen las tres publicaciones citadas para el área de técnicas de IA y optimización para ubicación de fallas.

Veerasamy *et al.* (2019) implementan la DWT para el análisis de las señales de corriente de falla que son obtenidas a través de simulaciones en Matlab, y como técnica de clasificación realizan un análisis comparativo de cinco estrategias: AI, Bayes, redes neuronales multicapa, ANFIS y SVM. Para comparar las estrategias, se utiliza el error absoluto medio, la raíz del error cuadrático medio, la estadística kappa, la tasa de éxito y la tasa de discriminación.

Los resultados demuestran que los clasificadores ANFIS y SVM son los más efectivos, con un rendimiento sustancialmente superior a otros clasificadores. Las simulaciones y el diseño de los clasificadores se llevan a cabo en Matlab, utilizando un sistema radial de distribución.

Khaleghi *et al.* (2018) desarrollan un método para localizar la zona de fallas transitorias y clasificar el tipo de falla en los sistemas de distribución de energía utilizando la transformada de *wavelet* y ANFIS. El documento destaca los retos, los costos y la baja precisión de las actuales técnicas de ubicación de fallas en líneas de distribución.

La estrategia propuesta por los autores extrae las señales de corriente del alimentador principal, y a través de redes ANFIS se implementan cuatro algoritmos para ubicar la zona de falla: un algoritmo por cada falla en derivación. El modelo tiene una menor complejidad que los métodos tradicionales; este criterio se establece por la disminución en la carga computacional y el tiempo de ejecución. Adicionalmente, el método presenta una mayor precisión, pues el error máximo observado fue inferior al 2%. Las simulaciones se realizan en EMTP-RV para un sistema radial de distribución de 25 kV.

Aslan y Yağan (2016) presentan un algoritmo de ubicación de fallas para líneas de distribución de energía aérea basadas en una red neuronal artificial. En general, las técnicas basadas en redes neuronales tienden a funcionar mejor en presencia de resistencia a fallas y variaciones en los parámetros del sistema de potencia, además de que no requieren un conocimiento preciso de la configuración del sistema.

El método utiliza una red neuronal artificial alimentada mediante el algoritmo de propagación hacia atrás con una función de entrenamiento Levenberg-Marquardt. Las entradas de la red neuronal se forman a través del uso de información de frecuencia de datos de fallas que se obtuvieron

con filtrado digital. El algoritmo se prueba ampliamente bajo diversas condiciones del sistema, según el tipo de falla generada en el sistema de distribución que se ha modelado con el *software* Matlab.

En el área de técnicas de IA para el análisis de fallas en GD, se describen tres publicaciones que trabajan en conjunto los dos enfoques. Z. Sun *et al.* (2021) implementan redes neurales; Fei y Moses (2019), optimización metaheurística.

Los resultados presentados en Z. Sun *et al.* (2021), Fei y Moses (2019) y Hui *et al.* (2019) permiten identificar el buen desempeño de las técnicas seleccionadas, pues se presentan buenos resultados y métricas relevantes para el tipo de problema analizado. Durante los últimos años, se ha propuesto un considerable número de técnicas en la literatura que abordan diferentes problemas. Sin embargo, es importante destacar que no existe un algoritmo que sea el mejor para todos los problemas. Se ha demostrado que, si un algoritmo se destaca en una función específica, es probable que otros algoritmos superen su desempeño en otras tareas.

Para mejorar las estrategias de solución de problemas, una propuesta prometedora es la utilización de algoritmos híbridos. Esta aproximación permite aprovechar las ventajas y superar las desventajas de diferentes estrategias, combinándolas para crear un algoritmo global que supere los enfoques individuales.

A continuación, se describen las tres publicaciones que trabajan en conjunto los enfoques de ubicación de fallas en GD.

Z. Sun *et al.* (2021) proponen un sistema basado en transmisión sináptica eléctrica para la ubicación de fallas en líneas de distribución con GD; para el análisis del flujo de corrientes bidireccionales, se relacionan las características bidireccionales de la transmisión sináptica eléctrica con la dirección de la corriente en un sistema de distribución por la incorporación de generación en los puntos de demanda.

Con el objetivo de verificar la precisión del método, se analizan tres tipos de fallas: falla única, fallas múltiples y fallas de información errónea. Además, se compara la eficiencia del modelo en función de la complejidad de la red de distribución. Finalmente, la estrategia, metodología y métricas

implementadas demuestran que el modelo cuenta con resultados eficientes. Los modelos se analizan a través de estructuras matriciales, y se utiliza Matlab como herramienta de simulación.

Fei y Moses (2019) proponen un algoritmo de rastreo de corriente aumentado con máquina de soporte vectorial; el objetivo del algoritmo de rastreo es construir un trazado del flujo y dirección de las corrientes de fuentes conectadas en diferentes nodos del sistema de distribución. La SVM se entrena como técnica de clasificación para identificar las corrientes de fallas trazadas. El trazado y la clasificación son comparados con los equivalentes de circuitos originales.

La SVM se evaluó y comparó utilizando diferentes métodos de kernel, lo cual mejoró la sensibilidad a fallas de muy bajo nivel. En términos generales, el método propuesto presenta resultados eficientes, con buenos ajustes para el esquema de protección de sobrecorriente del lado primario de la red de distribución. Sin embargo, no se especifica la herramienta de simulación utilizada en el estudio.

Hui *et al.* (2019) analizan la ubicación de fallas para el mejoramiento y seguridad de redes de distribución en corriente continua. Para este tipo de sistemas, al fallar una línea, el condensador del sistema de conversión se descarga rápidamente y hace que la corriente de falla aumente en un corto tiempo, lo que es extremadamente perjudicial para la seguridad del sistema, por lo que se requiere que la falla se ubique en el menor tiempo posible.

Las redes en corriente continua son el método de distribución de energía más prometedor por las nuevas cargas que se están conectando al sistema, como los automóviles eléctricos, los edificios inteligentes y la comunicación de datos; los autores destacan que son pocas las investigaciones sobre identificación de fallas y métodos de ubicación. Se propone un algoritmo de enjambre de partículas para la identificación de parámetros; el objetivo es optimizar los resultados de medición, para disminuir los errores causados por el muestreo inexacto.

Los resultados del estudio indican que el método propuesto no se ve afectado por la resistencia de transición y presenta una alta precisión de posicionamiento. La verificación del método de ubicación de fallas se lleva a cabo en la plataforma de simulación Matlab.

1.5.1. Análisis comparativos

En la tabla 3 se presenta un análisis comparativo de los métodos de ubicación de fallas previamente mencionados para los sistemas de distribución con GD.

Tabla 3. Análisis comparativo de los métodos de ubicación de fallas con GD

Técnica	Ventajas	Desventajas
Adaptativa	• Proporciona la configuración correcta para diferentes condiciones de funcionamiento. • Conserva la configuración de protección original, por lo que es económica.	• Requisitos del sistema de comunicación que aumentan el costo del sistema. • Cálculo complejo del ajuste del relé en caso de alta penetración de GD.
Impedancia	• Los canales de comunicación no son necesarios en la técnica de un solo extremo y es posible su uso simple en un relé de protección digital. • Se pueden obtener resultados más precisos con el método de dos extremos si el canal de comunicación está disponible.	• Múltiples posiciones de falla en las redes de distribución multilaterales. • Supone una red homogénea, error debido a la carga del sistema y la impedancia de falla.
Ondas viajeras	• Muy precisa y rápida. • Es independiente de muchos parámetros del sistema.	• Necesita adquisición de datos de alta frecuencia. • Requiere una referencia de tiempo común muy precisa.
En conocimientos	• Posee características como una tasa de aprendizaje rápida y tolerancia a fallas. • Es capaz de entregar una salida precisa con entrada parcial.	• Convergencia, cantidad y calidad en función de los datos de entrenamiento y validación. • Carga computacional alta. • Reentrenamiento del algoritmo en caso de cambio del sistema.
Métodos híbridos	• Aprovecha los beneficios de dos o más métodos.	• Requiere una toma de decisiones cuidadosa para usar la salida de relé. • Modelos confiables para crear datos de entrenamiento.

Fuente: elaboración propia a partir de Giral-Ramírez (2022) y Kumar y Saxena (2020).

2. Diseño del modelo inteligente

Las redes de distribución inteligentes son el futuro de la industria energética, debido a sus características de adaptabilidad y por la gran cantidad de acceso a la GD. Actualmente, los sistemas de distribución están realizando una transición del flujo de energía unidireccional al flujo de energía bidireccional, lo que plantea un nuevo desafío para la ubicación de secciones de falla con múltiples fuentes de energía (M. Zhao y Zhang, 2020). Para las redes de distribución con GD, es necesario estudiar la influencia de la posición de la instalación de GD en la dirección de la corriente de falla y construir la función de conmutación adecuada (Giral-Ramírez, 2022).


En los últimos años, se han propuesto diversas técnicas en las que la IA ha presentado buenos resultados por su alto rendimiento y capacidad para proporcionar una respuesta rápida. Aunque los avances en el campo de la IA son prometedores, todavía hay muchas preguntas que deben responderse. Es necesario realizar un trabajo constante para identificar los avances en IA y obtener mejores resultados. Además, las técnicas implementadas deben ser escalables para gestionar eficazmente la carga computacional y abordar problemas de mayor complejidad.

La figura 14 presenta el modelo inteligente para la ubicación de fallas de baja impedancia en líneas de distribución con GD propuesto, el cual se caracteriza a través de cuatro etapas.

En la primera etapa se analiza el evento de falla a través del estudio de cortocircuito (etapa 1: Test Power System y Short Circuit Study). En la segunda etapa, después de que ocurre el evento de falla, se establece el estado de los interruptores del sistema de acuerdo con las mediciones y las alarmas de sobrecorriente (etapa 2: Feeder Terminal Unit [FTU] y Switching Function).

En la tercera etapa se ubica el segmento de falla implementado un algoritmo de búsqueda metaheurística. Finalmente, en la cuarta etapa se generan las métricas. A continuación, se describe cada una de las etapas del modelo inteligente implementado.

Figura 14. Modelo inteligente para la ubicación de fallas propuesto



Fuente: elaboración propia.

2.1. Etapa 1: sistema de prueba y estudio de cortocircuito

En esta etapa se realiza la descripción del sistema de prueba utilizado y de la estrategia para el estudio de cortocircuito. Para el sistema de prueba, se define la metodología para enumerar los nodos y las características de los dispositivos que se requieren para la medición y protección, mientras que para el estudio de cortocircuito se presentan las herramientas de simulación utilizadas.

2.1.1. Sistema de prueba

El modelo inteligente para la ubicación de fallas se analizó en el sistema de la figura 15. Este sistema se tomó por sus características de suministro múltiple y por las múltiples particularidades que se pueden incluir (Huang *et al.*, 2020). A continuación, se presenta cada una de las características del sistema de acuerdo con las variables que se requiere implementar en el modelo inteligente implementado.

2.1.1.1. Características del sistema de prueba


- Fuentes de alimentación: cantidad de fuentes de alimentación, incluyendo la GD. El sistema de la figura 15 tiene dos fuentes de alimentación ($\{ER, GD\}$): la subestación principal modelada a través del equivalente de red (ER) y la GD.
- Interruptor de interconexión: es un interruptor instalado para permitir que un sistema con suministro de múltiples fuentes se pueda convertir en un sistema de suministro único. El sistema de la figura 15 tiene un interruptor de interconexión ($\{KL\}$).
- Interruptores de segmentos: son los dispositivos diseñados para proteger la red de distribución y donde se va a instalar el sistema de medida. De acuerdo con la posición del interruptor, la red de distribución se puede dividir en áreas *aguas arriba* y áreas *aguas abajo*. El sistema de la figura 15 tiene una red con diez interruptores de segmentos ($\{k1, k2, k3, \dots, k10\}$), por lo que el sistema tiene diez dispositivos de medición.
- Número de nodos: en el modelo propuesto, los interruptores de segmentos se utilizan como nodos; la cantidad de interruptores de segmentos o

nodos se define de acuerdo con las cantidades de segmentos por analizar. El sistema de la figura 15 es una red de diez nodos.

- Segmento de línea: el área entre dos interruptores adyacentes es un segmento de línea. La línea tiene dos condiciones: el segmento de línea sin falla y el segmento de línea en falla. La ecuación (1) presenta el estado x_i del segmento de línea i para cada una de las condiciones. El sistema de la figura 15 es una red con diez segmentos de líneas ($\{X1, X2, X3, \dots, X10\}$).

$$x_i = \begin{cases} 0 & \text{Segmento de línea sin falla} \\ 1 & \text{Segmento de línea en falla} \end{cases} \quad (1)$$

Figura 15. Sistema de prueba: descripción del modelo inteligente para la ubicación de fallas



Fuente: elaboración propia a partir de Huang *et al.* (2020).

2.1.2. Estudio de cortocircuito


El modelo inteligente para la ubicación de fallas se desarrolló en Matlab, y el estudio de cortocircuito se realizó con el *software* de acceso abierto OpenDSS. OpenDSS es un *distribution system simulator* (DSS) diseñado para admitir la integración y modernización de la red de recursos energéticos distribuidos. Es un simulador multiplataforma de código abierto que permite modelar tecnologías de distribución, recursos, activos y controles tradicionales y avanzados; además, permite realizar cosimulaciones con diferentes *software*, como Matlab y Python (Cikan y Cikan, 2023; Mejdi *et al.*, 2022).

La implementación de casos de estudio en OpenDSS no es complicada; solo se requieren conocimientos generales de programación, debido a que no cuenta con una interfaz gráfica. Es importante destacar que durante los últimos años se ha impulsado una versión gráfica llamada OpenDSS-G, la cual, aunque tiene múltiples ventajas, limita la utilidad de OpenDSS, además de generar una elevada carga computacional.

El objetivo de utilizar OpenDSS y Matlab es aprovechar las ventajas de cada una de estas herramientas. OpenDSS es un simulador ligero que permite implementar escenarios con recursos energéticos distribuidos sin una elevada carga computacional, mientras que Matlab es un simulador numérico que cuenta con dos entornos para la creación de aplicaciones gráficas: Guide y App Designer.

Guide fue una herramienta que durante muchos años implementó Matlab para la creación de aplicaciones, pero se dejó de actualizar. Desde 2016, Matlab incluyó un segundo entorno, App Designer, un entorno profesional de diseño dedicado a la creación de aplicaciones web y de escritorio. Aunque Matlab es un *software* pago, las aplicaciones de escritorio compiladas se pueden compartir y utilizar sin ningún tipo de costo. En la figura 16 se presenta el flujo de información entre OpenDSS y App Designer para consultas de parámetros.

Figura 16. Flujo de información entre OpenDSS y App Designer



Fuente: elaboración propia.

2.2. Etapa 2: unidad de terminal de alimentación y función del interruptor

En esta etapa se presenta el sistema utilizado para la medición de las condiciones de operación. Adicionalmente, se describe de forma detallada el modelo

matemático que se requiere para obtener los estados esperados del interruptor de segmento. También, se describen las variables y se plantea un ejemplo para un interruptor de segmento.

2.2.1. Unidad de terminal de alimentación (FTU)

Las redes de distribución se caracterizan por tener una gran cantidad de nodos con pocas mediciones; esto indica que la estimación del estado del sistema de distribución carece de mediciones en tiempo real, lo que dificulta la supervisión y posterior control del sistema (Long *et al.*, 2022; Primadianto y Lu, 2017). Con el objetivo de incluir la estimación del estado del sistema en tiempo real y satisfacer su observabilidad, el modelo inteligente de ubicación de fallas propuesto utiliza unidades de terminal de alimentador (*feeder terminal unit* [FTU]) como sistema de medida.

Una FTU es un dispositivo electrónico inteligente diseñado para la medición y automatización de alimentadores. Permite almacenar datos y transmitirlos al centro de control (D. Zhao *et al.*, 2022). Estos dispositivos son ampliamente utilizados en las redes de distribución para la ubicación, aislamiento y restauración de fallas (*fault location, isolation, and restoration* [FLIR]) (Farughian *et al.*, 2018).

Diferentes FTU se instalan en una red de distribución para monitorear las condiciones de operación (J. Li *et al.*, 2022). Cuando uno o varios tramos simultáneos de la red fallan, las FTU relacionadas adquieren rápidamente la información de sobrecorriente y luego la envían a los sistemas de gestión de la red. En consecuencia, las señales de alarma recopiladas proporcionadas por las FTU están disponibles para localizar los tramos en falla (Xiong *et al.*, 2022).

La utilización de las FTU para cargar señales de estado de falla y lograr una ubicación rápida y precisa se ha convertido en un tema de investigación relevante. Hasta el momento, académicos de varios países han propuesto algunos métodos y algoritmos de ubicación de fallas basados en FTU (Chih *et al.*, 2022; J. Chen *et al.*, 2020; J. Li *et al.*, 2022).

Como se describió, el sistema de medida se instala en los interruptores de segmentos; por lo tanto, las condiciones de operación monitoreadas por las FTU que se almacenan y transmiten al centro de control corresponden

al estado de los interruptores de segmentos; a continuación, se describe en detalle cuáles son estos estados.

2.2.2. Función del interruptor

La función del interruptor se utiliza para determinar los estados de los interruptores de segmento. La función del interruptor transforma la información de los estados de los segmentos de línea ($\{x\}$) en los estados de los interruptores de segmentos ($\{k\}$). Esta transformación puede considerarse innecesaria, de acuerdo con la ecuación (1); para ubicar el segmento de la línea en falla, solo se requiere identificar los estados de los segmentos de línea. Entonces, ¿para qué implementar esta transformación si ya se conocen los estados de los segmentos de línea?

La respuesta a esta interrogante radica en el hecho de que el sistema de medición implementado (FTU) monitorea, almacena y transmite la información asociada a los estados de los interruptores de segmentos; es decir, las FTU no monitorean las condiciones de los segmentos de línea.

Esta aclaración genera una segunda pregunta: si las FTU solamente monitorean las condiciones de operación de los estados de los interruptores de segmentos, ¿cómo se puede implementar la función del interruptor si no se conocen los estados de los segmentos de línea ($\{x\}$)? La respuesta es trivial: para implementar la función del interruptor, se deben generar estados de los segmentos de línea aleatorios. Evidentemente, bajo este escenario aleatorio, los estados de los interruptores de segmento obtenidos por la función del interruptor no corresponden con las características reales del sistema. En este punto es donde se incorpora la técnica de optimización inteligente.

Supongamos un evento: falla un segmento de línea del sistema de distribución; durante este evento, se ejecutan cuatro pasos. En el primero paso, las FTU caracterizan el evento, almacenando y transmitiendo los estados de los interruptores de segmentos. En el segundo paso, se genera un conjunto de estados aleatorios de segmentos de línea. En el tercer paso, la función del interruptor transforma los estados aleatorios de segmentos de línea en estados de los interruptores de segmentos. En el cuarto paso, se comparan los estados de los interruptores de segmentos obtenidos en el tercer paso con los almacenados y transmitidos por las FTU.

El objetivo de este proceso es encontrar, a partir de los estados aleatorios de segmentos de línea (segundo paso), los estados de los interruptores de segmentos almacenados y transmitidos por las FTU (primero paso). En otras palabras, se busca el conjunto de estados de segmentos de línea que hace que la función del interruptor entregue los estados de los interruptores de segmentos almacenados y transmitidos por las FTU, y esta búsqueda se realiza a través de la técnica de optimización inteligente.

2.2.2.1. Estados de los interruptores de segmentos

Las condiciones de operación monitoreadas por las FTU corresponden a los estados de los interruptores de segmentos. Para establecer los estados, se establece un umbral de corriente I_d , un evento de falla con una corriente I_{Falla} y una dirección positiva; cuando la red funciona normalmente, la dirección de la corriente es la dirección positiva de la red. Siendo I_k el estado de los interruptores de segmentos, la ecuación (2) describe los estados y las respectivas condiciones.

$$I_k = \begin{cases} 0 & I_{Falla} < I_d \text{ o sistema sin falla} \\ 1 & I_{Falla} > I_d \text{ Dirección } I_{Falla} \text{ Igual que la dirección positiva} \\ -1 & I_{Falla} > I_d \text{ Dirección } I_{Falla} \text{ Opuesta a la dirección positiva} \end{cases} \quad (2)$$

- 0: indica que la corriente que fluye a través de los interruptores de segmentos es menor que el umbral de corriente (I_d).
- 1: indica que la corriente (I_{Falla}) que fluye a través de los interruptores de segmentos es mayor que el umbral de corriente (I_d); su dirección es la misma que la dirección positiva de la red.
- -1: indica que la corriente (I_{Falla}) que fluye a través de los interruptores de segmentos es mayor que el umbral de corriente (I_d); su dirección es opuesta a la dirección positiva de la red.

2.2.2.2. Estados esperados de los interruptores de segmentos (I_k^*)

Los estados esperados de los interruptores de segmentos (I_k^*) corresponden a los estados de los interruptores de segmentos obtenidos al implementar los estados aleatorios de segmentos de línea en la función de interruptor.

2.2.2.3. Modelo matemático para la función del interruptor

En la bibliografía se pueden encontrar diferentes funciones de interruptor, expresadas en términos de sumatorias y productorias, o en términos de operadores lógicos. Algunas son exclusivas para sistemas radiales y otras permiten incluir sistemas enmallados o flujos de corrientes bidireccionales. En la tabla 4 se presentan algunas de las funciones de interruptor disponibles en la bibliografía.

Tabla 4. Funciones de interruptor

Función del interruptor	Referencia
$I_k^* = \left[\sum_{S_1} K_{S_1} \left(1 - \sum_{i_1} x_{j,S_1}(i_1) \right) \right] \sum_n x_j(n) - \left[\sum_{S_2} K_{S_2} \left(1 - \sum_{i_2} x_{j,S_2}(i_2) \right) \right] \sum_m x_j(m)$	W. Li <i>et al.</i> (2020)
$I_k^* = \sum_{i=1}^I g \prod_{e=1}^{N_1} S_{se} - \sum_{i=1}^J g \prod_{f=1}^{N_2} S_{sf}$	W. Tao <i>et al.</i> (2016)
$I_k^* = 1 - \prod_n (1 - Z_n)$	Jin y Ju (2012)
$I_k^* = \left(1 - \sum_{\substack{p=1 \\ p \neq k}}^N x(p) \right) \bigvee_{q=k+1}^N x(q)$	Na <i>et al.</i> (2008)

Fuente: elaboración propia.

El modelo inteligente para la ubicación de fallas implementado en esta investigación utilizó la función del interruptor propuesta en Huang *et al.* (2020). Se seleccionó esta función porque está diseñada para los sistemas de distribución con GD. La función del interruptor, de acuerdo con Huang *et al.* (2020), se presenta en la ecuación (3), donde $\vee$ es la operación lógica OR. En la tabla 5 se realiza la respectiva descripción de las variables.

$$I_k^* = \left(\bigvee_m x_m \right) \cdot \left(\bigvee_{p=1}^N \left[\left(\neg(\vee x_{ksp}) \right) \cdot KL_{k \rightarrow p} \right] \right) - \left(\bigvee_n x_n \right) \cdot \left(\bigvee_{q=1}^M \left[\left(\neg(\vee x_{ksq}) \right) \cdot KL_{k \rightarrow q} \right] \right) \quad (3)$$

Tabla 5. Descripción de las variables de la función del interruptor implementada

Variable	Descripción
I_k^*	Estado esperado del interruptor de segmento {k}
x_m	Estado de cada segmento de línea {x} aguas abajo del interruptor de segmento {k}
x_{ksp}	Desde el interruptor de segmentos {k} hasta las “p” fuentes de alimentación aguas arriba, el estado del segmento de la línea de paso {x}
$KL_{k \rightarrow p}$	Desde el interruptor de segmentos {k} hasta las “p” fuentes de alimentación aguas arriba, el estado del interruptor de interconexión {KL}
x_n	Estado de cada segmento de línea {x} aguas arriba del interruptor de segmento {k}
x_{ksq}	Desde el interruptor de segmentos {k} hasta las “q” fuentes de alimentación aguas abajo, el estado del segmento de la línea de paso {x}
$KL_{k \rightarrow q}$	Desde el interruptor de segmentos {k} hasta las “q” fuentes de alimentación aguas abajo, el estado del interruptor de interconexión {KL}
M	Número total de fuentes de alimentación aguas abajo del interruptor de segmento {k}
N	Número total de fuentes de alimentación aguas arriba del interruptor de segmento {k}

Fuente: elaboración propia.

De acuerdo con la tabla 5, es necesario realizar una aclaración respecto a la diferencia entre segmento de la línea de paso y segmento de línea. El segmento de la línea de paso hace referencia al conjunto de segmentos que permiten conectar el interruptor de segmento con la fuente de generación; es decir, no se incluyen las bifurcaciones. Los segmentos de línea, además de los segmentos de la línea de paso, incluyen las bifurcaciones.


2.2.2.4. Ejemplo de implementación de la función del interruptor

Supongamos que se requiere obtener la función del interruptor para los estados esperados del interruptor de segmento $k4$ (I_{k4}^*) del sistema de distribución de la figura 15.

- Primer paso: definir la dirección positiva de la red. Teniendo en cuenta que el sistema de distribución tiene GD y que la dirección positiva de la red es la dirección de la corriente cuando la red funciona normalmente, para establecer la dirección se requiere convertir el sistema de suministro múltiple a único, lo cual se realiza abriendo el interruptor de interconexión {KL}.

La dirección de la corriente de cada sistema individual, cuando está operando normalmente, es su dirección positiva. La figura 17 presenta la dirección positiva para el sistema de distribución de la figura 15.


Figura 17. Dirección positiva de una red con suministro múltiple



Fuente: elaboración propia.

- Segundo paso: definir el área aguas abajo y aguas arriba del interruptor. A partir del interruptor de segmento k4, los segmentos que pasan en la dirección positiva son los segmentos aguas abajo del interruptor (k4). Para este análisis, se mantiene cerrado el interruptor de interconexión {KL}, y la dirección positiva que se analiza es la del sistema de suministro único, donde está asociado el interruptor de segmento k4. En la figura 18 se presenta el área aguas abajo y aguas arriba para el interruptor de segmento k4. Este análisis permite definir las variables M y N . En la tabla 6 se realiza la correspondiente descripción de las variables.

Figura 18. Área aguas abajo y aguas arriba a partir del interruptor de segmento $k4$ y de la dirección positiva de la red



Fuente: elaboración propia.


Tabla 6. Descripción de las variables para el número de fuentes a partir del interruptor de segmento $k4$

Variable	Descripción	Número de fuentes
M	Número total de fuentes de alimentación aguas abajo del interruptor de segmento $\{k4\}$	1
N	Número total de fuentes de alimentación aguas arriba del interruptor de segmento $\{k4\}$	1

Fuente: elaboración propia.

- Tercer paso: definir los estados de cada segmento de línea de paso aguas arriba y aguas abajo. Es el conjunto de segmentos que permiten conectar el interruptor de segmento con la fuente de generación aguas arriba y aguas abajo, sin incluir las bifurcaciones. Para este análisis, se mantiene cerrado el interruptor de interconexión $\{KL\}$. En la figura 19 se presentan los segmentos de las líneas de paso a partir del interruptor de segmento $k4$. En la tabla 7 se realiza la correspondiente descripción de las variables.

Figura 19. Segmentos de líneas de paso a partir del interruptor de segmento $k4$



Fuente: elaboración propia.


Tabla 7. Descripción de las variables para los segmentos de línea de paso a partir del interruptor de segmento $k4$

Variable	Descripción	Segmentos de la línea de paso
x_{ksp}	Desde el interruptor de segmentos $\{k4\}$ hasta el ER, el estado del segmento de la línea de paso $\{x\}$	X1, X2, X3
x_{ksq}	Desde el interruptor de segmentos $\{k4\}$ hasta la GD, el estado del segmento de la línea de paso $\{x\}$	X4, X8, X7

Fuente: elaboración propia.

- Cuarto paso: definir los estados de cada segmento de línea aguas arriba y aguas abajo. Es el conjunto de segmentos de las líneas de paso, incluyendo las bifurcaciones. Para este análisis, se mantiene cerrado el interruptor de interconexión $\{KL\}$. En la figura 20 se presentan los segmentos de las líneas a partir del interruptor de segmento $k4$. En la tabla 8 se realiza la correspondiente descripción de las variables.

Figura 20. Segmentos de líneas a partir del interruptor de segmento $k4$



Fuente: elaboración propia.

Tabla 8. Descripción de las variables para los segmentos de línea a partir del interruptor de segmento $k4$

Variable	Descripción	Segmentos de la línea de paso
x_m	Estado de cada segmento de línea $\{x\}$ aguas abajo del interruptor de segmento $\{k4\}$	X4, X7, X8, X9, X10
x_n	Estado de cada segmento de línea $\{x\}$ aguas arriba del interruptor de segmento $\{k4\}$	X1, X2, X3, X5, X6

Fuente: elaboración propia.

- Quinto paso: definir el modelo matemático a través de la función del interruptor para los estados esperados del interruptor de segmento $k4$ (I_{k4}^*). Se implementa la ecuación (3) a partir de la información de las tablas 6, 7 y 8. El resultado obtenido se presenta en la ecuación (4). El último paso es aplicar el operador lógico OR.

$$I_{k4}^* = \left(\bigvee (x4, x7, x8, x9, x10) \right) \cdot \left(\bigvee_{p=1}^1 \left[\left(\neg \left(\bigvee (x1, x2, x3) \right) \right) \cdot (1) \right] \right) - \left(\bigvee_n (x1, x2, x3, x5, x6) \right) \cdot \left(\bigvee_{q=1}^1 \left[\left(\neg \left(\bigvee (x4, x8, x7) \right) \right) \cdot (1) \right] \right) \quad (4)$$

2.2.2.5. Lógica de programación de la función del interruptor

Para obtener la ubicación de la falla cuando se presenta un evento, se requiere la función del interruptor para todos los interruptores de segmento. En la figura 21 se presenta la función (Switching_Function) implementada en Matlab para todos los estados esperados de los interruptores del sistema de prueba de la figura 15.

Figura 21. Función del interruptor para los interruptores de segmento

```
function [Ik_current] = Switching_Function(FTU)

X = FTU;
X1 = X(1,1); X2 = X(1,2); X3 = X(1,3); X4 = X(1,4); X5 =
X(1,5);
X6 = X(1,6); X7 = X(1,7); X8 = X(1,8); X9 = X(1,9); X10 =
X(1,10);

Ik1 = ( X1||X2||X3||X4||X5||X6||X7||X8||X9||X10 ) * not(0) -
...
      ( 0 ) * not( X1||X2||X3||X4||X7||X8 );
Ik2 = ( X2||X3||X4||X5||X6||X7||X8||X9||X10 ) * not(X1) - ...
      ( X1 ) * not( X2||X3||X4||X7||X8 );
Ik3 = ( X3||X4||X6||X7||X8||X9||X10 ) * not(X1||X2) - ...
      ( X1||X2||X5 ) * not( X3||X4||X7||X8 );
Ik4 = ( X4||X7||X8||X9||X10 ) * not(X1||X2||X3) - ...
      ( X1||X2||X3||X5||X6 ) * not(X4||X7||X8);

IKAp = 1; IKBp = 0; Ikq = 0;
Ik5 = ( X5 ) * ( ( not( X1||X2 ) * (IKAp) ) ||
( not( X3||X4||X8||X7 ) * (IKBp) ) ) -...
      ( X1||X2||X3||X4||X6||X7||X8||X9||X10 ) * ( not( 0
) * (Ikq) );

IKAp = 1; IKBp = 0; Ikq = 0;
Ik6 = ( X6 ) * ( not( X1||X2||X3 ) * (IKAp) || not(
X4||X8||X7 ) * (IKBp) ) -...
      ( X1||X2||X3||X4||X5||X7||X8||X9||X10 ) *
( not( 0 ) * (Ikq) );

IkAq = 0;
Ik7 = ( X1||X2||X3||X4||X5||X6||X7||X8||X9||X10 ) * not(0) -
...
      (0) * ( not( X1||X2||X3||X4||X7||X8 ) * (IkAq) );

IkAq = 0;
```

```

Ik8 = ( X1||X2||X3||X4||X5||X6||X8||X9||X10 ) * ( not(X7) *
(1) ) - ...
      ( X7 ) * ( not( X1||X2||X3||X4||X5||X8 ) * (IkAq));

IKAp = 0; IKBp = 1; Ikq = 0;
Ik9 = ( X9||X10 ) * ( not( X1||X2||X3||X4||X8 ) * (IKAp) ||
not( X7||X8 ) * (IKBp) ) -...
      ( X1||X2||X3||X4||X5||X6||X7||X8 ) * ( not( 0 ) *
(Ikq) );

IKAp = 0; IKBp = 1; Ikq = 0;
Ik10 = ( X10 ) * ( not( X1||X2||X3||X4||X8||X9 ) * (IKAp) ||
not( X7||X8||X9 ) * (IKBp) ) -...
      ( X1||X2||X3||X4||X5||X6||X7||X8||X9 ) *
( not( 0 ) * (Ikq) );

Ik_current = [Ik1 Ik2 Ik3 Ik4 Ik5 Ik6 Ik7 Ik8 Ik9 Ik10];

end

```

Fuente: elaboración propia.

2.3. Etapa 3: técnicas de optimización inteligente implementadas

La investigación de operaciones se dedica a modelar y resolver problemas complejos mediante el uso de técnicas de optimización. Durante mucho tiempo, estas técnicas han sido objeto de estudio por parte de investigadores de diversas áreas científicas (Y. Li *et al.*, 2016). Por otro lado, la computación bioinspirada es una rama de la optimización que se inspira en los fenómenos naturales (Bozorg-Haddad, 2018). Estas estrategias, conocidas como optimización metaheurística, forman parte de las técnicas de optimización inteligente y han enriquecido las estrategias de optimización existentes, pues ofrecen un rendimiento eficiente y proporcionan soluciones a problemas complejos (Y. Li *et al.*, 2016). Además, su amplio uso se debe a su simplicidad y flexibilidad (Kaur *et al.*, 2018). Son especialmente eficaces para resolver problemas complejos de ingeniería y problemas NP-difíciles en informática (Vasuki, 2020).

Durante los últimos años, en la literatura se ha propuesto una considerable cantidad de nuevos algoritmos bioinspirados. Aunque muchos de estos algoritmos son prometedores, la mayoría aún se encuentran en sus etapas iniciales

de desarrollo (Bozorg-Haddad, 2018). Es importante tener en cuenta el principio de *no-free-lunch*, el cual establece que no es posible encontrar un algoritmo metaheurístico que sea el mejor para todos los problemas. Si un algoritmo supera a otros en una función de optimización particular, es probable que existan otras funciones en las que otros algoritmos sean más eficientes que el primero (Wolpert y Macready, 1997).

En el área de IA, utilizando técnicas de optimización, se han implementado diversos trabajos para problemas específicos de ubicación de fallas con diferentes antecedentes y objetivos (véase la sección 1.4.2). Esta investigación no propone una estrategia de optimización metaheurística “novedosa” ni establece mejoras sobre las respectivas estrategias originales (Aranha *et al.*, 2022; Sörensen, 2015); el objetivo es aplicar cuatro estrategias metaheurísticas basadas en comportamientos poblacionales para la ubicación de fallas de baja impedancia en líneas de distribución con GD.

La tabla 9 presenta las estrategias de optimización inteligentes implementadas, sus respectivas siglas y las referencias bibliográficas. Las siglas presentadas corresponden al nombre de la estrategia en inglés: *zebra optimization algorithm* (ZOA), *cuckoo search algorithm* (CSA), *lightning search algorithm* (LSA) y *binary gravitational search algorithm* (BGSA).


La contribución y novedad de este trabajo es la adaptación e implementación del ZOA, el LSA y el BGSA para la ubicación de fallas en sistemas con GD. El CSA es utilizado por Huang *et al.* (2020), trabajo que se toma como criterio de comparación para este proyecto de investigación.

Para el análisis de los resultados, y teniendo en cuenta las debilidades actuales del análisis comparativo entre metaheurísticas (Aranha *et al.*, 2022; Gao *et al.*, 2019; García-Martínez *et al.*, 2017), para una comparación justa, en cada uno de los escenarios se utiliza el mismo equipo computacional. Este trabajo analiza la precisión para identificar el segmento de línea en falla y parámetros propios de las técnicas de optimización inteligente: número de iteraciones, tiempo de simulación, mejor puntuación (mínimo de la función *fitness*) y *fitness* promedio.

De acuerdo con cada una de las etapas descritas, la figura 22 presenta el diagrama de flujo del modelo propuesto. De forma general, los cambios significativos se presentan únicamente en la lógica de operación de los algoritmos

bioinspirados adaptados. Los parámetros de entrada y salida son los mismos para ZOA, CSA, LSA y BGSA.

Figura 22. Diagrama de flujo del modelo inteligente propuesto para la ubicación de fallas con GD



Fuente: elaboración propia.

Los parámetros de entrada corresponden a 1) la caracterización y medición del evento de falla, 2) los estados reales de los interruptores de segmentos obtenidos a través de la función del interruptor y 3) la población aleatoria inicial (x_i) que se requiere para definir el espacio de búsqueda de cada una de las estrategias. Los parámetros de salida corresponden a 1) la población final o el mejor individuo (x_i), 2) los estados de los interruptores de segmentos obtenidos del mejor individuo y 3) las métricas de desempeño.

Tabla 9. Estrategias de optimización inteligentes implementadas

Estrategia	Sigla	Referencia
Algoritmo de optimización de cebrá	ZOA	Trojovská <i>et al.</i> (2022)
Algoritmo de búsqueda de cuco	CSA	Huang <i>et al.</i> (2020)
Algoritmo de búsqueda de relámpago	LSA	Shareef <i>et al.</i> (2015)
Algoritmo de búsqueda gravitacional binaria	BGSA	Rashedi <i>et al.</i> (2010)

Fuente: elaboración propia.

2.3.1. Función *fitness*

Desde el punto de vista de algoritmos metaheurísticos basados en población, la función *fitness* permite evaluar a un individuo o a una población de individuos. Esta función determina la habilidad de un individuo para competir con otros individuos. La probabilidad de que un individuo sea seleccionado está basada en el *fitness*. Si se quiere maximizar, cuanto mayor sea el valor de la función para el individuo, mayor será su *fitness*. Si se quiere minimizar, cuanto menor sea el valor de la función para el individuo, menor será su *fitness*.

De acuerdo con la función del interruptor, la función *fitness* indica el grado de proximidad del estado esperado del interruptor de segmento y el estado del interruptor de segmento. Como se describió previamente, el objetivo es encontrar un conjunto de estados de segmentos de línea (I_k^*) que haga que la función del interruptor entregue los estados de los interruptores de segmentos almacenados (I_k) y transmitidos por las FTU.

El proceso de encontrar el conjunto de estados de segmentos de línea es el proceso de optimización; por lo tanto, la función *fitness* es la función objetivo a minimizar en el modelo de optimización. Se define como un problema de

minimización porque, cuando el valor obtenido de la función *fitness* sea el más pequeño (min), es cercano a I_k . En la figura 23 se presenta el diagrama de flujo para determinar la función *fitness* en el problema de ubicación de fallas.


Las ecuaciones (5) y (6) son las funciones de evaluación utilizadas en la bibliografía. Como se describe en la figura 23, la función *fitness* toma el valor de la función evaluación. La ecuación (5) se conoce como la función de evaluación tradicional (Huang *et al.*, 2020; M. Zhao y Zhang, 2020; W. Tao *et al.*, 2016; Xiong *et al.*, 2022).

La ecuación (6) representa la función de evaluación mejorada implementada en Huang *et al.* (2020), donde ω es el factor definido para evitar juicios erróneos, α es el número de fallas supuestas y $\sum_{j=1}^m x_j - \alpha$ es el número total de fallas en todos los segmentos de línea de la red.

$$E = \sum_{k=1}^n |I_k - I_k^*| \quad (5)$$

$$E = \sum_{k=1}^n |I_k - I_k^*| + \omega \left| \sum_{j=1}^m x_j - \alpha \right| \quad (6)$$

Figura 23. Diagrama de flujo de la función *fitness*



Fuente: elaboración propia.

A continuación, se presentan los algoritmos metaheurísticos basados en población implementados. El modelo matemático detallado de cada una de las estrategias se puede consultar directamente en la publicación asociada (tabla 9).


2.3.2. Algoritmo de optimización de cebras (ZOA)

La cebra es una de las tres especies del género *Equus*, propias de África; son animales sociales que viven en manadas. Estas manadas están compuestas por un macho, varias hembras y las crías. Sin duda, su rasgo más distintivo es su patrón de coloración, que consiste en rayas blancas sobre un fondo negro. Las rayas de cada ejemplar son tan únicas como las huellas dactilares. Se destacan dos comportamientos de la vida social de las cebras: la búsqueda de alimento y la estrategia de defensa contra los depredadores (Steinberg, 2003).

- Búsqueda de alimento: una cebra es la encargada de abrir el camino para que otras cebras se trasladen al forraje; esta cebra es denominada pionera. Por lo tanto, otras cebras en la manada se mueven en las llanuras bajo la guía de esta cebra pionera.
- Estrategias de defensa: escapar en un patrón de movimiento en zigzag y agruparse para intentar confundir o asustar al depredador.

El ZOA fue propuesto por Eva Trojovská, Mohammad Dehghani y Pavel Trojovský en 2022 (Trojovská *et al.*, 2022). Desde un punto de vista matemático, cada cebra es una solución candidata al problema y el plano en el que se encuentran las cebras en el espacio de búsqueda del problema. De acuerdo con la revisión de la literatura, no se ha implementado como técnica de ubicación de fallas para sistemas eléctricos de potencia. El ZOA se presenta en el diagrama de flujo de la figura 24.

Figura 24. Diagrama de flujo del algoritmo de optimización de cebra (ZOA)



Fuente: elaboración propia.

2.3.3. Algoritmo de búsqueda de cuco (CSA)

Los pájaros cucos son famosos por el agradable sonido que producen. Algunas especies de pájaros cucos construyen sus nidos y crían a sus camadas, mientras que otras especies son parásitos de cría (De Mársico *et al.*, 2020). El parasitismo de cría y el comportamiento de vuelo de Lévy son los dos rasgos principales de las aves cuco (Dey, 2020; Vasuki, 2020).


- Parasitismo de cría: es una estrategia reproductiva en la que ciertos individuos, llamados parásitos, depositan sus huevos en los nidos de otras aves o especies, que son los hospedadores. De esta manera, los hospedadores incuban y cuidan los huevos de los parásitos como si fueran propios, a menudo a expensas de sus propias crías.
- Vuelo de Lévy: la mayoría de los seres vivos siguen un patrón similar en su movimiento. Este movimiento tiene un comportamiento fractal y se denomina vuelo de Lévy. El patrón en su movimiento consiste en alternar movimientos cortos al azar, similares al movimiento browniano, con trayectorias más largas. El vuelo de Lévy se caracteriza por ser una forma especial de caminata aleatoria, donde la longitud de cada paso sigue una distribución de probabilidad con una cola pesada (Vasuki, 2020).

El CSA fue propuesto por Xin-She Yang y Suash Deb en 2010 (X.-S. Yang y Deb, 2010). Desde un punto de vista matemático, las soluciones se representan como nidos o cucos; de acuerdo con la calidad de las soluciones, estas pueden ser mejoradas (expulsar del nido) o eliminadas por nuevas soluciones (abandonar el nido y parasitar uno nuevo). Según la revisión de la literatura, son diversas las aplicaciones del CSA para sistemas eléctricos de potencia; en el área de ubicación de fallas se destaca Huang *et al.* (2020). El CSA se presenta en el diagrama de flujo de la figura 25.

2.3.4. Algoritmo de búsqueda de relámpago (LSA)

El rayo es el origen del trueno (sonido que resulta de los rayos) y del relámpago (luz emitida por el rayo). Los rayos son un conjunto de descargas eléctricas que se producen en las nubes. El LSA se basa en el fenómeno natural del rayo y en el mecanismo de propagación de un líder escalonado utilizando el concepto de partículas rápidas (Abualigah *et al.*, 2021).

Figura 25. Diagrama de flujo del algoritmo de búsqueda de cuco (CSA)



Fuente: elaboración propia.

- **Líder escalonado:** el líder escalonado es el vehículo mediante el cual los electrones se mueven de la nube a la tierra. El proceso para que se genere el rayo inicia con un camino de carga desde la nube. Este camino se va moviendo a través del aire y se desplaza, en tramos, con distintas direcciones. Este camino es lo que se conoce como el “líder escalonado” (Torres, 2002).
- **Partículas rápidas o proyectiles:** es el mecanismo de propagación de un líder escalonado. Durante el proceso de congelación de las moléculas de agua dentro de una nube, una parte de las moléculas de agua son expulsadas del

hielo en formación en una dirección aleatoria, como proyectiles. Después de ser expulsado de la nube, el proyectil viaja a través de la atmósfera, proporcionando un camino o canal de ionización inicial (Moreno *et al.*, 2021).

El LSA fue propuesto por Hussain Shareef, Ahmad Asrul Ibrahim y Ammar Hussein Mutlag en 2015 (Shareef *et al.*, 2020). Desde un punto de vista matemático, los proyectiles sugieren soluciones aleatorias, y la solución se refiere a la punta de la energía del líder actual. De acuerdo con la revisión de la literatura, no se ha implementado como técnica de ubicación de fallas para sistemas eléctricos de potencia. El LSA se presenta en el diagrama de flujo de la figura 26.


2.3.5. Algoritmo de búsqueda gravitacional binaria (BGSA)

La ley de gravitación universal describe la interacción gravitatoria entre diferentes cuerpos que poseen masa. El algoritmo de búsqueda gravitacional (GSA) se basa en la ley de gravitación universal; en la versión binaria del GSA (BGSA), el resultado de estas fuerzas se convierte en un valor de probabilidad para cada elemento del vector binario. El BGSA obedece a la ley de la gravedad y la ley del movimiento (Hashemi *et al.*, 2021).

- Ley de la gravedad: cada masa atrae a las demás masas mediante una fuerza gravitacional, donde esta fuerza entre dos partículas es directamente proporcional al producto de sus masas e inversamente proporcional al cuadrado de la distancia que las separa.
- Ley del movimiento: la velocidad actual de cualquier masa es igual a la suma de una fracción de su velocidad previa y la variación de la velocidad (primera ley de Newton). La variación en la velocidad o aceleración de una masa es igual a la fuerza que actúa sobre el sistema dividido por su masa inercial (segunda ley de Newton).

El BGSA fue propuesto por Esmat Rashedi, Hossein Nezamabadi-pour y Saeid Saryazdi en 2009 (Rashedi *et al.*, 2010). De acuerdo con la ley de gravitación universal, las masas se atraen entre sí, generando un movimiento hacia las masas más pesadas; la población son las masas, cada masa presenta una solución y las masas pesadas corresponden a las mejores soluciones.


Figura 26. Diagrama de flujo del algoritmo de búsqueda de relámpago (LSA)



Fuente: elaboración propia.

A pesar de su potencial, según la revisión de la literatura, no se ha implementado ampliamente como técnica de ubicación de fallas para sistemas eléctricos de potencia. El BGSA se presenta en el diagrama de flujo de la figura 27.

Figura 27. Diagrama de flujo del algoritmo de búsqueda gravitacional binaria (BGSA)



Fuente: elaboración propia.

2.4. Etapa 4: métricas

Como métrica de desempeño, se utilizó la precisión para identificar el segmento de línea en falla y parámetros propios de las técnicas de optimización inteligente: número de iteraciones, tiempo de simulación, mejor puntuación (mínimo de la función *fitness*) y *fitness* promedio.

Es importante resaltar que el tiempo de simulación es una métrica de desempeño subjetiva, pues depende de la metodología implementada para la programación del algoritmo y del equipo utilizado para la simulación. En esta investigación se analizaron las debilidades actuales del análisis comparativo entre metaheurísticas (Aranha *et al.*, 2022; Gao *et al.*, 2019; García-Martínez *et al.*, 2017), y, con el objetivo de obtener una comparación justa, se utilizó el mismo equipo y se ajustaron de forma similar los recursos y procesos del sistema operativo para cada simulación.

Se tabuló la información para el número de iteraciones, la precisión para identificar el segmento de línea y el tiempo de simulación. La tabla 10 presenta un ejemplo de las métricas tabuladas: en la primera columna se presenta el segmento en falla; en la segunda columna se describen los estados de los interruptores de segmentos medidos, almacenados y transmitidos por las FTU, y en la tercera columna se encuentra el total de iteraciones obtenido de acuerdo con el criterio de convergencia ajustado en las técnicas de optimización inteligente, criterio que se ajustó de igual forma para las cuatro estrategias; en la cuarta columna se encuentra la precisión obtenida para identificar el segmento de línea en falla, precisión que se ajusta porcentualmente: por ejemplo, si el criterio de convergencia se cumple para un sistema de diez FTU y como resultado se obtiene que $[I_k^*] = [I_k]$, entonces la precisión es del 100%; si el criterio de convergencia se cumple para un sistema de diez FTU y como resultado solo se obtienen cinco segmentos iguales (mismo valor, misma posición), la precisión es del 50%; si el criterio de convergencia se cumple para un sistema de diez FTU y como resultado solo se obtienen ocho segmentos iguales (mismo valor, misma posición), la precisión es del 80%; si el criterio de convergencia se cumple para un sistema de diez FTU y como resultado solo se obtienen dos segmentos iguales (mismo valor, misma posición), la precisión es del 20%. En la quinta columna se encuentra el tiempo de simulación.

Tabla 10. Métricas de desempeño: iteraciones, precisión y tiempo de simulación

Segmento de falla	I_k medido por las FTU	Algoritmo metaheurístico		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X_k	[1 1 1 1 0 0 1 1 0 0]	3000	50	2,4
X_k	[1 0 1 1 0 0 0 0 0 0]	3000	50	1,2
X_k, X_k	[1 1 0 0 0 0 0 0 0 0]	3000	0	0,9


Fuente: elaboración propia.

Desde el punto de vista poblacional, la función *fitness* determina la habilidad de un individuo para competir con otros miembros de la población. La probabilidad de que un individuo sea seleccionado está directamente relacionada con el valor obtenido en la función *fitness*. Según la función del interruptor, en el contexto de esta investigación, la función *fitness* indica el grado de proximidad entre el estado esperado del interruptor de segmento y el estado del interruptor de segmento. La función *fitness* es la función objetivo que se busca minimizar en el proceso de encontrar el conjunto de estados de segmentos de línea. Se define como un problema de minimización porque, cuando el valor obtenido de la función *fitness* sea el más pequeño (min), I_k^* es cercano a I_k .

En cada iteración, de acuerdo con la estrategia implementada, las características de cada individuo se evalúan en la función *fitness*. Esto implica que para una población de n individuos se requieren n evaluaciones en la función *fitness* por iteración. Como parte de la estrategia de análisis de resultados, se registran dos datos asociados con estas n evaluaciones. El primero corresponde al menor resultado obtenido entre las n evaluaciones, definido como la mejor puntuación por iteración. El segundo corresponde al promedio de todos los resultados obtenidos de las n evaluaciones, definido como el *fitness* promedio por iteración.

En los modelos de optimización metaheurística basados en comportamientos poblacionales, se anticipa que, al converger la estrategia implementada hacia la solución, el *fitness* promedio tienda a la mejor puntuación. Para presentar las métricas de mejor puntuación y *fitness* promedio, se utilizan gráficas en términos del número de iteraciones. La figura 28 presenta un ejemplo de las figuras obtenidas.

Figura 28. Métricas de desempeño: mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones



Fuente: elaboración propia.

3. *Software* de simulación

Este capítulo presenta la aplicación App LF-UD, denominada así por Application for Fault Location-Universidad Distrital. El objetivo de App LF-UD es proporcionar un entorno de simulación que permita analizar el rendimiento de diferentes algoritmos de ubicación de fallas de baja impedancia en líneas de distribución con y sin GD, incluyendo aquellas estandarizadas y las propuestas por la comunidad académica de manera continua.

La interfaz gráfica y los algoritmos de ubicación están desarrollados en App Designer, mientras que el análisis de flujo de carga y cortocircuito, así como la inclusión de la GD, se realizaron mediante el *software* de acceso abierto OpenDSS. App LF-UD utiliza como métrica de desempeño el error relativo, de acuerdo con los parámetros del estándar IEEE C37.114-2014 (IEEE, 2015). Este error se puede obtener para un punto específico o a través de una gráfica para un tramo completo de línea.

El simulador permite variar diversos parámetros, como el tipo de estrategia de ubicación de fallas, la línea o nodo en falla, el tipo de falla (trifásica, monofásica, bifásica, bifásica a tierra), la resistencia de falla, el tamaño en términos de potencia de cortocircuito de la GD, la ubicación de la GD, la longitud y los modelos de las líneas de distribución.

En su primera versión, App LF-UD incorpora dos estrategias de ubicación de fallas: el método de reactancia simple y el método de Takagi. Sin embargo, la aplicación se diseñó para permitir la inclusión sencilla de más estrategias de ubicación de fallas en el futuro. El trabajo futuro es incluir ondas viajeras, técnicas de optimización inteligente, esquemas de ubicación híbridas, entre otras. Como sistema de prueba, se utiliza la red IEEE de 13 nodos y la red IEEE de 34 nodos. Es importante destacar que la programación de

la aplicación se desarrolló para que sea sencillo implementar otros sistemas de prueba.

La simulación de eventos en sistemas de potencia es una metodología que posibilita la exploración de preguntas de investigación y la creación de prototipos a un costo y un tiempo considerablemente menores que los necesarios para experimentar con sistemas reales. Los simuladores ofrecen un entorno virtual que cuenta con una serie de características deseables, lo que permite la modelización de criterios particulares y el análisis de su rendimiento en diversos escenarios (Chaudhary *et al.*, 2012). En el área de análisis de sistemas de potencia, existen diversas herramientas de simulación, tanto comerciales como de acceso abierto.

Existen múltiples simuladores disponibles para el análisis de sistemas de potencia; sin embargo, en el área de ubicación de fallas, en la revisión de literatura realizada en Scopus y Web of Science no se identificó ningún trabajo asociado a desarrollo de *software*. En general, la investigación en esta área se centra en proponer nuevas estrategias de ubicación. A continuación, se describen tres trabajos y un estándar relacionados con el tema abordado en este documento.

El primer trabajo describe una herramienta de simulación que utiliza ondas viajeras. El segundo presenta una metodología de ubicación de fallas que implementa estrategias específicas para este propósito. El tercero es un artículo de revisión de tema sobre ubicación de fallas. Finalmente, el cuarto documento es un estándar de la IEEE.

En el área de aplicaciones, el trabajo de grado de pregrado de Bárcenas y Rueda (2021) desarrolla una herramienta computacional para la ubicación de fallas en líneas de transmisión; específicamente, la herramienta se centra en la teoría de las ondas viajeras y plantea la adaptación de un algoritmo para la detección de fallas; se utilizó Python como lenguaje de programación.

En el área de cosimulación, Yem *et al.* (2022) proponen un método que utiliza lógica difusa y redes neuronales para la detección, clasificación, caracterización y ubicación de fallas a partir de datos de sensores y medidores inteligentes instalados en la red inteligente. Por su parte, Giral-Ramírez (2022) presenta una revisión de las técnicas basadas en IA para la ubicación de fallas en redes de distribución con GD.

Es fundamental destacar como antecedente el estándar IEEE C37.114-2014 (IEEE, 2015), guía para determinar la ubicación de fallas en líneas de transmisión y distribución en corriente alterna. Este documento presenta la descripción de los enfoques tradicionales y las técnicas de medición utilizadas en los dispositivos modernos para la ubicación de fallas: métodos basados en impedancia de uno y dos terminales y el método de onda viajera.

App LF-UD fue desarrollada en la herramienta App Designer de Matlab. Está conformada por quince funciones: siete interfaces gráficas y cinco manuales de usuario. Las métricas utilizadas en App LF-UD se implementaron de acuerdo con los parámetros del estándar C37.114-2014. Sin embargo, en relación con los simuladores comerciales, se mejoró la metodología de presentación de las métricas.


La figura 29 presenta la metodología de operación de App LF-UD, que busca depurar errores y fue desarrollada implementando una arquitectura por módulos. La tabla 11 presenta una descripción general de cada uno de los módulos.

Tabla 11. Descripción de los módulos de App LF-UD

Módulo	Descripción
Menú principal	Módulo de presentación: permite acceder a los manuales de operación, la información de la aplicación, la información de los desarrolladores y la selección del sistema de prueba.
Sistema de potencia de prueba	Módulo para la parametrización de los modelos del sistema de prueba.
Generación distribuida	Módulo para la parametrización del tamaño y la ubicación del sistema de GD.
Ubicación de la falla	Módulo para la caracterización de la falla y la metodología de ubicación de falla por implementar.
Métricas	Módulo para la parametrización de la métrica de desempeño por implementar.

Fuente: elaboración propia.

Figura 29. Diagrama de bloques de la metodología de operación de App LF-UD



Fuente: elaboración propia.

En las siguientes secciones se describen en detalle cada uno de los módulos, sus variables de entrada, sus variables de salida y la respectiva metodología.


3.1. Menú principal

El “Menú principal” corresponde a la interfaz principal de la aplicación App LF-UD, donde se presenta al usuario toda la documentación de la aplicación y la información de los desarrolladores. En total, se desarrollaron cinco manuales de usuario: Manual de Usuario Menú Principal, Manual de Instalación App LF-UD, Manual de Instalación OpenDSS, Manual de Usuario IEEE 13 Nodos y Manual de Usuario IEEE 34 Nodos.

Adicionalmente, en este módulo el usuario debe seleccionar el sistema de prueba por analizar; en esta primera versión de la aplicación, se implementaron

dos sistemas de prueba: IEEE 13 Node Test Feeder e IEEE 34 Node Test Feeder. Esta selección se realizó debido a que son sistemas de distribución de permanente uso en el análisis de fallas. Sin embargo, es importante resaltar que la programación de la aplicación se desarrolló para que implementar otros sistemas de prueba sea sencillo. La figura 30 describe el diagrama de entrada y salida del módulo.

Figura 30. Variables de entrada y salida del módulo “Menú principal”



Fuente: elaboración propia.

La tabla 12 presenta la descripción de las variables de entrada que se pueden parametrizar del módulo. Cuenta con cuatro variables, de las cuales Test System es de ajuste obligatorio; las demás son de tipo informativo.

Tabla 12. Variables de entrada del módulo “Menú principal”

Variable	Descripción
App LF-UD. Manual de operación	Acceso al manual de instalación y operación de App LF-UD. Este manual presenta al usuario un paso a paso de cómo se debe utilizar la aplicación; el manual está dividido en cuatro partes: Manual de Usuario Menú Principal, Manual de Instalación, Manual de Usuario IEEE 13 Nodos y Manual de Usuario IEEE 34 Nodos. Es importante destacar que este tutorial se realiza para ordenadores con sistema operativo Microsoft Windows; sin embargo, la metodología para otros sistemas operativos es equivalente si se utiliza una máquina virtual.
OpenDSS. Manual de conexión	Acceso al manual de conexión de OpenDSS. Este manual presenta al usuario un paso a paso de cómo se debe descargar e instalar OpenDSS; es importante destacar que este tutorial se realiza para ordenadores con sistema operativo Microsoft Windows.

Variable	Descripción
Acerca de	Acceso a la información de nombre, versión y creadores de la aplicación.
Sistema de prueba	Selección del sistema de prueba: sistema IEEE de 13 nodos o sistema IEEE de 34 nodos.

Fuente: elaboración propia.

Como se ve en la figura 30, el módulo implementado tiene una sola variable de salida (tabla 13).

Tabla 13. Variable de salida del módulo “Menú principal”

Variable	Descripción
Sistema de prueba	Direccionamiento al sistema de prueba utilizado; es una variable de salida de solo selección, luego no realiza ningún tipo de ajuste.

Fuente: elaboración propia.

3.2. Sistema de potencia de prueba

El módulo “Sistema de potencia de prueba” permite parametrizar los modelos de los elementos del sistema de prueba. De acuerdo con el tipo de sistema seleccionado en el módulo “Menú principal”, el usuario tiene dos posibilidades: utilizar los modelos por defecto o parametrizar nuevos modelos según las características de ubicación de fallas por analizar. Los dos sistemas de prueba utilizados cuentan con una subestación, líneas de distribución y transformadores de distribución; el modelo de cada uno de los elementos es totalmente parametrizable.


Es importante destacar que la interfaz para el modelamiento de los elementos se diseñó teniendo en cuenta las características necesarias para realizar estudios de flujo de carga balanceado y cortocircuito.

En este módulo, además de poder modelar los elementos propios de cada uno de los sistemas de prueba, el usuario tiene la posibilidad de incluir un sistema de GD. Como el objetivo es analizar diferentes escenarios, la inclusión de la GD se caracteriza en ubicación y tamaño; es decir, el usuario puede ubicar el sistema de GD en cualquiera de los nodos del sistema y ajustar de forma

libre los parámetros de potencia e impedancia. En esta primera versión, la aplicación se limita a la inclusión de una sola GD y el modelo corresponde a parámetros de potencia e impedancia de cortocircuito.

Dado que cada uno de los modelos parametrizados modifica la conexión entre Matlab y OpenDSS, en este módulo se incluyó una interfaz de conexión; el objetivo es poder realizar, validar y depurar, según sea el caso, la conexión entre Matlab y OpenDSS. La figura 31 presenta el diagrama de entrada y salida del módulo.

Figura 31. Variables de entrada y salida del módulo “Sistema de potencia de prueba”



Fuente: elaboración propia.

La tabla 14 presenta la descripción de las variables de entrada que se pueden o no parametrizar del módulo. Cuenta con cinco variables, de las cuales OpenDSS and Matlab Connection es la única de ajuste obligatorio; las demás se pueden establecer por defecto o configurar de acuerdo con las características de ubicación de fallas por analizar.

Tabla 14. Variables de entrada del módulo “Sistema de potencia de prueba”

Variable	Descripción
Sistema de prueba	Parámetro definido en el módulo “Menú principal”; se utiliza para definir el sistema de prueba por utilizar: sistema IEEE de 13 nodos o sistema IEEE de 34 nodos.

Variable	Descripción
Conexión entre OpenDSS y Matlab	Realiza, valida y depura la conexión entre Matlab y OpenDSS; sirve para verificar que las dos herramientas de simulación están trabajando paralelamente. Si se llega a presentar algún error en la conexión, el manual de conexión OpenDSS incluye un apartado que explica cómo identificar y solucionar el problema.
Modelo de la subestación	Define el modelo de la subestación de alimentación de acuerdo con los criterios de flujo de carga y cortocircuito; la ubicación es un parámetro fijo y se estableció según la información establecida por el IEEE (2022).
Características de las líneas de distribución	Define el modelo de las líneas de distribución, específicamente impedancia en componentes de secuencia para líneas no transpuestas y longitud.
Características de la GD	Permite habilitar, ubicar y modelar el sistema de GD por incluir en el sistema de prueba.

Fuente: elaboración propia.

Como se identifica en la figura 31, el módulo implementado tiene una sola variable de salida (tabla 15).

Tabla 15. Variable de salida del módulo “Sistema de potencia de prueba”

Variable	Descripción
Modelo del sistema de potencia	Modelo final del sistema de prueba por analizar de acuerdo con los parámetros asignados a la subestación, las líneas de distribución, los transformadores de distribución y la GD.

Fuente: elaboración propia.

A continuación, se realiza una descripción de los sistemas de prueba utilizados y de la metodología de conexión entre Matlab y OpenDSS y la GD.

3.2.1. Sistema de prueba

Como sistemas de prueba se utilizan la red IEEE de 13 nodos y la red IEEE de 34 nodos. Cada uno de los elementos se puede parametrizar de acuerdo con el caso de estudio por analizar; en general, por criterio de diseño, para los dos sistemas de prueba, las líneas en componentes de secuencia tienen el mismo modelo y longitud —ecuación (7)—; sin embargo, como se describió antes, este parámetro se puede modificar. A continuación, se presentan de forma general los sistemas de prueba utilizados.

$$\begin{aligned} Z_{L_0} &= (0,2153 + j0,6325) \left[\frac{\Omega}{\text{km}} \right] \\ Z_{L_1} &= (0,2121 + j0,6430) \left[\frac{\Omega}{\text{km}} \right] \end{aligned} \quad \text{Length} = 0,61 [\text{km}] \quad (7)$$


3.2.1.1. Sistema de prueba IEEE de 13 nodos

El sistema de prueba de 13 nodos del IEEE (figura 32) se utiliza para realizar análisis en redes de distribución. Se caracteriza por ser corto y de sencilla implementación. Las configuraciones y los parámetros detallados del alimentador publicado se pueden descargar del sitio web del IEEE (2022) y de Schneider *et al.* (2018); para App LF-UD, se le realizaron modificaciones respecto a la estructura inicial, pues es específico: no hay compensación, no hay líneas subterráneas y todas las cargas son balanceadas.

3.2.1.2. Sistema de prueba IEEE de 34 nodos


El sistema de prueba de 34 nodos del IEEE (figura 33) representa un alimentador real en Arizona. Sus características topológicas y su amplia variedad de componentes son representativas de una red de distribución rural típica que podría incorporar GD. Las configuraciones y los parámetros detallados del alimentador publicado se pueden descargar del sitio web del IEEE (2022) y de Schneider *et al.* (2018); para App LF-UD, se le realizaron modificaciones respecto a la estructura inicial, pues es específico: no hay compensación y todas las cargas son balanceadas.

Figura 32. Sistema IEEE de 13 nodos



Fuente: elaboración propia a partir de IEEE (2022) y Schneider *et al.* (2018).

Figura 33. Sistema IEEE de 34 nodos



Fuente: elaboración propia a partir de IEEE (2022) y Schneider *et al.* (2018).

3.2.2. Conexión OpenDSS y Matlab

Como se muestra en la figura 34, la conexión entre OpenDSS y App Designer se basa en una estructura de capas. En la primera capa se encuentra el compilador de OpenDSS, encargado de realizar los cálculos de flujo de carga y cortocircuito. En la segunda capa se realiza la comunicación entre Matlab y OpenDSS. La tercera capa corresponde a la interfaz del usuario. Las capas primera y segunda son ocultas, lo que indica que no están disponibles directamente para el usuario; sin embargo, sus parámetros sí pueden ajustarse a través de la capa 3.

Como se identifica en la figura 34, se requieren cinco pasos para correr una simulación en App LF-UD. En el primer paso se ajustan las entradas de la capa 3; en este paso, el usuario define el modelo de cada uno de los elementos del sistema de prueba y establece las características del evento de falla por analizar. El segundo paso se realiza en la capa 2; en este paso, Matlab se conecta, verifica y depura la conexión con OpenDSS, y posteriormente envía los datos de la capa 1 a la capa 3.


El tercer paso se realiza en la capa 3; en este paso, OpenDSS toma los datos entregados por la capa 2, actualiza los modelos del sistema de prueba, actualiza los parámetros de falla del evento por analizar y ejecuta el estudio de flujo de carga y cortocircuito. El cuarto paso es similar al paso 2: teniendo

en cuenta que la conexión ya fue verificada y depurada, en este paso solamente se realiza el envío de información de la capa 3 a la capa 1. El quinto y último paso se realiza en la capa 1; en este paso se toma la información enviada por la capa 3, se realiza un procesamiento de la información y se visualiza en la interfaz.

El procesamiento de la información que se realiza en la quinta etapa sobre la capa 3 es una característica fundamental para App LF-UD; el procesamiento consiste en filtrar, implementar y caracterizar. Teniendo en cuenta que OpenDSS genera múltiples datos de un evento, el proceso de filtrado es el encargado de tomar estos datos y, de acuerdo con los requerimientos del algoritmo de ubicación de fallas por implementar, extraer la información que se requiera.

En la fase de implementación se toman los datos filtrados y se ejecuta el algoritmo de ubicación de fallas. Las métricas utilizadas en App LF-UD se implementaron de acuerdo con los parámetros del estándar C37.114-2014. Sin embargo, a diferencia de los simuladores comerciales, se mejoró la metodología de presentación de las métricas. La fase de caracterización en el procesamiento de la información tiene como objetivo generar estas métricas de manera efectiva y comprensible.

Figura 34. Estructura por capas de la conexión OpenDSS-App Designer




Fuente: elaboración propia.

3.3. Generación distribuida

La figura 35 presenta el diagrama de entrada y salida del módulo. La GD se puede habilitar y deshabilitar fácilmente, y la inclusión se caracteriza en ubicación y tamaño. El usuario puede ubicar el sistema de GD en cualquiera de los nodos del sistema y ajustar de forma libre los parámetros de potencia e impedancia; en esta primera versión, la aplicación se limita a la inclusión de una sola GD y su modelo está en función de sus características de cortocircuito.

Figura 35. Variables de entrada y salida del módulo “Generación distribuida”



Fuente: elaboración propia.

La tabla 16 presenta la descripción de las variables de entrada que se pueden parametrizar del módulo. Cuenta con seis variables de ajuste obligatorio.

Tabla 16. Variables de entrada del módulo “Generación distribuida”

Variable	Descripción
Enable/Disable	Habilita y deshabilita el sistema de GD.
Ubicación de la generación distribuida	Define el nodo donde se va a instalar la GD.
Scc (3φ, 1φ)	Define la potencia de cortocircuito trifásica y monofásica de la GD.
$X_1/R_1, X_0/R_0$	Define la relación X/R para la secuencia positiva y la secuencia cero de la GD.

Fuente: elaboración propia.

Como se identifica en la figura 35, el módulo implementado tiene dos variables de salida (tabla 17).


Tabla 17. Variables de salida del módulo “Generación distribuida”

Variable	Descripción
Tamaño de la generación distribuida	Establece las características de cortocircuito de la GD.
Ubicación de la generación distribuida	Establece el nodo donde se va a instalar la GD.

Fuente: elaboración propia.

3.4. Ubicación de la falla

La figura 36 presenta el diagrama de entrada y salida del módulo. El simulador permite variar la línea en falla, el tipo de falla (trifásica, monofásica, bifásica, bifásica a tierra), la resistencia de falla, el tipo de estrategia de ubicación de fallas y el nodo de medición. App LF-UD incorpora dos estrategias de ubicación de fallas: el método de reactancia simple y el método de Takagi; sin embargo, la aplicación se diseñó para incluir de forma sencilla más estrategias de ubicación de fallas.

Figura 36. Variables de entrada y salida del módulo “Ubicación de la falla”

Fuente: elaboración propia.

La tabla 18 presenta la descripción de las variables de entrada que se pueden parametrizar del módulo. Cuenta con seis variables de ajuste obligatorio.

Tabla 18. Variables de entrada del módulo “Ubicación de la falla”

Variable	Descripción
Modelo del sistema de potencia	Define el sistema de prueba por utilizar: sistema IEEE de 13 nodos o sistema IEEE de 34 nodos.
Línea en falla	Define la línea en falla del evento por analizar.
Tipo de falla	Define el tipo de falla (3ϕ , 2ϕ , $2\phi_G$, 1ϕ) del evento por analizar.
Resistencia de falla	Define la resistencia de falla del evento por analizar.
Método de ubicación de falla	Define el método de ubicación de falla de baja impedancia por utilizar.
Nodo de medición	Define el nodo donde se va a realizar la medición del evento por analizar.

Fuente: elaboración propia.

Como se identifica en la figura 36, el módulo implementado tiene cuatro variables de salida (tabla 19).


Tabla 19. Variables de salida del módulo “Ubicación de la falla”

Variable	Descripción
Estudio de flujo de carga	Variables del flujo de carga obtenidas de la simulación.
Estudio de cortocircuito	Variables del cortocircuito obtenidas de la simulación.
Identificación de la falla	Identificación del tipo de falla de acuerdo con el método de ubicación de falla de baja impedancia seleccionado.
Ubicación de la falla	Ubicación de la falla de acuerdo con el método de ubicación de falla de baja impedancia seleccionado.

Fuente: elaboración propia.

3.5. Métricas

La figura 37 presenta el diagrama de entrada y salida del módulo. App LF-UD utiliza como métrica de desempeño el error relativo, de acuerdo con los parámetros del estándar C37.114-2014. Según los ajustes del usuario, el error se puede obtener para un punto específico o a través de una gráfica para un tramo completo de línea. En general, para determinar el error relativo, el valor teórico (km) es la distancia elegida por el usuario para generar la falla, y el valor simulado (km) es el obtenido por el método de ubicación de fallas seleccionado.

Figura 37. Variables de entrada y salida del módulo “Métricas”

Fuente: elaboración propia.

La tabla 20 presenta la descripción de las variables de entrada que se pueden parametrizar del módulo. Cuenta con cuatro variables de ajuste obligatorio.

Tabla 20. Variables de entrada del módulo “Métricas”

Variable	Descripción
Estudio de flujo de carga	Variables del flujo de carga obtenidas de la simulación.
Estudio de cortocircuito	Variables del cortocircuito obtenidas de la simulación.
Ubicación de la falla	Ubicación de la falla de acuerdo con el método de ubicación de falla de baja impedancia seleccionado.

Fuente: elaboración propia.

Como se identifica en la figura 37, el módulo implementado tiene cuatro variables de salida (tabla 21).

Tabla 21. Variables de salida del módulo “Métricas”

Variable	Descripción
Distancia de falla	Error relativo (%) obtenido en el punto de la falla.
Distancia vs. corriente	Figura de distancia vs. magnitud de la corriente de fase.
Error vs. corriente	Figura del error relativo vs. la magnitud de la corriente de fase.
Error vs. distancia	Figura del error relativo vs. la distancia.

Fuente: elaboración propia.

3.6. Diagramas de flujo del *software* de simulación

En la figura 38 se presenta el diagrama de flujo completo para la operación de App LF-UD. Como se describió, en la primera versión de App LF-UD se incorporaron dos estrategias de ubicación de fallas: el método de reactancia simple y el método de Takagi; sin embargo, la aplicación se diseñó para incluir de forma sencilla más estrategias de ubicación de fallas. A continuación, se presentan los diagramas de flujo de las dos metodologías utilizadas y la interfaz final de App LF-UD. Un ejemplo de las métricas obtenidas, para un caso de estudio, se presenta en la sección 4.1. Impacto de la GD en los modelos convencionales.


3.6.1. Método de reactancia simple

El algoritmo de reactancia simple se basa en la evaluación de la parte imaginaria de la impedancia obtenida en condiciones de cortocircuito. La impedancia de falla se determina aplicando un divisor de tensión y de corriente. En la figura 39 se presenta el diagrama de flujo del método de reactancia simple implementado en App LF-UD.

3.6.2. Método de Takagi

El método de Takagi mejora el rendimiento del método de reactancia simple, restando la corriente de carga de la corriente total de falla. Usando el principio de superposición, la red, durante una falla, se descompone en una red previa a la falla y una red durante la falla. En la figura 40 se presenta el diagrama de flujo del método de Takagi implementado en App LF-UD. Este método tiene su forma mejorada, donde se considera el ángulo y se agrega la corriente de secuencia cero; el objetivo es incluir, en el proceso de ubicación, la no homogeneidad de las impedancias de la línea.

Figura 38. Diagrama de flujo de operación de App LF-UD



Fuente: elaboración propia.

Figura 39. Diagrama de flujo del método de reactancia simple





Figura 40. Diagrama de flujo del método de Takagi


Fuente: elaboración propia.

3.7. Interfaz de App LF-UD

En las figuras 41-43 se presentan tres de las siete interfaces gráficas de App LF-UD. La figura 41 presenta la ventana de parametrización del sistema IEEE de 13 nodos (la ventana del sistema IEEE de 34 nodos es similar). La

figura 42 presenta la ventana para la parametrización de la falla y la metodología de ubicación de falla. La figura 43 presenta la ventana de parametrización del sistema de GD.

Figura 41. Interfaz de App LF-UD: parametrización del sistema de prueba




Fuente: elaboración propia.

Figura 42. Interfaz de App LF-UD: parametrización de la metodología de ubicación de fallas

Fuente: elaboración propia.

Figura 43. Interfaz de App LF-UD: inclusión de GD



Fuente: elaboración propia.

4. Evaluación del modelo inteligente


Este capítulo presenta la evaluación del modelo inteligente propuesto para la ubicación de fallas.

4.1. Impacto de la GD en los modelos convencionales

En esta sección se presenta un breve resultado del impacto de la inclusión de GD en los métodos convencionales de impedancia. El análisis del impacto no es un objetivo de este trabajo, pues existen diversas investigaciones en esta área. Sin embargo, para evaluar el funcionamiento del simulador App LF-UD, se plantea un escenario aleatorio para un evento de falla con y sin GD.


Las figuras 44 y 45 presentan dos de las métricas de App LF-UD. La figura 44 presenta el error en función de la distancia de la falla, y la figura 45 presenta el error en función de la magnitud de la corriente. De acuerdo con los resultados obtenidos, se evidencia cómo aumenta el error cuando se incluye GD; el impacto de esta inclusión tiene diversas propuestas de solución, dependiendo del sistema de medida, de la dirección de la corriente de falla y de la técnica de ubicación.

Figura 44. Métrica de App LF-UD: error relativo vs. distancia simulada



Fuente: elaboración propia.

Figura 45. Métrica de App LF-UD: error relativo vs. magnitud de corriente



Fuente: elaboración propia.


4.2. Ubicación de fallas en un único segmento

En esta sección se presentan las métricas para las cuatro técnicas de optimización inteligente implementadas en eventos con un único segmento de falla, o no simultáneos. La información se tabula para el número de iteraciones, la precisión en la identificación del segmento de línea y el tiempo de simulación; para la mejor puntuación (mínimo de la función *fitness*) y para el *fitness* promedio, se utilizan gráficas en términos del número de iteraciones. Con el objetivo de obtener una comparación justa, se empleó el mismo

equipo y se ajustaron de forma similar los recursos y procesos del sistema operativo para cada simulación.

Las cuatro técnicas de optimización inteligente se implementaron en el sistema de la figura 46. Este sistema se tomó por sus características de suministro múltiple y por las variadas particularidades que se pueden incluir (Huang *et al.*, 2020). En la sección 2.1 se describe de forma detallada el sistema de la figura 46. A continuación, se presentan las métricas obtenidas.

Figura 46. Sistema de prueba para la evaluación de las cuatro técnicas de optimización inteligente



Fuente: elaboración propia a partir de Huang *et al.* (2020).

4.2.1. Algoritmo de optimización de cebra (ZOA)

La tabla 22 presenta el número de iteraciones, la precisión para identificar el segmento de línea y el tiempo de simulación para ZOA. Teniendo en cuenta que el evento es una falla en un único segmento, se analizaron las diez fallas.


Tabla 22. Métricas tabuladas para ZOA: iteraciones, precisión y tiempo de simulación (fallas no simultáneas)


Segmento de falla	I_k medido por las FTU	ZOA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X1	[1 -1 -1 -1 0 0 1 1 0 0]	2	100	0,00728
X2	[1 1 -1 -1 0 0 1 1 0 0]	2	100	0,00351
X3	[1 1 1 -1 0 0 1 1 0 0]	3	100	0,00385
X4	[1 1 1 1 0 0 1 1 0 0]	2	100	0,00262
X5	[1 1 -1 -1 0 0 1 1 0 0]	4	100	0,00530
X6	[1 1 1 -1 0 1 1 1 0 0]	2	100	0,00293
X7	[1 1 1 1 0 0 1 0 0 0]	1	100	0,00236
X8	[1 1 1 1 0 0 1 1 0 0]	2	100	0,00317
X9	[1 1 1 1 0 0 1 1 1 0]	3	100	0,00381
X10	[1 1 1 1 0 0 1 1 1 1]	2	100	0,00266

Fuente: elaboración propia.

Las figuras 47-49 presentan la mejor puntuación y el *fitness* promedio por iteración para fallas no simultáneas en los segmentos X1, X2, X3, X4, X5, X6, X8, X9, X10. No se incluye la gráfica para la falla en el segmento X7, como se identifica en la tabla 22, pues para este evento solo se necesitó de una iteración.


Figura 47. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X1, X2 y X3, no simultáneas, utilizando ZOA






Fuente: elaboración propia.


Figura 48. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X4, X5 y X6, no simultáneas, utilizando ZOA






Fuente: elaboración propia.

Figura 49. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X8, X9 y X10, no simultáneas, utilizando ZOA





Fuente: elaboración propia.

4.2.2. Algoritmo de búsqueda de cuco (CSA)

La tabla 23 presenta el número de iteraciones, la precisión para identificar el segmento de línea y el tiempo de simulación para CSA. Teniendo en cuenta que el evento es una falla en un único segmento, se analizaron las diez fallas.

Tabla 23. Métricas tabuladas para CSA: iteraciones, precisión y tiempo de simulación (fallas no simultáneas)


Segmento de falla	I_k medido por las FTU	CSA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X1	[1 -1 -1 -1 0 0 1 1 0 0]	2565	100	2,25464
X2	[1 1 -1 -1 0 0 1 1 0 0]	1082	100	0,91817
X3	[1 1 1 -1 0 0 1 1 0 0]	1018	100	0,85788


Segmento de falla	I_k medido por las FTU	CSA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X4	[1 1 1 1 0 0 1 1 0 0]	3000	0	2,54828
X5	[1 1 -1 -1 0 0 1 1 0 0]	1944	100	1,61124
X6	[1 1 1 -1 0 1 1 1 0 0]	1529	100	1,37849
X7	[1 1 1 1 0 0 1 0 0 0]	993	100	0,83297
X8	[1 1 1 1 0 0 1 1 0 0]	1942	100	1,65583
X9	[1 1 1 1 0 0 1 1 1 0]	2835	100	2,35343
X10	[1 1 1 1 0 0 1 1 1 1]	2139	100	1,81562

Fuente: elaboración propia.

Las figuras 50-53 presentan los mínimos de la función *fitness* y los mínimos promedio de la función *fitness* para fallas no simultáneas en los segmentos X1, X2, X3, X4, X5, X6, X7, X8, X9 y X10.


Figura 50. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X1, X2 y X3, no simultáneas, utilizando CSA






Fuente: elaboración propia.


Figura 51. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X4, X5 y X6, no simultáneas, utilizando CSA







Fuente: elaboración propia.


Figura 52. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X7, X8 y X9, no simultáneas, utilizando CSA





Fuente: elaboración propia.

Figura 53. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en el segmento X10, no simultáneas, utilizando CSA



Fuente: elaboración propia.

4.2.3. Algoritmo de búsqueda de relámpago (LSA)

La tabla 24 presenta el número de iteraciones, la precisión para identificar el segmento de línea y el tiempo de simulación para LSA. Teniendo en cuenta que el evento es una falla en un único segmento, se analizaron las diez fallas.


Tabla 24. Métricas tabuladas para LSA: iteraciones, precisión y tiempo de simulación (fallas no simultáneas)

Segmento de falla	I_k medido por las FTU	LSA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X1	[1 -1 -1 -1 0 0 1 1 0 0]	15	100	0,49805
X2	[1 1 -1 -1 0 0 1 1 0 0]	13	100	0,09696
X3	[1 1 1 -1 0 0 1 1 0 0]	15	100	0,11783
X4	[1 1 1 1 0 0 1 1 0 0]	13	100	0,07952
X5	[1 1 -1 -1 0 0 1 1 0 0]	12	100	0,09417
X6	[1 1 1 -1 0 1 1 1 0 0]	19	100	0,12239
X7	[1 1 1 1 0 0 1 0 0 0]	10	100	0,06264
X8	[1 1 1 1 0 0 1 1 0 0]	11	100	0,07081
X9	[1 1 1 1 0 0 1 1 1 0]	16	100	0,10000
X10	[1 1 1 1 0 0 1 1 1 1]	13	100	0,07640

Fuente: elaboración propia.


Las figuras 54-57 presentan los mínimos de la función *fitness* y los mínimos promedio de la función *fitness* para fallas no simultáneas en los segmentos X1, X2, X3, X4, X5, X6, X7, X8, X9 y X10.

Figura 54. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X1, X2 y X3, no simultáneas, utilizando LSA




Fuente: elaboración propia.

Figura 55. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X4, X5 y X6, no simultáneas, utilizando LSA




Fuente: elaboración propia.

Figura 56. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X7, X8 y X9, no simultáneas, utilizando LSA



Fuente: elaboración propia.

Figura 57. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en el segmento X10, no simultáneas, utilizando LSA



Fuente: elaboración propia.

4.2.4. Algoritmo de búsqueda gravitacional binaria (BGSA)

La tabla 25 presenta el número de iteraciones, la precisión para identificar el segmento de línea y el tiempo de simulación para BGSA. Teniendo en cuenta que el evento es una falla en un único segmento, se analizaron las diez fallas.

Tabla 25. Métricas tabuladas para BGSA: iteraciones, precisión y tiempo de simulación (fallas no simultáneas)


Segmento de falla	I_k medido por las FTU	BGSA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X1	[1 -1 -1 -1 0 0 1 1 0 0]	20	100	0,03708
X2	[1 1 -1 -1 0 0 1 1 0 0]	22	100	0,03451
X3	[1 1 1 -1 0 0 1 1 0 0]	21	100	0,03029
X4	[1 1 1 1 0 0 1 1 0 0]	28	100	0,05244
X5	[1 1 -1 -1 0 0 1 1 0 0]	17	100	0,02423
X6	[1 1 1 -1 0 1 1 1 0 0]	30	100	0,04493
X7	[1 1 1 1 0 0 1 0 0 0]	24	100	0,03830
X8	[1 1 1 1 0 0 1 1 0 0]	17	100	0,02689


Segmento de falla	I_k medido por las FTU	BGSA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X9	[1 1 1 1 0 0 1 1 1 0]	20	100	0,02982
X10	[1 1 1 1 0 0 1 1 1 1]	23	100	0,04211

Fuente: elaboración propia.

Las figuras 58-61 presentan los mínimos de la función *fitness* y los mínimos promedio de la función *fitness* para fallas no simultáneas en los segmentos X1, X2, X3, X4, X5, X6, X7, X8, X9 y X10.


Figura 58. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X1, X2 y X3, no simultáneas, utilizando BGSA






Fuente: elaboración propia.



Figura 59. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X4, X5 y X6, no simultáneas, utilizando BGSA






Fuente: elaboración propia.


Figura 60. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en los segmentos X7, X8 y X9, no simultáneas, utilizando BGSA





Fuente: elaboración propia.

Figura 61. Mejor puntuación vs. iteraciones y *fitness* promedio vs. iteraciones por falla en el segmento X10, no simultáneas, utilizando BGSA



Fuente: elaboración propia.

4.3. Ubicación de fallas en múltiples segmentos

En esta sección se presentan las métricas para las cuatro técnicas de optimización inteligente implementadas en eventos con múltiples segmentos de falla, o simultáneos. Este análisis se incluye porque, generalmente, las técnicas propuestas para la ubicación de fallas solo abordan eventos no simultáneos. La información se tabula para el número de iteraciones, la precisión en la identificación del segmento de línea y el tiempo de simulación.

Para los eventos simultáneos no se incluyeron las gráficas de los mínimos de la función *fitness* y los mínimos promedio de la función *fitness*, ya que son muy

similares a las gráficas de los eventos no simultáneos. Con el objetivo de obtener una comparación justa, se empleó el mismo equipo y se ajustaron de forma similar los recursos y procesos del sistema operativo para cada simulación.

Se estudian los mismos eventos múltiples para ZOA, CSA, LSA y BGSA. En el primer evento, se analizan tres fallas simultáneas: los segmentos en falla corresponden a las bifurcaciones del sistema de prueba (X5, X6 y X10). El resto de los eventos analizan dos fallas simultáneas: los segmentos en falla corresponden a falla en un segmento de línea de paso aguas arriba del interruptor KL y bifurcación aguas abajo del interruptor KL (X2 y X9); falla en un segmento de línea de paso aguas abajo del interruptor KL y bifurcación aguas arriba del interruptor KL (X6 y X7); falla en dos segmentos de línea de paso, aguas arriba y aguas abajo, del interruptor KL (X2 y X8); falla en un segmento de línea de paso aguas arriba del interruptor KL y bifurcación aguas arriba del interruptor KL (X1 y X6). A continuación, se describen los resultados obtenidos.

4.3.1. Algoritmo de optimización de cebra (ZOA)

La tabla 26 presenta el número de iteraciones, la precisión para identificar el segmento de línea y el tiempo de simulación para ZOA, de acuerdo con las características de los eventos múltiples.

Tabla 26. Métricas tabuladas para ZOA: iteraciones, precisión y tiempo de simulación (fallas simultáneas)

Segmentos de falla	I_k medido por las FTU	ZOA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X5, X6, X10	[1 1 0 0 1 1 1 1 1 1]	2	100	0,00688
X2, X9	[1 1 -1 -1 0 0 1 1 1 0]	2	100	0,00387
X6, X7	[1 1 1 1 0 1 1 0 0 0]	2	100	0,00543
X2, X8	[1 1 0 0 0 0 1 1 0 0]	2	100	0,00333
X1, X6	[1 -1 -1 -1 0 0 1 1 0 0]	5	100	1,14020

Fuente: elaboración propia.

4.3.2. Algoritmo de búsqueda de cuco (CSA)

La tabla 27 presenta el número de iteraciones, la precisión para identificar el segmento de línea y el tiempo de simulación para CSA, de acuerdo con las características de los eventos múltiples.

Tabla 27. Métricas tabuladas para CSA: iteraciones, precisión y tiempo de simulación (fallas simultáneas)

Segmentos de falla	I_k medido por las FTU	CSA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X5, X6, X10	[1 1 0 0 1 1 1 1 1 1]	2042	100	2,53652
X2, X9	[1 1 -1 -1 0 0 1 1 1 0]	811	100	0,77924
X6, X7	[1 1 1 1 0 1 1 0 0 0]	1056	100	1,00563
X2, X8	[1 1 0 0 0 0 1 1 0 0]	1756	100	1,65990
X1, X6	[1 -1 -1 -1 0 0 1 1 0 0]	419	100	0,38352

Fuente: elaboración propia.

4.3.3. Algoritmo de búsqueda de relámpago (LSA)

La tabla 28 presenta el número de iteraciones, la precisión para identificar el segmento de línea y el tiempo de simulación para LSA, de acuerdo con las características de los eventos múltiples.

Tabla 28. Métricas tabuladas para LSA: iteraciones, precisión y tiempo de simulación (fallas simultáneas)

Segmentos de falla	I_k medido por las FTU	LSA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X5, X6, X10	[1 1 0 0 1 1 1 1 1 1]	29	100	0,20371
X2, X9	[1 1 -1 -1 0 0 1 1 1 0]	12	100	0,07941
X6, X7	[1 1 1 1 0 1 1 0 0 0]	19	100	0,15758
X2, X8	[1 1 0 0 0 0 1 1 0 0]	14	100	0,09860
X1, X6	[1 -1 -1 -1 0 0 1 1 0 0]	13	100	0,12128

Fuente: elaboración propia.

4.3.4. Algoritmo de búsqueda gravitacional binaria (BGSA)

La tabla 29 presenta el número de iteraciones, la precisión para identificar el segmento de línea y el tiempo de simulación para BGSA, de acuerdo con las características de los eventos múltiples.

Tabla 29. Métricas tabuladas para BGSA: iteraciones, precisión y tiempo de simulación (fallas simultáneas)

Segmentos de falla	I_k medido por las FTU	BGSA		
		Iteraciones	Precisión (%)	Tiempo de simulación (s)
X5, X6, X10	[1 1 0 0 1 1 1 1 1 1]	21	100	0,19912
X2, X9	[1 1 -1 -1 0 0 1 1 1 0]	20	100	0,27065
X6, X7	[1 1 1 1 0 1 1 0 0 0]	25	100	0,10534
X2, X8	[1 1 0 0 0 0 1 1 0 0]	21	100	0,04968
X1, X6	[1 -1 -1 -1 0 0 1 1 0 0]	21	100	0,11225

Fuente: elaboración propia.

4.4. Discusión

La evaluación del modelo propuesto para la ubicación de fallas a través de las cuatro técnicas de optimización inteligente para eventos no simultáneos y simultáneos se realizó a través de cinco métricas de evaluación:

1. Precisión para identificar el segmento de línea (%)
2. Número de iteraciones
3. Tiempo de simulación (s)
4. Mínimos de la función *fitness* vs. número de iteraciones
5. Mínimos promedio de la función *fitness* vs. número de iteraciones

4.4.1. Precisión

Este valor calcula términos porcentuales y, posterior al criterio de convergencia, establece la cantidad de segmentos iguales (mismo valor, misma posición), siendo el 100 % el escenario en el que $[I_k^*] = [I_k]$. Es decir, una precisión del

100 % indica que el segmento en falla se ubicó perfectamente; una precisión del 0 % indica que el segmento en falla no se ubicó correctamente. Las tablas 22-25 presentan la precisión para los eventos no simultáneos, mientras que las tablas 26-29 presentan la precisión para los eventos simultáneos.

De acuerdo con los resultados obtenidos, se identifica que las cuatro técnicas de optimización inteligente implementadas presentan una precisión del 100 % para todos los eventos analizados (fallas simultáneas y fallas no simultáneas). Es importante mencionar que, para CSA, el evento no simultáneo X4 obtuvo una precisión del 0 %. Este valor se soluciona ajustando las características de la población inicial. Por lo tanto, se puede afirmar que, para el sistema de potencia implementado, las cuatro técnicas de optimización inteligente utilizadas son buenas alternativas para ubicar fallas de baja impedancia en líneas de distribución, tanto con GD como sin ella.

Es importante destacar que para generalizar la afirmación anterior se requiere llevar a cabo múltiples pruebas en diversos sistemas de potencia. Aunque las cuatro estrategias de optimización inteligente muestran buenos resultados en el mismo sistema, es necesario analizar diferentes escenarios y casos de estudio para llegar a una conclusión generalizada.

4.4.2. Número de iteraciones y tiempo de simulación


De acuerdo con el análisis de la métrica de precisión, las cuatro técnicas de optimización inteligente utilizadas son excelentes alternativas por ubicar de forma precisa los segmentos en falla. Sin embargo, cuando se analiza este tipo de estrategias, es fundamental evaluar características que permitan establecer la carga computacional. Es decir, tener la estrategia más precisa, pero con una mayor carga computacional, no es eficaz. El objetivo es proponer soluciones que además reduzcan los altos requerimientos de *hardware* y *software*.

Se han realizado múltiples investigaciones para analizar la carga computacional; esta investigación utilizó dos de las más comunes: el número de iteraciones y el tiempo de simulación. Las tablas 22-25 presentan el número de iteraciones y el tiempo de simulación en segundos para los eventos no simultáneos, mientras que las tablas 26-29 presentan el número de iteraciones y el tiempo de simulación en segundos para los eventos simultáneos. A diferencia de la

métrica de precisión, para el número de iteraciones y el tiempo de simulación sí se identificaron diferencias significativas.

En la figura 62 se presenta, mediante un diagrama de barras, para ZOA, CSA, LSA y BGSA, el comportamiento del número de iteraciones en segmentos de fallas no simultáneas. Cada técnica se analizó en función del valor mínimo, máximo y promedio de iteraciones; para el promedio, se tomó la parte entera del promedio. Como se observa en la figura 62, ZOA fue la estrategia con el menor número de iteraciones, seguida por LSA, BGSA y CSA, que fue la estrategia que requirió el mayor número de iteraciones para encontrar la solución. ZOA presentó una característica adicional: fue capaz de encontrar la solución para un evento en una sola iteración, y en promedio necesitó de cuatro iteraciones.

Figura 62. Valor mínimo, máximo y promedio de iteraciones para segmentos de fallas no simultáneas




Fuente: elaboración propia.

Al analizar la relación de proporcionalidad respecto a ZOA, para los valores promedio, LSA aumentó 7 veces el número de iteraciones; BGSA, 11, y CSA, 900.

En la figura 63 se presenta, mediante un diagrama de barras, para ZOA, CSA, LSA y BGSA, el comportamiento del número de iteraciones en segmentos de fallas simultáneas. Cada técnica se analizó en función del valor mínimo, máximo y promedio de iteraciones; para el promedio, se tomó la parte entera del promedio. Como se observa en la figura 63, así como en los eventos no simultáneos, ZOA fue la estrategia con el menor número de iteraciones, y CSA la estrategia con el mayor número. Aunque hay variaciones

en la cantidad de iteraciones respecto a la figura 62, se mantiene el mismo orden de magnitud.

Figura 63. Valor mínimo, máximo y promedio de iteraciones para segmentos de fallas simultáneas



Fuente: elaboración propia.

El tiempo de simulación es una métrica de desempeño subjetiva, pues depende de la metodología implementada para la programación del algoritmo y del equipo utilizado para la simulación. Sin embargo, hace parte del conjunto de métricas utilizadas para el análisis de la carga computacional. Se aclara que, para obtener una comparación justa, se utilizó el mismo equipo y se ajustaron de forma similar los recursos y procesos del sistema operativo. En las tablas 30 y 31 se presentan los valores máximos, mínimos y promedio para los eventos no simultáneos y simultáneos, respectivamente.

Para los eventos no simultáneos, de acuerdo con la tabla 30, en la primera posición se ubica ZOA; en la segunda, BGSA; en la tercera, LSA, y, finalmente, en la cuarta, CSA. Al analizar el incremento de tiempo respecto a ZOA, para los valores promedio no simultáneos, BGSA incrementó 0,03 s; LSA, 0,1 s, y CSA, 1,5 s.

Para los eventos simultáneos, de acuerdo con la tabla 31, en la primera posición se ubica ZOA; en la segunda y tercera posición, a diferencia de los no simultáneos, se ubican LSA y BGSA, y, finalmente, en la cuarta posición se ubica CSA. Al analizar el incremento de tiempo respecto a ZOA, para los valores promedio simultáneos, LSA incrementó 0,13 s; LSA, 0,14 s, y CSA, 1,3 s. En este caso, la única variación representativa se presentó para BGSA, que aumentó de 0,03 a

0,14 s; para las demás, se mantiene un incremento en el tiempo de simulación del mismo orden de magnitud.

Tabla 30. Tiempo de simulación en segmentos de fallas no simultáneas (s)

Tiempo	ZOA	CSA	LSA	BGSA
Mínimo	0,00236	0,83297	0,06264	0,02423
Máximo	0,00728	2,35343	0,49805	0,05244
Promedio	0,00375	1,52895	0,13188	0,03606

Fuente: elaboración propia.

Tabla 31. Tiempo de simulación en segmentos de fallas simultáneas (s)

Tiempo	ZOA	CSA	LSA	BGSA
Mínimo	0,00333	0,38352	0,07941	0,04968
Máximo	0,00688	2,53652	0,20371	0,27065
Promedio	0,00457	1,27296	0,13212	0,14741

Fuente: elaboración propia.

Conclusiones

La presente investigación desarrolla un modelo utilizando técnicas de IA para la ubicación de fallas de baja impedancia en líneas de distribución con GD. El modelo utiliza funciones matemáticas que permiten transformar estados de segmentos de línea en estados de operación de los interruptores. Como estrategias de IA, se trabaja con técnicas de optimización inteligente; específicamente, con cuatro modelos de optimización metaheurística basados en comportamientos poblacionales, los cuales son ampliamente utilizados: algoritmo de optimización de cebra (ZOA), algoritmo de búsqueda de cuco (CSA), algoritmo de búsqueda de relámpago (LSA) y algoritmo de búsqueda gravitacional binaria (BGSA). El modelo propuesto, a diferencia de las técnicas convencionales, no localiza una longitud de falla: se diseñó para identificar segmentos de falla, característica que está asociada a las unidades de terminal de alimentador (FTU), utilizadas como sistema de medida. Como métricas de desempeño, se utilizan la precisión para identificar el segmento de línea (%), el número de iteraciones, el tiempo de simulación (s), los mínimos de la función *fitness* vs. el número de iteraciones, y los mínimos promedio de la función *fitness* vs. el número de iteraciones.

Para asumir los retos de los nuevos sistemas eléctricos, se requiere incorporar estrategias avanzadas de computación. En los últimos años se han propuesto diversas técnicas para la ubicación de fallas en líneas de distribución con GD, donde la IA ha presentado buenos resultados por su alto rendimiento y capacidad para proporcionar una respuesta rápida durante una falla. No hay una solución óptima al problema de ubicación de fallas en líneas de distribución con GD: por la generalidad de la IA, no es posible caracterizar un algoritmo como la mejor estrategia para la ubicación de fallas.

Aunque se han logrado avances prometedores, todavía quedan muchas preguntas por responder; el enfoque constante consiste en identificar los avances en IA para lograr resultados cada vez mejores. Además, las estrategias implementadas deben ser escalables, con el fin de gestionar eficientemente la carga computacional y para que sean capaces de resolver problemas de mayor complejidad.

La evaluación del modelo propuesto para la ubicación de fallas mediante las cuatro técnicas de optimización inteligente para eventos no simultáneos y simultáneos se realizó a través de la precisión para identificar el segmento de línea en falla y de parámetros propios de las técnicas: número de iteraciones, tiempo de simulación, mínimos de la función *fitness* y mínimos promedio de la función *fitness*. Respecto a la métrica de precisión, las cuatro técnicas presentaron una precisión del 100 % para todos los eventos analizados (fallas simultáneas y fallas no simultáneas); por lo tanto, para el sistema de potencia implementado, las cuatro técnicas son buenas alternativas para detectar fallas de baja impedancia en líneas de distribución con y sin GD. Aunque las cuatro estrategias mostraron buenos resultados, se requiere analizar diferentes escenarios y casos de estudio para llegar a una conclusión generalizada. Respecto al número de iteraciones y el tiempo de simulación, ZOA fue la estrategia con el menor número de iteraciones, seguida por LSA y BGSA, y CSA fue la estrategia que requirió el mayor número de iteraciones para encontrar la solución.

App LF-UD es una herramienta de simulación que permite analizar el desempeño de diferentes algoritmos de ubicación de fallas de baja impedancia en líneas de distribución con y sin GD. La interfaz gráfica y los algoritmos de ubicación fueron desarrollados en App Designer, mientras que el análisis de flujo de carga y cortocircuito, así como la inclusión de la GD, se realizaron con el *software* de acceso abierto OpenDSS. Las métricas utilizadas se implementaron de acuerdo con los parámetros del error relativo definidos en el estándar C37.114-2014. Según los ajustes del usuario, el error se puede obtener para un punto específico o a través de una gráfica de acuerdo con un tramo completo de línea. El simulador permite variar el tipo de estrategia de ubicación de fallas, la línea o nodo en falla, el tipo de falla (trifásica, monofásica, bifásica, bifásica a tierra), la resistencia de falla, el tamaño en términos de potencia de cortocircuito de la GD, la ubicación de la GD, la longitud

y los modelos de las líneas de distribución. En el caso de la GD, la inclusión se realiza en términos de la potencia de cortocircuito y la ubicación de la GD, características relevantes para el análisis de cortocircuito; no obstante, es necesario mejorar estas características agregando modelos de GD de acuerdo con el tipo de generación.

Trabajo futuro

Con el rápido desarrollo de las redes de distribución, los usuarios están demandando una mayor confiabilidad y calidad en la prestación del servicio. En el área de IA con técnicas de optimización, se han realizado numerosos trabajos sobre el diseño de algoritmos para problemas específicos. El objetivo fundamental de estos trabajos es proporcionar a los operadores y usuarios herramientas que les permitan adaptarse a los nuevos esquemas de operación.

La ubicación de fallas con métodos de IA genera nuevos desafíos. Aunque los avances son alentadores, aún existen muchas preguntas por responder. Es fundamental aprovechar los avances en ciencias de la computación, con el fin de obtener resultados óptimos. Para lograrlo, es esencial que las estrategias implementadas sean escalables, lo que permitirá gestionar eficientemente la carga computacional y abordar con éxito problemas de mayor complejidad.

El trabajo futuro implica identificar estrategias de aprendizaje inteligente y adaptarlas para abordar las tareas complejas que surgen en el análisis de las redes de distribución. Este enfoque permitirá satisfacer las crecientes demandas de confiabilidad y calidad en la prestación del servicio eléctrico. Adicionalmente, para el sistema de potencia implementado, las cuatro técnicas de optimización inteligente utilizadas son buenas alternativas, pero es necesario analizar diferentes escenarios y casos de estudio para llegar a una conclusión generalizada.

Este trabajo utilizó cuatro técnicas de optimización inteligente para la ubicación de segmentos en fallas en líneas de distribución con GD. El modelo utiliza funciones de interruptor y FTU como esquema de medición. Las funciones permiten transformar los estados de segmentos de línea en estados

de operación de los interruptores; la función implementada se seleccionó según el análisis del estado del arte; sin embargo, son diversos los parámetros que se pueden incluir y ajustar en una función de interruptor.

Las FTU son dispositivos electrónicos inteligentes diseñados para la medición y automatización; se ubican en los interruptores de segmentos para almacenar y transmitir al centro de control los eventos; sin embargo, desde un punto de vista económico, su instalación presenta altos costos para el operador. El trabajo futuro consiste en adaptar o proponer nuevas funciones de interruptor, así como en implementar estrategias de ubicación óptima para las FTU, buscando optimizar tanto la eficiencia como la viabilidad económica del sistema e implementar estrategias de ubicación óptima para las FTU.

En este trabajo se utilizaron métricas asociadas a la precisión en la ubicación y a la carga computacional. Sin embargo, como trabajo futuro, es esencial incorporar otro tipo de métricas que permitan analizar aspectos como la confiabilidad de la red de distribución, los costos de inversión y los costos de operación. La inclusión de estas métricas adicionales proporcionará una visión más integral y completa del desempeño y la viabilidad del sistema.

Además, en relación con las métricas utilizadas, es importante destacar que el tiempo de simulación es una métrica de desempeño subjetiva, que depende de la metodología implementada para la programación del algoritmo y del equipo utilizado para la simulación. Por lo tanto, como parte del trabajo futuro, se debe considerar la inclusión de otro tipo de métricas para el análisis de la carga computacional.

Referencias

- Abualigah, L., Elaziz, M. A., Hussien, A. G., Alsabibi, B., Jalali, S. M. J. y Gandomi, A. H. (2021). Lightning search algorithm: A comprehensive survey. *Applied Intelligence*, 51(4), 2353-2376. <https://doi.org/10.1007/s10489-020-01947-2>
- Adefarati, T. y Bansal, R. C. (2016). Integration of renewable distributed generators into the distribution system: A review. *IET Renewable Power Generation*, 10(7), 873-884.
- Alwash, S. F., Ramachandaramurthy, V. K. y Mithulananthan, N. (2015). Fault-location scheme for power distribution system with distributed generation. *IEEE Transactions on Power Delivery*, 30(3), 1187-1195. <https://doi.org/10.1109/TPWRD.2014.2372045>
- Aranha, C., Camacho Villalón, C. L., Campelo, F., Dorigo, M., Ruiz, R., Sevaux, M., Sörensen, K. y Stützle, T. (2022). Metaphor-based metaheuristics, a call for action: The elephant in the room. *Swarm Intelligence*, 16(1), 1-6. <https://doi.org/10.1007/s11721-021-00202-9>
- Aslan, Y. y Yağan, Y. E. (2016, 30 de junio-2 de julio). *ANN based fault location for medium voltage distribution lines with remote-end source* [presentación en conferencia]. 2016 International Symposium on Fundamentals of Electrical Engineering (ISFEE), Bucarest, Rumania. <https://doi.org/10.1109/ISFEE.2016.7803203>
- Bahmanyar, A., Jamali, S., Estebsari, A. y Bompard, E. (2017). A comparison framework for distribution system outage and fault location methods. *Electric Power Systems Research*, 145, 19-34. <https://doi.org/https://doi.org/10.1016/j.epsr.2016.12.018>
- Bao, W., Fang, Q., Wang, P., Yan, W. y Pan, P. (2021, 29-30 de mayo). *A fault location method for active distribution network with DGs* [presentación en conferencia]. International Conference on Smart Grid and

Electrical Automation (ICSGEA), Kunming, China.
<https://doi.org/10.1109/ICSGEA53208.2021.00010>

- Bárcenas, D. y Rueda, J. (2021). *Herramienta computacional para la localización de fallas en líneas de transmisión usando teoría de ondas viajeras* [tesis de pregrado, Universidad del Norte]. DSpace UniNorte. <http://hdl.handle.net/10584/11244>
- Barja-Martinez, S., Aragüés-Peñalba, M., Munné-Collado, Í., Lloret-Gallego, P., Bullich-Massagué, E. y Villafafila-Robles, R. (2021). Artificial intelligence techniques for enabling Big Data services in distribution networks: A review. *Renewable and Sustainable Energy Reviews*, 150, artículo 111459. <https://doi.org/https://doi.org/10.1016/j.rser.2021.111459>
- Beheshtaein, S., Cuzner, R., Savaghebi, M., Golestan, S. y Guerrero, J. M. (2019). Fault location in microgrids: A communication-based high-frequency impedance approach. *IET Generation Transmission & Distribution*, 13(8, SI), 1229-1237. <https://doi.org/10.1049/iet-gtd.2018.5166>
- Bkassiny, M., Li, Y. y Jayaweera, S. K. (2013). A survey on machine-learning techniques in cognitive radios. *IEEE Communications Surveys & Tutorials*, 15(3), 1136-1159. <https://doi.org/10.1109/SURV.2012.100412.00017>
- Bozorg-Haddad, O. (ed.). (2018). *Advanced optimization by nature-inspired algorithms (vol. 720)*. Springer. <https://doi.org/10.1007/978-981-10-5221-7>
- Cadena, A., Lozano, F., Quijano, N., Ramos, G., Ríos, M., Gordillo, G., Torres, H. y Latorre, G. (2011). *Redes inteligentes y generación distribuida*. Universidad de los Andes.
- Chang, K.-C., Zhang, R., Deng, H., Chang, F.-H., Wang, H.-C. y Amesimenu, G. D. K. (2022). Chaotic particle swarm optimization algorithm for fault location of distribution network with DG BT. En A. E. Hassanien, V. Snášel, K.-C. Chang, A. Darwish y T. Gaber (eds.), *International Conference on Advanced Intelligent Systems and Informatics* (pp. 256-266). Springer International Publishing.
- Chaudhary, R., Sethi, S., Keshari, R. y Goel, S. (2012). A study of comparison of Network Simulator-3 and Network Simulator-2. *International Journal of Computer Science and Information Technologies*, 3(1), 3085-3092.

- Chen, J., Chu, E., Li, Y., Yun, B., Dang, H. y Yang, Y. (2020). Faulty feeder identification and fault area localization in resonant grounding system based on wavelet packet and bayesian classifier. *Journal of Modern Power Systems and Clean Energy*, 8(4), 760-767. <https://doi.org/10.35833/MPCE.2019.000051>
- Chen, X. y Jiao, Z. (2018, 17-19 de septiembre). *Accurate fault location method of distribution network with limited number of PMUs* [presentación en conferencia]. 2018 China International Conference on Electricity Distribution (CICED), Tianjin, China. <https://doi.org/10.1109/CICED.2018.8592074>
- Chicco, G. y Mazza, A. (2019). 100 years of symmetrical components. *Energies*, 12(3), 450.
- Chih, H.-C., Lin, W.-C., Huang, W.-T. y Yao, K.-C. (2022). Implementation of EDGE computing platform in feeder terminal unit for smart applications in distribution networks with distributed renewable energies. *Sustainability*, 14(20), artículo 13042. <https://doi.org/10.3390/su142013042>
- Cikan, M. y Cikan, N. N. (2023). Optimum allocation of multiple type and number of DG units based on IEEE 123-bus unbalanced multi-phase power distribution system. *International Journal of Electrical Power & Energy Systems*, 144, artículo 108564. <https://doi.org/https://doi.org/10.1016/j.ijepes.2022.108564>
- Dadary, S. y Afrakhte, H. (2017). Accuracy improvement of impedance-based fault locating method in distribution systems with DGs considering loss of laterals and load variations. *International Transactions on Electrical Energy Systems*, 27(11), artículo e2420. <https://doi.org/https://doi.org/10.1002/etep.2420>
- Dagenhart, J. (1999, 2-4 de mayo). *The 40-ohm ground fault phenomenon* [presentación en conferencia]. 1999 Rural Electric Power Conference (Cat. No. 99CH36302), Indianapolis, Estados Unidos. <https://doi.org/10.1109/REPCON.1999.768690>
- Darab, C., Tarnovan, R., Turcu, A. y Martineac, C. (2019, 21-23 de mayo). *Artificial intelligence techniques for fault location and detection in distributed generation power systems* [presentación en conferencia]. 2019 8th International Conference on Modern Power Systems (MPS), Cluj-Napoca, Rumania. <https://doi.org/10.1109/MPS.2019.8759662>

- Das, J. C. (2016). *Understanding symmetrical components for power system modeling*. John Wiley & Sons.
- Das, S., Santoso, S. y Ananthan, S. N. (2021). *Fault location on transmission and distribution lines: Principles and applications*. John Wiley & Sons.
- De las Casas, M. B., Quintero, H. R., Sosa, I. O., Morales, D. S. y Mendoza, L. E. L. (2009). Influencia de la generación distribuida en los niveles de cortocircuito y en las protecciones eléctricas en subestaciones de 110/34, 5 kV. *Ingeniería Energética*, 30(1).
- De Mársico, M. C., Scardamaglia, R. C. y Reboreda, J. C. (2020). *Aves que parasitan nidos ajenos*. *Ciencia Hoy*, 29(169), 49-55.
- Dey, N. (2020). *Applications of cuckoo search algorithm and its variants*. Springer.
- Farughian, A., Kumpulainen, L. y Kauhaniemi, K. (2018). Review of methodologies for earth fault indication and location in compensated and unearthed MV distribution networks. *Electric Power Systems Research*, 154, 373-380. <https://doi.org/https://doi.org/10.1016/j.epsr.2017.09.006>
- Fei, W. y Moses, P. (2019). Fault current tracing and identification via machine learning considering distributed energy resources in distribution networks. *Energies*, 12(22), artículo 4333. <https://doi.org/10.3390/en12224333>
- Fortescue, C. L. (1918). Method of symmetrical co-ordinates applied to the solution of polyphase networks. *Transactions of the American Institute of Electrical Engineers*, 37(2), 1027-1140.
- Gana, N., Ab Aziz, N. F., Ali, Z., Hashim, H. y Yunus, B. (2017). A comprehensive review of fault location methods for distribution power system. *Indonesian Journal of Electrical Engineering and Computer Science*, 6(1). <https://doi.org/http://doi.org/10.11591/ijeecs.v6.i1.pp185-192>
- Gao, S., Zhou, M., Wang, Y., Cheng, J., Yachi, H. y Wang, J. (2019). Dendritic neuron model with effective learning algorithms for classification, approximation, and prediction. *IEEE Transactions on Neural Networks and Learning Systems*, 30(2), 601-614. <https://doi.org/10.1109/TNNLS.2018.2846646>
- Gaonkar, D. (ed.). (2010). *Distributed generation*. InTech.

- García-Martínez, C., Gutiérrez, P. D., Molina, D., Lozano, M. y Herrera, F. (2017). Since CEC 2005 competition on real-parameter optimisation: A decade of research, progress and comparative analysis's weakness. *Soft Computing*, 21(19), 5573-5583. <https://doi.org/10.1007/s00500-016-2471-9>
- Giral-Ramírez, D. (2022). Intelligent fault location algorithms for distributed generation distribution networks: A review. *Przegląd Elektrotechniczny*, 1(7), 139-146. <https://doi.org/10.15199/48.2022.07.23>
- Goh, H. H., Sim, S. Y., Mohamed, M. A. H., Rahman, A. K. A., Ling, C. W., Chua, Q. S. y Goh, K. C. (2017). Fault location techniques in electrical power system: A review. *Indonesian Journal of Electrical Engineering and Computer Science*, 8(1), 206-212.
- González, D. (2014). *Sobretensiones debidas a cortocircuitos fase-tierra en redes de media tensión para distintos regímenes de neutro*. Universidad de Sevilla.
- Hashemi, A., Dowlatshahi, M. B. y Nezamabadi-Pour, H. (2021). Gravitational search algorithm: Theory, literature review, and applications. *Handbook of AI-Based Metaheuristics*, 119-150.
- He, X., Qian, Q., Wang, Y., Wang, Y. y Shi, S. (2018, 20-22 de octubre). *Adaptive traveling waves based protection of distribution lines* [presentación en conferencia]. 2018 2nd IEEE Conference on Energy Internet and Energy System Integration (EI2), Pekín, China. <https://doi.org/10.1109/EI2.2018.8582627>
- Hernández, C., Giral, D. y Marquez, H. (2017). Evolutive algorithm for spectral handoff prediction in cognitive wireless networks. *Contemporary Engineering Sciences*, 10(14), 673-689. <https://doi.org/10.12988/ces.2017.7766>
- Hernández-Sampieri, R., Fernández-Collado, C. y Baptista, P. (2006). *Metodología de la investigación*. McGraw-Hill.
- Huang, X., Xie, Z. y Huang, X. (2020). Fault location of distribution network base on improved cuckoo search algorithm. *IEEE Access*, 8, 2272-2283. <https://doi.org/10.1109/ACCESS.2019.2962276>
- Hui, Y., Yan, X., Bin, Q. y Qi, W. (2019, 10-13 de mayo). *Fault location method for DC distribution network based on particle swarm optimization* [presentación en conferencia]. 2019 IEEE 2nd International Conference on Electronics Technology (ICET), Chengdú, China. <https://doi.org/10.1109/ELTECH.2019.8839476>

- Ibrahim, K. S. M. H., Huang, Y. F., Ahmed, A. N., Koo, C. H. y El-Shafie, A. (2021). A review of the hybrid artificial intelligence and optimization modelling of hydrological streamflow forecasting. *Alexandria Engineering Journal*, 61(1), 279-303.
- Ibrahim, M. S., Dong, W. y Yang, Q. (2020). Machine learning driven smart electric power systems: Current trends and new perspectives. *Applied Energy*, 272, artículo 115237. <https://doi.org/10.1016/j.apenergy.2020.115237>
- IEEE. (2009). IEEE application guide for IEEE Std 1547(TM), IEEE Standard for Interconnecting Distributed Resources with Electric Power Systems. En *IEEE Std 1547.2-2008* (pp. 1-217). <https://doi.org/10.1109/IEEESTD.2008.4816078>
- IEEE. (2015). Guide for determining fault location on AC transmission and distribution lines. En *C37.114-2014* (pp. 1-76). <https://doi.org/10.1109/IEEESTD.2015.7024095>
- IEEE. (2018). IEEE Standard for Interconnection and Interoperability of Distributed Energy Resources with Associated Electric Power Systems Interfaces. En *IEEE Std 1547-2018 (revision of IEEE Std 1547-2003)* (pp. 1-138). <https://doi.org/10.1109/IEEESTD.2018.8332112>
- IEEE. (2019). IEEE recommended practice for conducting short-circuit studies and analysis of industrial and commercial power systems. En *IEEE Std 3002.3-2018* (pp. 1-184). <https://doi.org/10.1109/IEEESTD.2019.8672198>
- IEEE. (2022). *IEEE PES Test Feeder*. <https://cmte.ieee.org/pes-testfeeders/resources/>
- International Electrotechnical Commission. (2016). *IEC 60909-0:2016. Short-circuit currents in three-phase a.c. systems*. <https://webstore.iec.ch/publication/24100>
- Jenkins, N., Ekanayake, J. y Strbac, G. (2014). *Distributed generation*. IET.
- Jiang, B., Dong, X., Shi, S. y Wang, B. (2015, 26-30 de julio). *Fault line identification of single line to ground fault for non-effectively grounded distribution networks with double-circuit lines* [presentación en conferencia]. IEEE Power and Energy Society General Meeting, Denver, Estados Unidos. <https://doi.org/10.1109/PESGM.2015.7286346>

- Jin, Q. y Ju, R. (2012, 27-30 de julio). *Fault location for distribution network based on genetic algorithm and stage treatment* [presentación en conferencia]. 2012 Spring Congress on Engineering and Technology, Denver, Estados Unidos. <https://doi.org/10.1109/PESGM.2015.7286346>
- Kaur, A., Kaur, A. y Sharma, S. (2018, 22-23 de febrero). *Cognitive decision engine design for CR based IoTs using differential evolution and bat algorithm* [presentación en conferencia]. 2018 5th International Conference on Signal Processing and Integrated Networks (SPIN), Noida, India. <https://doi.org/10.1109/SPIN.2018.8474273>
- Khaleghi, A., Oukati Sadegh, M., Ghazizadeh-Ahsaei, M. y Mehdipour Rabori, A. (2018). Transient fault area location and fault classification for distribution systems based on wavelet transform and adaptive neuro-fuzzy inference system (ANFIS). *Advances in Electrical and Electronic Engineering*, 16(2), 155-166. <https://doi.org/10.15598/aece.v16i2.2563>
- Kumar, R. y Saxena, D. (2020). A literature review on methodologies of fault location in the distribution system with distributed generation. *Energy Technology*, 8(3), artículo 1901093. <https://doi.org/https://doi.org/10.1002/ente.201901093>
- Lala, H., Karmakar, S. y Ganguly, S. (2019). Detection and localization of faults in smart hybrid distributed generation systems: A Stockwell transform and artificial neural network-based approach. *International Transactions on Electrical Energy Systems*, 29(2), artículo e2725. <https://doi.org/10.1002/etep.2725>
- Li, J., Liu, Y., Li, C., Zeng, D., Li, H. y Wang, G. (2022). An FTU-based method for locating single-phase high-impedance faults using transient zero-sequence admittance in resonant grounding systems. *IEEE Transactions on Power Delivery*, 37(2), 913-922. <https://doi.org/10.1109/TPWRD.2021.3074217>
- Li, W., Su, J., Wang, X., Li, J. y Ai, Q. (2020). Fault location of distribution networks based on multi-source information. *Global Energy Interconnection*, 3(1), 76-84. <https://doi.org/https://doi.org/10.1016/j.gloi.2020.03.005>
- Li, Y., Shen, H. y Wang, M. (2016, 6-10 de noviembre). *Optimization spectrum decision parameters in CR using autonomously search algorithm* [presentación en conferencia]. International Conference on Signal

- Processing (ICSP), Chengdú, China. <https://doi.org/10.1109/ICSP.2016.7878007>
- Lin, W.-C., Huang, W.-T., Yao, K.-C., Chen, H.-T. y Ma, C.-C. (2021). Fault location and restoration of microgrids via particle swarm optimization. *Applied Sciences*, 11(15), artículo 7036. <https://doi.org/10.3390/app11157036>
- Long, C., Zhang, H., Shi, Y., Guo, R. y Dong, L. (2022). An optimal meter placement method based on virtual flow. *Proceedings of the Asia Conference on Electrical, Power and Computer Engineering*, 63, 1-5. <https://doi.org/10.1145/3529299.3533394>
- Madani, V., Das, R. y Meliopoulos, A. P. (2017, 21-23 de diciembre). *Active distribution network and microgrid integration strategy* [presentación en conferencia]. 2017 7th International Conference on Power Systems (ICPS), Pune, India. <https://doi.org/10.1109/ICPES.2017.8387348>
- Maruf, H. M. M., Müller, F., Hassan, M. S. y Chowdhury, B. (2018, 25-28 de junio). *Locating faults in distribution systems in the presence of distributed generation using machine learning techniques* [presentación en conferencia]. 2018 9th IEEE International Symposium on Power Electronics for Distributed Generation Systems (PEDG), Charlotte, Estados Unidos. <https://doi.org/10.1109/PEDG.2018.8447728>
- Mejdi, L., Kardous, F. y Grayaa, K. (2022). Impact analysis and optimization of EV charging loads on the LV grid: A case study of workplace parking in Tunisia. *Energies*, 15(19), artículo 7127. <https://doi.org/10.3390/en15197127>
- Mer, D. K. y Patel, R. R. (2016, 3-5 de marzo). *The concept of distributed generation & the effects of its placement in distribution network* [presentación en conferencia]. 2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT), Chennai, India. <https://doi.org/10.1109/ICEEOT.2016.7755458>
- Mora Flórez, J. J. y Pérez Londoño, S. M. (2016). *Localización de fallas de baja impedancia en sistemas de distribución de energía eléctrica, a partir del fundamental de tensión y corriente*. Universidad Tecnológica de Pereira.
- Moreno, S. R., Pierezan, J., Coelho, L. dos S. y Mariani, V. C. (2021). Multi-objective lightning search algorithm applied to wind farm layout optimization. *Energy*, 216, artículo 119214. <https://doi.org/10.1016/j.energy.2020.119214>

- Na, W., Yan-jun, J. y Jian-tao, Y. (2008, 9-12 de noviembre). *Fault location of distribution network based on plant growth simulation algorithm* [presentación en conferencia]. 2008 International Conference on High Voltage Engineering and Application, Chongqing, China. <https://doi.org/10.1109/ICHVE.2008.4774003>
- Naghizadeh, R., Afrakhte, H. y Ziapour, M. (2018, 8-10 de mayo). *Smart distribution network reconfiguration based on optimal planning of distributed generation resources using teaching learning based algorithm to reduce generation costs, losses and improve reliability* [presentación en conferencia]. Iranian Conference On Electrical Engineering (ICEE), Mashhad, Irán. <https://doi.org/10.1109/ICEE.2018.8472451>
- Nuthalapati, B. y Sinha, U. K. (2019). Fault detection and location of broken power line not touching the ground. *International Journal of Emerging Electric Power Systems*, 20(3), 2-11. <https://doi.org/10.1515/ijeeps-2018-0321>
- Primadianto, A. y Lu, C.-N. (2017). A review on distribution system state estimation. *IEEE Transactions on Power Systems*, 32(5), 3875-3883. <https://doi.org/10.1109/TPWRS.2016.2632156>
- Priya, G. S. y Geethanjali, M. (2018, 9-10 de marzo). *Design and development of distance protection scheme for wind power distributed generation* [presentación en conferencia]. 2018 National Power Engineering Conference (NPEC), Madurai, India. <https://doi.org/10.1109/NPEC.2018.8476720>
- Rashedi, E., Nezamabadi-pour, H. y Saryazdi, S. (2010). BGSA: Binary gravitational search algorithm. *Natural Computing*, 9(3), 727-745. <https://doi.org/10.1007/s11047-009-9175-3>
- Schneider, K. P., Mather, B. A., Pal, B. C., Ten, C.-W., Shirek, G. J., Zhu, H., Fuller, J. C., Pereira, J. L. R., Ochoa, L. F., De Araujo, L. R., Dugan, R. C., Matthias, S., Paudyal, S., McDermott, T. E. y Kersting, W. (2018). Analytic considerations and design basis for the IEEE distribution test feeders. *IEEE Transactions on Power Systems*, 33(3), 3181-3188. <https://doi.org/10.1109/TPWRS.2017.2760011>
- Shareef, H., Ibrahim, A. A. y Mutlag, A. H. (2015). Lightning search algorithm. *Applied Soft Computing*, 36, 315-333. <https://doi.org/10.1016/j.asoc.2015.07.028>
- Sharifzadeh, A., Ameli, M. T. y Azad, S. (2021). Power system challenges and issues. En M. Nazari-Heris, S. Asadi, B. Mohammadi-Ivatloo,

- M. Abdar, H. Jebelli y M. Sadat-Mohammadi (eds.), *Application of machine learning and deep learning methods to power system problems* (pp. 1-17). Springer.
- Sharma, R., Mahela, O. P. y Agarwal, S. (2018, 24-25 de febrero). *Detection of power system faults in distribution system using Stockwell transform* [presentación en conferencia]. 2018 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS), Bhopal, India. <https://doi.org/10.1109/SCEECS.2018.8546879>
- Shi, Y., Sagduyu, Y. E., Erpek, T., Davaslioglu, K., Lu, Z. y Li, J. H. (2018, 20-24 de mayo). *Adversarial deep learning for cognitive radio security: Jamming attack and defense strategies* [presentación en conferencia]. 2018 IEEE International Conference on Communications Workshops (ICC Workshops), Kansas, Estados Unidos. <https://doi.org/10.1109/ICCW.2018.8403655>
- Sifat, A. I., McFadden, F. S., Ahmed, A., Rayudu, R. y Hunzel, A. (2017, 4-7 de diciembre). *Feasibility of magnetic signature-based detection of low and high impedance faults in low-voltage distribution networks* [presentación en conferencia]. 2017 IEEE Innovative Smart Grid Technologies - Asia (ISGT-Asia), Auckland, Nueva Zelanda. <https://doi.org/10.1109/ISGT-Asia.2017.8378472>
- Sonoda, D., De Souza, A. C. Z. y Da Silveira, P. M. (2018). Fault identification based on artificial immunological systems. *Electric Power Systems Research*, 156, 24-34. <https://doi.org/https://doi.org/10.1016/j.epsr.2017.11.012>
- Sörensen, K. (2015). Metaheuristics—the metaphor exposed. *International Transactions in Operational Research*, 22(1), 3-18.
- Srinivasa Rao, T. C., Tulasi Ram, S. S. y Subrahmanyam, J. B. V. (2019). Fault signal recognition in power distribution system using deep belief network. *Journal of Intelligent Systems*, 29(1), 459-474. <https://doi.org/10.1515/jisys-2017-0499>
- Steinberg, J. (2003). Cebras: nacidas para migrar. *National Geographic*, 12(9), 30-43.
- Strezoski, L., Stefani, I. y Brbaklic, B. (2019, 1-4 de julio). *Active management of distribution systems with high penetration of distributed energy resources* [presentación en conferencia]. IEEE EUROCON 2019. 18th

- International Conference on Smart Technologies, Novi Sad, Serbia.
<https://doi.org/10.1109/EUROCON.2019.8861748>
- Sun, H., Yi, H., Zhuo, F., Du, X. y Yang, G. (2020). Precise fault location in distribution networks based on optimal monitor allocation. *IEEE Transactions on Power Delivery*, 35(4), 1788-1799. <https://doi.org/10.1109/TPWRD.2019.2954460>
- Sun, Z., Wang, Q. y Wei, Z. (2021). Fault location of distribution network with distributed generations using electrical synaptic transmission-based spiking neural P systems. *International Journal of Parallel, Emergent and Distributed Systems*, 36(1), 11-27. <https://doi.org/10.1080/17445760.2019.1682145>
- Tao, F., Zhang, L. y Laili, Y. (2016). *Configurable intelligent optimization algorithm*. Springer.
- Tao, W., Yang, G. y Zhang, J. (2016, 22-26 de mayo). *Fault section locating for distribution network with DG based on improved ant colony algorithm* [presentación en conferencia]. 2016 IEEE 8th International Power Electronics and Motion Control Conference (IPEMC-ECCE Asia), Hefei, China. <https://doi.org/10.1109/IPEMC.2016.7512600>
- Tashakkori, A., Wolfs, P. J., Islam, S. y Abu-Siada, A. (2020). Fault location on radial distribution networks via distributed synchronized traveling wave detectors. *IEEE Transactions on Power Delivery*, 35(3), 1553-1562. <https://doi.org/10.1109/TPWRD.2019.2948174>
- Tleis, N. (2019). *Power systems modelling and fault analysis: Theory and Practice*. Academic Press.
- Torres, H. (2002). *El rayo: mitos, leyendas, ciencia y tecnología*. Universidad Nacional de Colombia.
- Trojovská, E., Dehghani, M. y Trojovský, P. (2022). Zebra optimization algorithm: A new bio-inspired optimization algorithm for solving optimization algorithm. *IEEE Access*, 10, 49 445-49 473. <https://doi.org/10.1109/ACCESS.2022.3172789>
- Trujillo, C. L., Santamaría, F., Hernández, J. A., Jaramillo, A. A., Gaona, E. E., Rivas, E., Flórez, O. D., Rodríguez, D. J., Alarcón, J. A. y Rojas, H. E. (2015). *Microrredes eléctricas*. Editorial UD.
- Unidad de Planeación Minero Energética, Universidad Nacional de Colombia y Universidad del Valle. (2018). *Observatorio Colombiano de Energía: aproximación a las condiciones para su conformación*.

- Vasuki, A. (2020). *Nature-inspired optimization algorithms*. CRC Press.
- Vaziri, M., Vadhva, S., Oneal, T. y Johnson, M. (2011, 3-5 de agosto). *Distributed generation issues, and standards* [presentación en conferencia]. 2011 IEEE International Conference on Information Reuse & Integration, Las Vegas, Estados Unidos. <https://doi.org/10.1109/IRI.2011.6009588>
- Veerasamy, V., Abdul Wahab, N. I., Ramachandran, R., Thirumeni, M., Subramanian, C., Othman, M. L. y Hizam, H. (2019). High-impedance fault detection in medium-voltage distribution network using computational intelligence-based classifiers. *Neural Computing and Applications*, 31(12), 9127-9143. <https://doi.org/10.1007/s00521-019-04445-w>
- Wang, X., Yu, X., Xue, Y., Zhu, Y. y Fu, J. (2018). Application of improved quantum genetic algorithm in fault location of distribution network. En B. Xu (ed.), *Proceedings of 2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC 2018)* (pp. 2524-2529). IEEE.
- Wang, X.-F., Song, Y. e Irving, M. (2010). *Modern power systems analysis*. Springer Science & Business Media.
- Wolpert, D. H. y Macready, W. G. (1997). No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, 1(1), 67-82. <https://doi.org/10.1109/4235.585893>
- Xiong, G., Yuan, X., Mohamed, A. W., Chen, J. y Zhang, J. (2022). Improved binary gaining-sharing knowledge-based algorithm with mutation for fault section location in distribution networks. *Journal of Computational Design and Engineering*, 9(2), 393-405. <https://doi.org/10.1093/jcde/qwac007>
- Yang, H., Guo, Y. y Liu, X. (2020). Fault section location of active distribution network based on wolf pack and differential evolution algorithms. *International Journal of Performability Engineering*, 16(1), 143-151.
- Yang, X.-S. y Deb, S. (2010). Engineering optimisation by cuckoo search. *International Journal of Mathematical Modelling and Numerical Optimisation*, 1(4), 330-343.
- Yellagoud, S. K. y Talluri, P. R. (2018, 27-28 de octubre). *Assessment of fault location methods for electric power distribution networks* [presentación en

- conferencia]. 2018 4th International Conference for Convergence in Technology (I2CT), Mangalore, India. <https://doi.org/10.1109/I2CT42659.2018.9058148>
- Yem Souhe, F. G., Boum, A. T., Ele, P., Mbey, C. F. y Foba Kakeu, V. J. (2022). A novel smart method for state estimation in a smart grid using smart meter data. *Applied Computational Intelligence and Soft Computing*, 2022(1), 1-14. <https://doi.org/10.1155/2022/7978263>
- Yu, D. C. y Khan, S. H. (1994). An adaptive high and low impedance fault detection method. *IEEE Transactions on Power Delivery*, 9(4), 1812-1821.
- Zhang, B., Liu, H., Song, J. y Zhang, J. (2019, 3-5 de enero). *Simulation on grounding fault location of distribution network based on regional parameters* [presentación en conferencia]. International Symposium on High Assurance Systems Engineering (HASE), Hangzhou, China.
- Zhang, T., Yu, H., Zeng, P., Sun, L., Song, C. y Liu, J. (2020). Single phase fault diagnosis and location in active distribution network using synchronized voltage measurement. *International Journal of Electrical Power & Energy Systems*, 117. <https://doi.org/10.1016/j.ijepes.2019.105572>
- Zhao, D., Chen, Y., Wang, Y., Zhao, Y., Fu, Z., Du, J., Wang, L., Cheng, R., Zhen, Y., Zhang, H., Zhou, Y. y Ren, Q. (2022). Electromagnetic-thermal analysis of FTU under the high-power electromagnetic environment. *Electronics*, 11(16), artículo 2528. <https://doi.org/10.3390/electronics11162528>
- Zhao, M. y Zhang, Y.-F. (2020). Fault section location for distribution network containing DG based on IBQPSO. *Journal of Computational Methods in Sciences and Engineering*, 20(3), 937-949.

Sobre los autores

Diego Armando Giral Ramírez

Docente de planta de la Universidad Distrital Francisco José de Caldas, adscrito a los programas de Tecnología en Electricidad de Media y Baja Tensión e Ingeniería Eléctrica, de la Facultad Tecnológica. Ingeniero eléctrico de la Universidad Distrital Francisco José de Caldas, magíster en Ingeniería Eléctrica de la Universidad de los Andes y doctor en Ingeniería de la Universidad Distrital Francisco José de Caldas. Ha publicado libros de investigación y artículos en el área de sistemas de potencia y telecomunicaciones.

Correo electrónico: dagiralr@udistrital.edu.co

Orcid: <https://orcid.org/0000-0001-9983-4555>

César Augusto Hernández Suárez

Docente de planta de la Universidad Distrital Francisco José de Caldas, adscrito a los programas de Tecnología en Electricidad de Media y Baja Tensión e Ingeniería Eléctrica, de la Facultad Tecnológica, y al Doctorado en Ingeniería, de la Facultad de Ingeniería. Ingeniero eléctrico con especialización en Interconexión de Redes y magíster en Ciencias de la Información y las Comunicaciones de la Universidad Distrital Francisco José de Caldas; doctor en Ingeniería de la Universidad Nacional de Colombia. Ha publicado libros de investigación y artículos en el área de telecomunicaciones.

Correo electrónico: cahernandezs@udistrital.edu.co

Orcid: <https://orcid.org/0000-0001-9409-8341>

José David Cortés Torres

Ingeniero eléctrico de la Universidad Distrital Francisco José de Caldas; magíster en Ingeniería Eléctrica y estudiante del Doctorado en Ingeniería de la Universidad Industrial de Santander. Profesor de la Universidad Industrial de Santander, adscrito al programa de Ingeniería Eléctrica de la Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Ha publicado artículos en el área de sistemas de potencia.

Correo electrónico: jose.cortes@saber.uis.edu.co

Orcid: <https://orcid.org/0000-0001-9232-6785>

EC

E2

Este libro se terminó de imprimir en marzo
de 2025 en la Editorial UD, Bogotá, Colombia.