



Revista EIA
ISSN 1794-1237
e-ISSN 2463-0950
Año XIX/ Volumen 22/ Edición N.43
Enero - junio 2025
Reia4335 pp. 1-41

Publicación científica semestral
Universidad EIA, Envigado, Colombia

PARA CITAR ESTE ARTÍCULO / TO REFERENCE THIS ARTICLE /

Álvarez-Osorio, D.; Arenas-Crespo, O.; Arregocés-Guerra, P.; Rodríguez-Suárez, J. C.; Tobar-Rosero, O. A. y Zapata-Madrigal, G. D.

Modernización del Sistema de Diagnóstico Automático de Eventos en Líneas de Transmisión y Subtransmisión de Energía Eléctrica

Revista EIA, 22(43), Reia4335 pp. 1-41
<https://doi.org/10.24050/reia.v22i43.1768>

✉ *Autor de correspondencia:* Correa Rodríguez-Suárez, J. C.
Magister en Ingeniería Eléctrica,
Especialista en Gerencia de Proyectos,
Ingeniero Electricista
Correo electrónico:
jcrodriguez@intercolombia.com

Recibido: 20-03-2024

Aceptado: 10-12-2024

Disponibile online: 01-01-2025

Modernización del Sistema de Diagnóstico Automático de Eventos en Líneas de Transmisión y Subtransmisión de Energía Eléctrica

ÁLVAREZ-OSORIO DAVID¹

ARENAS-CRESPO OSWALDO¹

ARREGOCÉS-GUERRA PAULINA²

✉ RODRÍGUEZ-SUÁREZ JUAN C.¹

TOBAR-ROSETO OSCAR A.²

ZAPATA-MADRIGAL GERMÁN D.²

1. ISA Intercolombia S.A E.S.P, Colombia

2. Universidad Nacional de Colombia Sede Medellín, Colombia

Resumen

En los sistemas eléctricos es fundamental contar con un correcto esquema de protección, en aras de garantizar estabilidad, seguridad y confiabilidad para los usuarios finales. Es así como al momento de ocurrencia de un evento en el Sistema de Transmisión de Energía se genera gran cantidad de información proveniente de los sistemas de control, relés de protección y registradores de fallas, que debe ser analizada en corto tiempo para la definición de acciones correctivas y la declaración de disponibilidad de los activos comprometidos en el evento. Contar con tiempos de respuesta adecuados para dichos procesos, le permite a una empresa tomar acciones efectivas y oportunas ante múltiples contingencias. Aquí juega un papel fundamental el diagnóstico automático de las fallas como una herramienta apoyada en tecnologías de inteligencia artificial (IA) que permiten tener tiempos de respuesta considerablemente bajos en comparación con los análisis operativos convencionales. En este documento se expone el desarrollo de una herramienta como perfeccionamiento de un aplicativo inicial para diagnóstico

de eventos en líneas de transmisión y subtransmisión con diferentes niveles de tensión, identificando los modelos de IA que tienen mayor eficacia en el proceso de análisis y diagnóstico, exponiendo el proceso realizado desde la preparación de los datos hasta la validación de la herramienta y comparando los resultados obtenidos con el aplicativo llamado Diagnóstico Automático de Eventos (DAE), el cual, fue desarrollado por la propia empresa hace varios años y que se utiliza actualmente en los análisis operativos de las fallas. Los resultados obtenidos permiten identificar la alta eficacia del nuevo sistema DAE desarrollado y su aplicabilidad para análisis en líneas de transmisión con voltajes desde niveles de tensión de 34,5 kV hasta 500 kV.

Palabras clave: sistemas de potencia; líneas; transmisión; subtransmisión; algoritmos; diagnóstico automático; análisis de fallas; inteligencia artificial; analítica; sistema; redes neuronales.

Modernization of the Automatic Diagnosis System for Events in Electrical Energy Transmission and Subtransmission Lines

Abstract

In electrical systems it is essential to have a correct protection scheme, to guarantee stability, security and reliability for end users. This is how, during an event in the Energy Transmission System, a large amount of information is generated from the control systems, protection relays and fault recorders, which must be analyzed in a short time to define corrective actions and the declaration of availability of the assets committed in the event. Having adequate response times for these processes will allow the company to take effective and timely actions in the face of multiple contingencies. Automatic Event Diagnosis (DAE) plays a fundamental role here, as a tool supported by artificial intelligence (AI) technologies that allow for considerably low response times compared to conventional operational analyses. This document presents the development of a tool as an improvement of an initial application for diagnosing events in transmission and subtransmission lines with different voltage levels, identifying the AI models that are most effective in the analysis and diagnosis process, exposing the process carried out from the preparation of the data to the validation of the tool and comparing the results obtained with the DAE system that is usually used in the company. The results obtained allow to identify the high efficiency of the new DAE system developed and its applicability for analysis in transmission lines with voltages from 34.5 kV to 500 kV.

Keywords: power systems; lines; transmission; subtransmission; algorithms; automatic diagnosis; fault analysis; artificial intelligence; analytics; neural networks.

1. Introducción

El crecimiento económico y el desarrollo industrial del país va de la mano con el crecimiento del sistema eléctrico, teniendo como premisa garantizar el suministro efectivo de energía para nuevos usuarios y el desarrollo de actividades propias de cada sector (UPME, 2019). Este proceso, lleva consigo una renovación tecnológica y de sistemas en el sector procurando garantizar la prestación de un servicio estable, seguro y con calidad.

Producto de esto, se evidencia en el sector el uso de nuevas tecnologías para el monitoreo y supervisión del sistema, tecnologías para protección, control, medida y registro de eventos, y, tecnologías de la información y las telecomunicaciones, entre otros (DNP, 2022).

Dada su dinámica, el sistema eléctrico tendrá en su operación eventos anómalos o situaciones particulares, que tendrán como respuesta el accionamiento de una función de protección. Ante dichas situaciones, es necesario garantizar un menor tiempo de restablecimiento y una continuidad en la prestación del servicio (Castillo-Barvo et al., 2022) (Ibrahim, 2012).

Aquí se evidencia uno de los principales retos en el sector, destacando la importancia del análisis de eventos para identificar causas, falencias en el sistema, debilidades o fortalezas y oportunidades de mejora, que impacten de manera directa en la prestación del servicio.

El diagnóstico de fallas permite a los operarios y centros de control corregir los problemas de forma rápida y eficaz (Ibrahim, 2012) (Sevcik y Lunsford, 2007). Por su parte, un sistema automático de diagnóstico de eventos se constituye como una herramienta óptima para asegurar el análisis y mejora continua, permitiendo garantizar el correcto funcionamiento de la red cuando se presenta una falla, generando mejoras en la calidad de prestación del servicio

al disminuir los tiempos de restablecimiento (Ibrahim 2012) (Fan y Liao, 2012) (Musaruddin y Zivanovic, 2009b) (Musaruddin y Zivanovic, 2009a).

En tal sentido, se encuentra en la inteligencia artificial (IA) una herramienta clave que permite entrenar modelos de analítica para identificar, ubicar y realizar diagnósticos de las fallas con los datos resultantes de las señales eléctricas del sistema, tal como se expondrá en las siguientes secciones (Lima et al., 2011) (Quintero, 2010) (Calderón, Zapata y Ovalle, 2007) (Mukherjee, Kundu y Das, 2021) (Raza et al., 2020) (Al-Mtawa, Haque y Halabi, 2022) (Ferreira et al., 2016) (Prasad, Belwin Edward y Ravi, 2018) (Vatsa y Hati, 2022) (Meng y Jingyi, 2020)

El presente artículo tiene como objetivo exponer el trabajo conjunto realizado por el equipo de análisis de datos la Universidad Nacional de Colombia en cabeza del Grupo T&T y el equipo experto en el análisis de eventos eléctricos perteneciente al área de Dirección Operación de ISA Intercolombia S.A. E.S.P., para viabilizar la implementación de algoritmos de IA para la detección de diferentes tipos de fallas en el sistema eléctrico.

Este desarrollo, se complementa con un sistema experto y permite mejorar los resultados del sistema de diagnóstico actual empleado por la empresa. Un factor diferencial en este proceso es la inclusión de análisis de fallas en líneas de transmisión y subtransmisión con niveles de tensión de 66 kV, 115 kV, 230 kV y 500 kV.

2. Antecedentes

El diagnóstico de fallas es necesario para mantener el sistema eléctrico de potencia operando de forma segura (Sevcik y Lunsford, 2007), (Musaruddin y Zivanovic, 2009a). En tal sentido, se han realizado estudios para desarrollar métodos de identificación de fallas en el sistema eléctrico, los cuales tienden a implementar sistemas expertos para mejorar su eficacia (Musaruddin y Zivanovic, 2009a). Los estudios analizados buscan métodos para identificar y atender fallas específicas dentro del sistema (Ibrahim 2012).

La empresa ISA INTERCOLOMBIA cuenta con un sistema de diagnóstico automático de eventos en líneas de transmisión, llamado DAE, que es el resultado de un trabajo conjunto con el Grupo T&T de la Universidad Nacional de Colombia desde el año 2010. Dicho sistema realiza un análisis de las señales analógicas y digitales asociadas a las líneas de transmisión del sistema eléctrico, apoyándose en los registros de eventos de fallas generados como archivos COMTRADE, para obtener un diagnóstico de estas en los diferentes tramos de la red. Esto se complementa al contrastarse con información tomada del SOE (Secuencia de Eventos) del sistema SCADA.

Para el análisis analógico del DAE se entrenó una red neuronal que procesa las señales de corriente y voltaje y arroja un resultado de tipo de falla; es decir, recorre toda la señal en un tramo de estudio y verifica en que parte del tramo se encuentra una perturbación que se interpreta como una falla en una fase o más fases específicas.

Con respecto a las señales digitales, el sistema hace un análisis de la señalización asociada a arranques y disparos que se generan a partir de las fallas, teniendo en cuenta las aperturas y recierres en las fases o polos como respuesta a las fallas monofásicas, bifásicas o trifásicas en las líneas de transmisión.

Finalmente, se correlaciona el comportamiento de señales analógicas y digitales provenientes de las diferentes fuentes, para obtener un análisis del comportamiento del sistema y emitir el diagnóstico correspondiente al evento.

El DAE de líneas es un sistema robusto que cuenta con una precisión en su diagnóstico de alrededor del 90%. Sin embargo, dicho sistema tiene algunas desventajas que son la motivación para realizar modificaciones en el mismo. Las desventajas actuales del sistema de DAE para líneas son:

- El DAE de líneas requiere actualizaciones acordes a la operación del sistema eléctrico, sin embargo, para dicho software no se cuenta con la documentación necesaria para su completo entendimiento, limitando la intervención en el programa.

- El modelo de la red neuronal del DAE no cuenta con documentación de las variables utilizadas para el entrenamiento, lo cual restringe el reentrenamiento del modelo para su mejora y actualización.
- El diagnóstico de DAE solo se tuvo en cuenta para casos específicos de eventos con valores de tensión entre 230 kV siendo posible obtener buenos resultados en líneas con dichos niveles de tensión (en algunos casos también 500 kV). Sin embargo, para diferentes valores de tensión (115kV, 110kV, 66kV y menores), el modelo de la red neuronal no está entrenado, por lo cual no es preciso y su respuesta no es confiable.

Por ende, en el presente documento se expone el proceso de mejora a partir de la estandarización de los datos, el desarrollo de modelos y su validación; para obtener un sistema de diagnóstico de eventos que garantice una aplicación más amplia en líneas de transmisión con diferentes niveles de tensión y con alto grado de confiabilidad en sus resultados.

Antecedentes Diagnóstico Automático de Eventos - DAE

Como punto de referencia sobre el diagnóstico de eventos y el estudio preliminar que dio lugar al desarrollo que aquí se expone, se toma la experiencia de Leonardo Vásquez Ruiz, Adrián Santiago Arboleda y Germán Zapata Madrigal en (Vásquez, Arboleda y Zapata, 2011), donde plantean la complejidad de los sistemas de transmisión de energía como factor clave en la implementación de un sistema de diagnóstico automático de fallas con el fin de priorizar el análisis y restablecimiento del sistema eléctrico.

El estudio aborda el problema tomando como eje los conceptos de agente y sistema Multiagente, como parte de la inteligencia artificial distribuida (IAD). Se destacan algunas ventajas de los Multiagentes como son, el paralelismo y coordinación de agentes para mejorar la eficiencia, la Independencia, autonomía para el manejo de problemas de comunicaciones intermitentes y la modularidad y extensibilidad, para darle flexibilidad en la adición de nuevas fuentes de información, herramientas de análisis y actualización del conocimiento.

En el trabajo, se plantean modelos Multiagente y modelos de Lenguaje Unificado de Modelado (UML) para la construcción de un prototipo de diagnóstico de fallas en sistemas de transmisión de energía eléctrica. Estos modelos consideran el carácter distribuido de la información, la calidad de las fuentes y los sistemas de procesamiento de tales fuentes.

En (Vásquez, 2010), se aborda el problema del Diagnóstico Automático de Fallas en Sistemas de Transmisión de Energía, desde la óptica de los sistemas distribuidos y el manejo de la gran cantidad de información que puede resultar en el momento de la ocurrencia del evento.

Se plantea un sistema híbrido que aprovecha, de un lado, las ventajas de los Sistemas Multi-agente y por otro lado, el uso de técnicas de inteligencia artificial basadas en lógica difusa para lidiar con la incertidumbre debida al manejo de información inconsistente o incompleta (Vásquez, 2010).

A su vez, se describe en detalle el proceso de diagnóstico de fallas y cada una de sus etapas, asociando a estas una estructura de agentes, siendo así más funcional. Se reconocen además los diferentes niveles del proceso, teniendo en los niveles más bajos un análisis de la información en la fuente y suministrando resultados parciales a los niveles superiores, para realizar la integración y facilitar la elaboración de un diagnóstico más preciso (Vásquez, 2010).

A partir de esto, se obtiene mayor velocidad en el diagnóstico empleando las ventajas del procesamiento paralelo. El documento destaca que la solución de diagnóstico automático puede ser una ayuda para la toma de decisiones en tiempo real, a partir del procesamiento y análisis en línea de la información recolectada (Vásquez, 2010).

Lo hecho por L. Vasquez, complementa los estudios realizados por Luis Everley Llano Z. quien en (LLano, Zapata y Ovalle, 2007), aborda la identificación en tiempo real de eventos de falla en sistemas eléctricos con registro SOE, a partir del modelamiento y validación de un sistema de inferencia difuso.

EL objetivo fundamental del proceso fue la detección del inicio del evento y la información relevante asociada a este. El conjunto de

reglas contempladas para el modelo de análisis se construye a partir del conocimiento del experto, definiendo la relación esperada para la combinación de los posibles estados de las variables lingüísticas de entrada, tales como: “cantidad de señales SOE”, “tiempo promedio entre señales”, “tipo de señal SOE”, etc. Las pruebas contemplaron un conjunto con más de mil señales asociadas a registros SOE reales, obteniendo resultados exitosos (LLano, Zapata y Ovalle, 2007).

Este autor, aborda también la identificación de eventos de fallas a partir de la combinación de herramientas de inteligencia artificial, exponiendo en (Zuleta, Madrigal y Carranza, 2007) un sistema híbrido que combina inferencia difusa con un sistema experto basado en redes de Petri coloreadas. A partir de esto, se realiza un filtrado de información no útil, identificación de eventos de falla y estableciendo automáticamente el estado de los componentes del sistema eléctrico en la prefalla. El sistema fue probado con un conjunto elevado de registros de SOE con múltiples señales y tuvo resultados exitosos, según lo esperado por el autor.

Por su parte, (Calderón, 2007) plantea la relevancia de los archivos de registro de osciloperturbografía (Comtrade) que se obtienen a partir de la ocurrencia de una falla en el sistema. Se destaca en este estudio la importancia de comprender y analizar dichos registros, partiendo del hecho que no es posible tener dos registros de falla idénticos, aun cuando las características del evento sean similares.

En dicho estudio se plantea la necesidad de usar modelos inteligentes y adaptativos, que aprendan de las experiencias para mejorar su desempeño en el tiempo y se adapten a las condiciones exigidas por un SEP real. En tal sentido, se evalúa un Modelo Adaptativo de Inteligencia Artificial (MAIA), una Metodología de Entrenamiento y Validación Adaptativa (MEVA) y un Sistema Basado en Conocimiento (SBC) para el proceso de diagnóstico de eventos. Finalmente, el conjunto MAIA + SBC se entrena y valida a partir de MEVA, utilizando 46996 casos simulados y 3600 registros reales.

El mismo autor aborda en (Calderón, Cadavid y Ovalle, 2008) un proceso de clasificación de fallas en líneas de transmisión de energía eléctrica utilizando redes neuronales, tomando como

referencia el análisis de los registros de oscilopertugraffías. Este estudio es fundamental en el proceso de desarrollo de DAE adelantado por la empresa.

En este proceso de análisis y detección de eventos, es fundamental la fuente de información empleada, por ende, se destaca el aporte de Luz Inés Hincapié, quien expone en (Inés et al., 2011) el desarrollo de un controlador para automatizar el proceso de descarga de eventos, tomando como base el uso del estándar IEC 61850, implementado en Dispositivos Electrónicos Inteligentes (IEDs) que son la evolución de los relés convencionales.

Este proceso, permite extraer fuentes de información de dispositivos independiente del proveedor o referencia de equipo, con lo cual se consolida un insumo base para el análisis y diagnóstico de eventos y es el referente para lo que hace actualmente el Sistema Automático de Gestión de Equipos de Subestaciones (SAGES) en la empresa.

Analítica de datos y sistemas experto

Para el diagnóstico de eventos en sistemas eléctricos se ha abordado Deep Learning con computación cuántica, como es el caso de (Ajagekar y You, 2021), donde se combinan estas técnicas basándose en control de calidad para dicho proceso de diagnóstico. A partir de la estrategia de análisis planteada se identifican importantes desafíos de computación superados a partir de metodologías de capacitación basadas en control de calidad.

Los autores, utilizan como referencia un sistema simulado de 30 barras y una cantidad considerable de eventos de falla en subestaciones y líneas de transmisión, que permiten validar la aplicabilidad y eficiencia del modelo de análisis. Se logra un diagnóstico de fallas confiable y con tiempos de respuesta reducidos a través de métodos de reconocimiento de patrones de última generación basados en redes neuronales artificiales (ANN) y arboles de decisión (DT) (Ajagekar y You, 2021).

Análisis mediante máquinas de soporte vectorial (SVM) se implementan en (Parikh, Das y Maheshwari, 2010) para la clasificación de fallas en líneas de transmisión compensadas en serie.

Para tal fin, el modelo utiliza las muestras de un ciclo (de duración) de tres corrientes de línea y corriente de secuencia cero, como características fundamentales en SVM para la clasificación de errores.

La validación del algoritmo se realiza con una línea de transmisión (300 Km/400Kv) mediante simulación digital con un conjunto de datos de 25200 casos de prueba con compensación, considerando 10 tipos de falla con diferentes niveles de resistencia, ángulo de inicio y posiciones de la falla. Se destaca la rapidez de la técnica empleada, la precisión y su robustez considerando la amplia variación en el sistema y las condiciones de falla (Parikh, Das y Maheshwari, 2010).

Este tipo de soluciones buscan detectar, clasificar y localizar las fallas, en las líneas de transmisión, equipos inductivos y demás elementos de la infraestructura eléctrica. El sistema implementa métodos de inteligencia artificial y procesamiento de datos en todos los estudios.

Por su parte, los sistemas expertos han permitido una mayor velocidad de respuesta de los operarios para restablecer el flujo eléctrico en los lugares donde se han implementado (Kezunovic, 2000).

Las herramientas más relevantes en los estudios son: método de aprendizaje profundo como las redes neuronales, árboles de probabilidad, la transformada wavelet discreta (DWT), algoritmos genéticos. Los datos usados para desarrollar el sistema experto varían según el enfoque de cada estudio.

En (Vaschetti, Magnago y Sauchelli, 2012), se busca el perfil de tensiones y la minimización de pérdidas incluyendo el rechazo de carga cuando es necesario. Se utilizan los conceptos de nodo piloto, sistema experto basado en reglas y flujo óptimo de potencia (OPF). Además de un algoritmo genético, las herramientas implementadas usadas son: CLIPS y MATLAB.

Por su parte, (Aizpurua, 2010) propone el desarrollo de un ente integrador de diversas técnicas disponibles en la gestión de alarmas masivas en los centros de control y despacho de energía eléctrica, con el fin de encontrar la causa raíz de la avalancha de alarmas (árbol de alarmas) y reducir la cantidad de ellas utilizando técnicas

de asociación o agrupamiento cumpliendo con los estándares establecidos por la norma EEMUA.

En este tipo de estudios se encuentran casos donde se implementan sistemas expertos basados en reglas (JESS Eclipse), sistemas neuro-difusos, ontología, Red Neuronal Hebbiana, Grafos de Vínculo (Bonclin), Mapa Cognitivo difuso (FCM), y árbol de alarmas.

Estudios complementarios para el análisis de fallas

Actualmente se emplean muchas técnicas de analítica las cuales se complementan entre ellas para arrojar resultados más precisos, particularmente orientados a aplicaciones en el sector eléctrico, que van desde los sistemas de almacenamiento de energía con baterías, vehículos eléctricos y para análisis de estabilidad en sistemas de potencia, entre otros (Benner y Russell, 2009), (Lin et al., 2020) (Deshmukh, Glicksman y Norford , 2018) (Wang, Zhang y Hu, 2021) (Ghadiri, 2016) (Fuente y Represa, 1997) (Li, Frey y Gauterin, 2023) (Moseler, Heller y Isermann, 1999).

Sin embargo, se evidencia que, en el caso particular de diagnóstico automático de eventos, a partir de los archivos comtrade o registros de fallas, la información disponible es limitada.

El enfoque que se ha tenido en los procesos de análisis generalmente tiene como premisa el análisis preventivo en procesos de planificación. El análisis correctivo, tiene como objetivo la adecuación del sistema para mitigar el impacto del evento y prevenir futuras ocurrencias (Gómez-Ramírez, 2016) (Ortiz y Salazar, 2020); por ende, es común que en la bibliografía no se realicen reportes de diagnóstico, sino que se evalúan estrategias de mejora.

La inclusión de las redes inteligentes y con ellas las subestaciones digitales, da lugar a tener un foco en el análisis de fallas referidas al reporte de estados de variables propias del sistema secundario en las subestaciones eléctricas (Yan-Zhang et al., 2012).

Ejemplo de esto es (Wen y Qing, 2021), donde se presenta un modelo de diagnóstico de fallas de una subestación basado en el algoritmo de crecimiento FP. Aquí se extraen datos de fallas del sistema secundario, analizando las causas de estas y las reglas de

asociación, derivando en la base de referencia y las sugerencias para el personal de mantenimiento y operación.

Un método de diagnóstico de fallas basado en un algoritmo bayesiano ajustado para mejorar la precisión y eficiencia de mantenimiento del diagnóstico desde el lado secundario (protección y control) en una subestación digital o inteligente, es propuesto en (Zong et al., 2020). El método puede determinar el rango de falla y especificar los elementos de falla, en contraste con el método común de diagnóstico para estos sistemas usado actualmente, que se limita a determinar el rango de falla.

Con el fin de mejorar aún más la eficacia y la exhaustividad del diagnóstico de fallas de las subestaciones, (Zhao, Wang y Song, 2019) propone un método de diagnóstico de fallas, usando de manera efectiva el sistema secundario de monitoreo de la información de alarmas en línea. El modelo de similitud de texto se usa para eliminar la información de fallas recurrentes, extraer de manera efectiva la información de fallas críticas necesaria para el diagnóstico del sistema y clasificar la información de fallas del sistema secundario; mejorando así, la eficiencia del sistema inteligente de diagnóstico de fallas de la subestación.

En (Lin et al., 2019), se propone un método de diagnóstico de fallas utilizando señales de alarma analizadas en la subestación. Los métodos de diagnóstico de fallas en subestaciones incluyen principalmente redes neuronales artificiales, teoría difusa, sistemas expertos y teoría de conjuntos aproximados. Para reducir la cantidad de procesamiento de la señal, las señales repetidas se combinan y se eliminan las señales de fluctuación. La información clave, como el equipo y el comportamiento, se combina con la señal de texto para formar una tabla de información de la señal.

En las subestaciones inteligentes se genera una gran cantidad de datos y señales de alarma además de la aleatoriedad de las fallas, haciendo complejo el análisis de datos para su diagnóstico y ubicación, lo cual es tomado como motivación en (Lima et al., 2011). Aquí, se propone un método inteligente de diagnóstico de fallas en subestaciones basado en modelos de SVM de optimización,

exponiendo su aplicación para el diagnóstico de fallas, método que no se explica en muchos documentos.

A partir de la experiencia evidenciada en la bibliografía, en conjunto con los antecedentes de DAE en la empresa, se establece una metodología para el desarrollo de la herramienta de diagnóstico de eventos mejorada.

3. Metodología

El proceso para mejora del sistema DAE, parte de un análisis y documentación del sistema actual empleado por la empresa para el diagnóstico automático de eventos. A partir de aquí, se establecen pautas a seguir y estrategias de mejora para dicha herramienta.

Uno de los focos principales de este estudio, es ampliar la capacidad de análisis y diagnóstico de eventos para fallas asociados a líneas de transmisión con diferentes niveles de tensión, que van desde los 34.5 kV hasta los 500 kV.

Buscando modelos que puedan diagnosticar la falla, el tipo y la ubicación de estas, se han realizado simulaciones de un amplio espectro de varios tipos fallas, localizaciones, diferentes impedancias, ubicaciones adelante y atrás, fallas durante un polo abierto (fallas durante tiempos muertos de recierre monopolar), configuraciones topológicas enmalladas, radiales, etc., que pueden presentarse en las líneas de transmisión. Estas simulaciones en conjunto con los casos reales, son las que componen las bases de datos necesarias para el entrenamiento de diferentes modelos de Inteligencia Artificial.

Objetivo del diagnóstico de eventos (fallas):

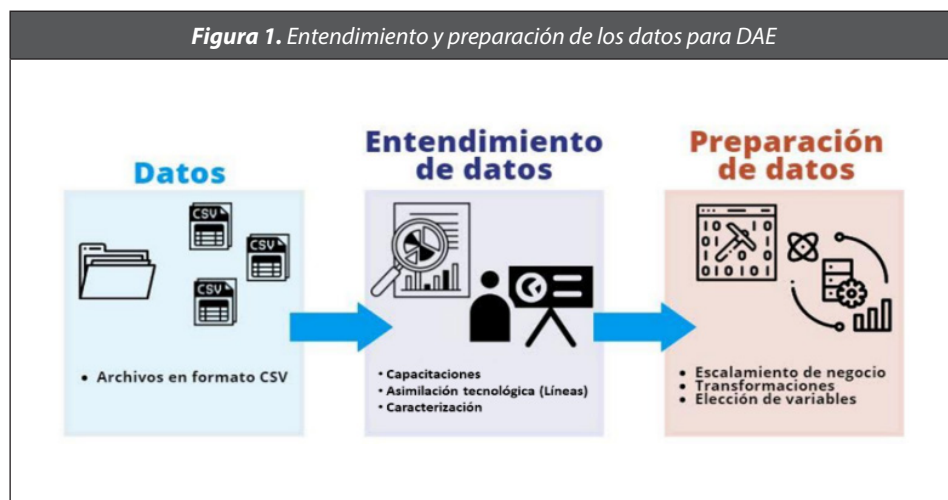
- Determinar el tipo de falla
 - AG, BG, CG, etc
 - Nivel de impedancia (baja, media, alta, muy alta)
- Determinación del elemento fallado y su ubicación
 - Línea 34.5 kv
 - Línea 66 kv

- Línea 115 kv
- Línea 230 kv
- Línea 500 kv
- Localización de la falla
 - Falla adelante
 - Falla atrás
- Análisis de operación de dispositivos de protección:
 - Operó y debió haber operado
 - Operó y no debió haber operado
 - No operó y debió haber operado
- Análisis de operación dispositivos de maniobra:
 - Abrió y debió haber abierto
 - Abrió y no debió haber abierto
 - No abrió y debió haber abierto

Para tal fin, se plantea una metodología de diagnóstico basada en la revisión, validación y documentación de la información suministrada por la empresa, siguiendo el esquema expuesto a continuación:

Entendimiento de la información suministrada

Esta etapa comprende la revisión minuciosa de los datos e información complementaria disponible, como archivos de código, conjuntos de datos simulados, etc. para el proceso de análisis y diagnóstico de eventos en líneas de transmisión.



Para garantizar un adecuado proceso en el análisis y diagnóstico de eventos, es fundamental el entendimiento de los datos, razón por la cual, esta etapa se ha dividido en dos componentes.

4. Diagnóstico

- *Revisión:* En esta fase se identifican: Tipos y calidad de datos, registros de eventos reales, eventos simulados, resultados de análisis, etc. Obteniendo como resultado:

Datos para entrenamiento: Datos correspondientes a simulaciones de eventos o datos sintéticos y un conjunto de datos reales para el perfeccionamiento de modelos

Datos para pruebas: Registros de eventos simulados y reales en la infraestructura de la empresa

Códigos para entrenamiento: Selección de variables de entrada y salida de algoritmos. Se revisaron librerías utilizadas previamente, técnicas de muestreo y algoritmos empleados.

Códigos para pruebas: Se revisaron librerías, técnicas de evaluación de los algoritmos entrenados anteriormente.

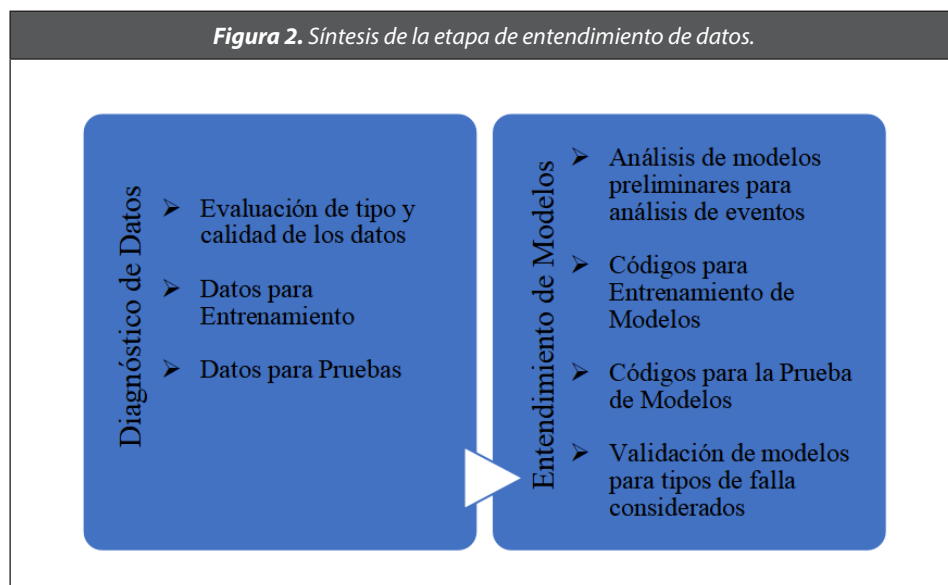
- *Documentación:* Se registran los hallazgos y resultados obtenidos en el diagnóstico de los datos e información de referencia para el análisis y diagnóstico de eventos

Entendimiento de modelos

Consiste en la evaluación de los códigos iniciales desarrollados para los modelos de análisis y diagnóstico de fallas en líneas de transmisión de trabajos realizados al interior de la empresa. Se complementa con una validación de los modelos, a partir de la revisión de los archivos de códigos y sus derivados.

- *Revisión y análisis de Códigos para el entrenamiento de modelos:* se identifican los modelos de análisis y algoritmos de aprendizaje automático (RF, SVM, MLP, etc.) empleadas para el análisis, al igual que las herramientas de programación utilizadas. Se destaca el buen desempeño de MLP0, por lo cual será tenido como referencia en los procesos de validación posteriores.
- *Diagnósticos de modelos según los tipos de falla:* Se valida el correcto uso de variables y se analizan los modelos para eventos de falla en líneas de transmisión clasificados como fallas con polos cerrados y fallas con un polo abierto, aplicados a diferentes niveles de tensión (66 kV a 500 kV).
- *Validación de modelos según el tipo de falla:* Se ejecutan los códigos para identificar posibles errores de programación y tomar las correcciones necesarias para su correcta evaluación. Se identifica el balanceo de los datos y las métricas de aceptación de los modelos
- *Códigos para pruebas de modelos:* Se desarrolla y emplea un entorno de pruebas para la ejecución de scripts de prueba y la evaluación de los modelos de análisis con los diferentes tipos de fallas establecidos, asociados a las líneas de transmisión de energía eléctrica.
- *Pruebas de los modelos con los diferentes tipos de fallas consideradas:* Se obtienen resultados preliminares del proceso de análisis, que permiten evaluar diferencias entre modelos y posibles falencias en torno al uso de datos, modelos de analítica y resultados de diagnóstico.

Lo expuesto en el proceso de entendimiento de los datos puede sintetizarse cómo se presenta en la Figura 2.



Preparación de los Datos

Para una correcta implementación de códigos y garantizar un óptimo análisis y diagnóstico para eventos de falla en líneas de transmisión, se debe garantizar que las fuentes de información son óptimas para un correcto entrenamiento y validación de modelos.

En este proceso se cuentan con tres fuentes de información, como son los resultados de simulaciones de fallas en líneas de transmisión cuando los tres polos están cerrados, datos de simulaciones considerando uno de los tres polos abiertos y una recopilación de los eventos que se han presentado en la compañía en los últimos años.

- Datos simulados: 33840 registros (2304 fallas de polo abierto y 31536 fallas de polo cerrado), con 69 variables (magnitudes y ángulos de voltaje, magnitudes y ángulos de corriente, nivel de tensión, tipo y ubicación de la falla, etc.)
- Datos reales: 7039 registros con 13 variables (Código de ocurrencia del evento, Magnitud de corriente para cada fase en kA, Magnitud de corriente de neutro en kA, Magnitud de voltaje para cada fase en kV, Nivel de tensión, Fase afectada (A, B, C, N)).

En cada caso, se presentan características diferentes relacionadas con la cantidad de casos por fallas, niveles de tensión y ubicación de las fallas, entre otros. Por lo cual, es fundamental identificar la fuente y los tipos de ajuste que se deben realizar en cada conjunto de datos a utilizarse.

Por ende, se realizan una serie de ajustes en aras de garantizar un mayor volumen de datos reales y un balanceo de estos, como preparación de los datos para la elaboración de modelos de IA para el diagnóstico de eventos enfocados en líneas de transmisión.

En esta etapa se destacan las siguientes actividades:

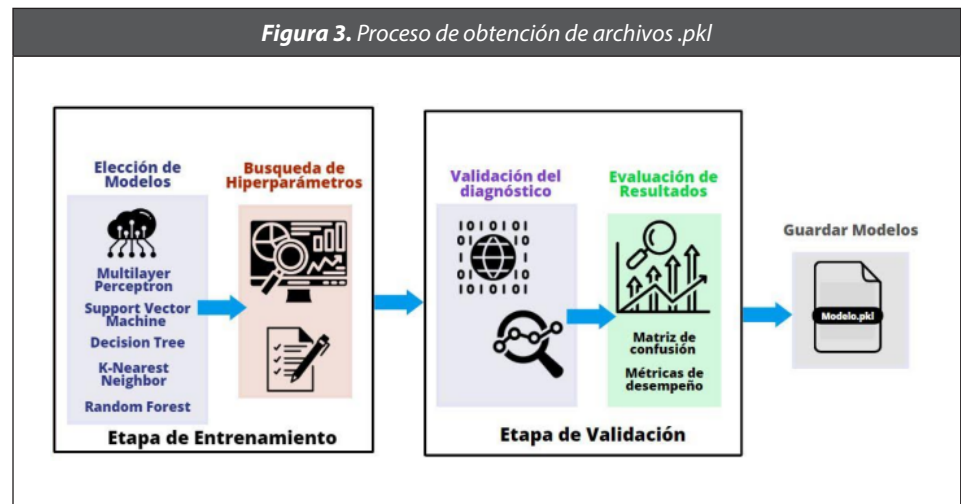
- **Importación de librerías:** librerías necesarias para la ejecución de las líneas de código que permiten una adecuada actuación de modelos y entendimiento de los datos.
- **Funciones propias:** se establece un conjunto de funciones dentro del código, para garantizar un orden y fácil comprensión de este, en conjunto con los datos utilizados. Algunas de las funciones utilizadas son:
 - *Split:* balanceo de clases y número de casos a considerar para cada tipo de falla.
 - *Matriz de confusión:* evaluar los modelos de detección de tipo de falla y analizar el desempeño del modelo en cada variable de salida.
 - *Codificación de la variable de salida de los modelos de tipo de falla:* traducir las predicciones de los modelos de tipo de falla, que vienen codificadas en cuatro variables binarias (A, B, C, G), en una sola que las integre.
 - *Codificación de los modelos de ubicación:* traducir las predicciones de los modelos de detección de ubicación de la falla.
- **Lectura de dataset:** se leen los archivos de entrenamiento, los cuales deben de estar en formato CSV.

- Acondicionamiento de datos reales: llevar los datos a los valores de negocio, eliminar registros duplicados, generar las variables de salida de los modelos de detección de falla y detección de tipo, al igual que llevarlos a una estructura para ser concatenados con los datos simulados después de transformarlos.
- Acondicionamiento de datos simulados: Ajuste de los datos para estandarización en número de variables (eliminación), valores por unidad de corriente y voltaje, niveles de tensión, tipos de falla, etc.
- Definición de dataset: definir el conjunto de datos para la etapa de detección de falla, detección de tipo y detección de ubicación, a partir de variables explicativas, variables de salida y variables de seguimiento.
- Preprocesamiento de datos: verificar que los datos considerados sean los adecuados para el entrenamiento de los modelos.
 - Se valida que no se presenten registros nulos y que los valores de cada variable permanezcan en rangos aceptables, con el apoyo de Dirección Operación de la empresa.
 - Se realiza un análisis estadístico a partir de la matriz de correlación con el objetivo de verificar que las variables consideradas no se encuentren correlacionadas (evita sesgo en los modelos).
 - Se continúa con la estandarización de las variables explicativas para llevar todos los valores a una misma escala y de esta manera prevenir que los algoritmos se confundan con las magnitudes de una u otra variable.
 - Se finaliza con el balanceo de las clases de la variable de salida de cada etapa del análisis. Este proceso debe considerar las variables de seguimiento para que el conjunto de datos de entrenamiento sea lo más generalizable posible.

Elaboración de Modelos

En esta etapa se busca la obtención de los archivos .pkl de los modelos, donde se parte del entrenamiento de algoritmos de aprendizaje de máquinas para la obtención de los mejores hiperparámetros determinados a partir de una métrica de

desempeño para estos. Posteriormente, con las variables de entrada y salida establecidas, se determina el desempeño de los modelos en los entrenamientos. El proceso realizado en esta etapa se expone en la Figura 3.



Los algoritmos de analítica empleados son:

- Multilayer Perceptron (MLP): el perceptrón o red neuronal artificial, tiene una arquitectura completamente conectada, que permite encontrar relaciones complejas entre los datos seleccionados (Bisong, 2019). Al ser el único modelo de aprendizaje profundo utilizado para este fin, puede ser mucho más adaptable para los casos donde se maneja gran cantidad de datos, pero a su vez más propenso al sobre entrenamiento.
- Support Vector Machine (SVM): toma los datos y los proyecta en una dimensión mayor con la implementación de una función o kernel, dimensión en la cual los datos puedan ser separables linealmente (Sánchez-Anzola, 2016). Una ventaja de dicho modelo es que puede utilizarse con una cantidad limitada de datos obteniendo un algoritmo con alta capacidad de generalización. Una desventaja de dicho modelo al trabajar con grandes dimensiones es el alto tiempo de entrenamiento que requiere.
- Decision Tree (DT): funciona a partir de observaciones y construcciones lógicas como un sistema basado en reglas, y se representa como un árbol con nodos, ramificaciones y hojas

(Barrientos, Cruz y Acosta, 2009). Cada variable de entrenamiento se analiza para encontrar la importancia del atributo en la clasificación. Este método tiene varias ventajas: en principio, tiene buen desempeño independiente de la cantidad de datos, y por utilizar reglas lógicas su entrenamiento es poco costoso y veloz, así como la inferencia. Sin embargo, su representación visual puede llegar a ser dispendiosa cuando se tiene una gran cantidad de variables.

- K-Nearest Neighbor (KNN): paradigma de clasificación en el cual se establecen centroides de forma aleatoria en los espacios de datos con el objetivo de abarcar una cantidad de datos o vecinos que se presume pertenecen a una clase u otra. El centroide se mueve a medida que encuentra mayor densidad de una clase en particular (Moujahid, Inza y Larrañaga, 2008). Este método funciona mejor con cantidades limitadas de datos, puesto que el cálculo de las distancias puede requerir mayor procesamiento para grandes dimensiones.
- Random Forest (RF): consiste en la creación de un bosque a partir de la combinación de varios árboles de decisión de manera aleatoria (Biau y Scornet, 2016), se puede considerar un método de ensamble, puesto que toma los promedios de clasificación de los árboles y hace ensambles de los mismos buscando los mejores resultados. Al igual que el árbol de decisión suele ser muy rápido además de solucionar problemas más complejos.

En el diagnóstico de fallas los pronósticos erróneos pueden tener implicaciones en dos sentidos. Los falsos positivos pueden significar un costo de operación al generarse una falsa alarma, sin embargo, su impacto es mucho menor que el de una falla no detectada (falso negativo), puesto que la no detección de la falla puede conllevar a ignorar un problema en líneas de transmisión, y que éste no sea corregido a tiempo, generando un problema mayor.

Por ende, las métricas de desempeño utilizadas deben tener información de las tasas de falsos positivos y negativos, así como métricas de exactitud, precisión entre otras para garantizar el buen comportamiento de los modelos entrenados.

En tal sentido, las métricas de desempeño consideradas en este proceso son: Accuracy, Precision, Recall, F1 Score, False Positive Rate Y False Negative Rate.

Para el caso de pronóstico de fallas, al ser un problema de clasificación binaria, pueden aplicarse las siguientes métricas: ROC curve, PRECISION- RECALL curve.

En los casos de entrenamiento se utilizó el método de validación cruzada, el cual consiste en dividir todo el conjunto de entrenamiento en partes iguales, realizando un número de iteraciones igual al número de divisiones, con el objetivo de rotar los datos de entrenamiento y evaluación. El resultado en las métricas es el promedio de los resultados de cada iteración.

Dicha técnica resulta útil a su vez, al momento de identificar y seleccionar los mejores hiperparámetros, complementándose con la técnica de búsqueda en malla.

Posteriormente, tras revisar los resultados de evaluación de modelos, se procede a almacenar los archivos .pkl que serán utilizados posteriormente en la etapa de pruebas para verificar su desempeño ante datos reales.

Validación

Para el proceso de validación y la comparación con los nuevos modelos desarrollados para análisis y diagnóstico de líneas, se utilizan 104 archivos comtrade de casos reales de fallas en líneas de transmisión. Los casos empleados son seleccionados con diferentes características como tipo de falla, localización, impedancia, secuencias de fallas, niveles de tensión y ubicación.

En principio, se requiere superar un requisito de normalización de nomenclatura en los archivos, para proceder a identificar y caracterizar la arquitectura de DAE original, siendo este el punto de referencia para la validación de los resultados con los nuevos modelos de análisis, partiendo de la alta eficacia en los análisis obtenidos con la herramienta DAE inicial.

Se identifica una función clave dentro del código de DAE, donde se lleva a cabo el análisis utilizando una red neuronal. Aquí es donde

se aplican algoritmos específicos para extraer características y patrones relevantes de los datos. Este análisis es crucial para obtener resultados precisos y significativos de diagnóstico de eventos con los datos analógicos.

Adicionalmente, se identifican los parámetros y funciones en el código inicial para llamar los resultados a partir de la red neuronal empleada, destacándose la obtención de los siguientes resultados para cada evento: tiempo inicial, tiempo final, resultado de análisis de identificación – predicción y fase afectada

Posteriormente, se identifica la estructura utilizada para el almacenamiento de resultados en el proceso de análisis, lo cual, es parte fundamental en el proceso de validación para identificar las modificaciones necesarias en el desarrollo expuesto y validar de manera clara y precisa los resultados con el DAE inicial y los nuevos modelos de análisis.

Se realizan los ajustes necesarios en el nuevo desarrollo, con el fin de hacer coincidir los atributos de análisis y atributos salida que garanticen una adecuada comparación de resultados.

Finalmente, para obtener los resultados de la evaluación de los modelos para fallas en líneas se toman como referencia las fuentes de información preparadas en el ajuste de archivos.

Una vez realizados los modelos y evaluada su eficacia en el análisis de eventos de falla, se contrastan estos resultados con aquellos obtenidos al emplear la herramienta de DAE actual de la empresa con los correspondientes eventos de falla. La evaluación incluye un proceso iterativo, que comprendió un reentrenamiento de los modelos, con filtrado y balanceo de datos, contemplando una limpieza de estos, con el fin de evitar sensibilidad en los modelos.


En este punto, cabe recalcar que el DAE actual está diseñado para operar con una alta eficacia en el análisis de fallas para líneas de 220 kV y 500 kV; sin embargo, el conjunto de datos para pruebas incluye fallas en líneas con otros niveles de tensión.

Tabla 1. Comparativo entre características de análisis para DAE actual y el nuevo modelo de análisis para mejora de DAE.

Concepto	Modelo DAE actual	Modelo nuevo
Entrenado con niveles de tensión	230kV y 500kV	34.5kV, 66kV, 110kV, 115kV, 220kV, 230kV, 500kV
Modelo	Red Neuronal (MLP)	MLPO, MLP, SVM, DT, KNN, RF
Fallas que detecta	Solo fallas internas (Adelante)	Fallas internas y externas (Adelante y Atrás)

A continuación, se presentan la Figura 4, en la que se expone el ejemplo de una falla utilizada para evaluar la predicción con cada tipo de modelo, considerando la detección de falla, tipo y ubicación. Las señales de la parte superior son de corriente vs el tiempo, mientras que las de la parte inferior exponen el comportamiento de voltaje vs el tiempo. Las dos graficas incluyen el comportamiento de las tres fases con sus colores (Fase A: rojo, fase B: verde, fase C: azul). En el caso particular, se evidencia una falla en la fase B.

Figura 4. Ejemplo - Falla utilizada para el análisis de los modelos de predicción



A continuación, se exponen los resultados con la implementación de los modelos de analítica de datos seleccionados previamente y su respuesta ante diferentes tipos de señales de falla en líneas de transmisión con diferentes características.

5. Resultados

Para el entrenamiento de los modelos, se cuenta con tres conjuntos de datos que pueden verse en la Tabla 2. Estos conjuntos de datos han sido desarrollados y elegidos por constituir fallas de diferente naturaleza, niveles de tensión y situaciones especiales que son consideradas importantes para el análisis de fallas en líneas de transmisión.

Tabla 2. Conjuntos de datos utilizados para la fase de entrenamiento

Origen	Naturaleza	Niveles de tensión (kV)	Tamaño
Simulados ATP	Polos cerrados	66, 115, 230, 500	31.536 registros, 69 atributos
Simulados ATP	Polos abiertos	66, 115, 230, 500	2304 registros, 69 atributos
Reales	Polos cerrados	13.8, 34.5, 66, 110, 220, 230 y 500	9.229 registros, 14 atributos

Resultados de entrenamiento

Para el proceso de entrenamiento y preparación de los modelos se utiliza la matriz de confusión para evaluar el desempeño general para detección de falla, identificación de tipo y ubicación de la falla, teniendo en cuenta las predicciones binarias, donde 0 indica no detección de falla y 1 indica detección de falla, al igual que métricas como accuracy, tasa de falsos positivos y tasa de falsos negativos para contrastar los resultados de los modelos.

De igual manera, para realizar un análisis más detallado sobre el desempeño de cada uno de los modelos asociados a diferentes variables objeto de análisis, se calcularon múltiples matrices de confusión enfocadas específicamente en la predicción de las fallas de polo abierto, polo cerrado, casos reales, falla interna, falla externa, fallas adelante y fallas atrás de manera separada.

Tabla 3. Resultados de entrenamiento para Detección de Falla en el modelo MLP

Matriz de confusión	Métricas									
<p>MLP model (General)</p> <table border="1"> <tr> <td>True label \ Predicted label</td> <td>0</td> <td>1</td> </tr> <tr> <td>0</td> <td>2631</td> <td>12</td> </tr> <tr> <td>1</td> <td>480</td> <td>59578</td> </tr> </table>	True label \ Predicted label	0	1	0	2631	12	1	480	59578	<p>Accuracy: 99%</p> <p>Tasa de falsos positivos: 0.02%</p> <p>Tasa de falsos negativos: x15.4%</p>
True label \ Predicted label	0	1								
0	2631	12								
1	480	59578								
<p>MLP model (Casos polo abierto)</p> <table border="1"> <tr> <td>True label \ Predicted label</td> <td>0</td> <td>1</td> </tr> <tr> <td>0</td> <td>2229</td> <td>10</td> </tr> <tr> <td>1</td> <td>9</td> <td>2529</td> </tr> </table>	True label \ Predicted label	0	1	0	2229	10	1	9	2529	<p>Accuracy: 99%</p> <p>Tasa de falsos positivos: 0.3%</p> <p>Tasa de falsos negativos: 0.4%</p>
True label \ Predicted label	0	1								
0	2229	10								
1	9	2529								
<p>MLP model (casos polos cerrados)</p> <table border="1"> <tr> <td>True label \ Predicted label</td> <td>0</td> <td>1</td> </tr> <tr> <td>0</td> <td>401</td> <td>2</td> </tr> <tr> <td>1</td> <td>465</td> <td>47541</td> </tr> </table>	True label \ Predicted label	0	1	0	401	2	1	465	47541	<p>Accuracy: 99%</p> <p>Tasa de falsos positivos: 0.0%</p> <p>Tasa de falsos negativos: 53.7%</p>
True label \ Predicted label	0	1								
0	401	2								
1	465	47541								

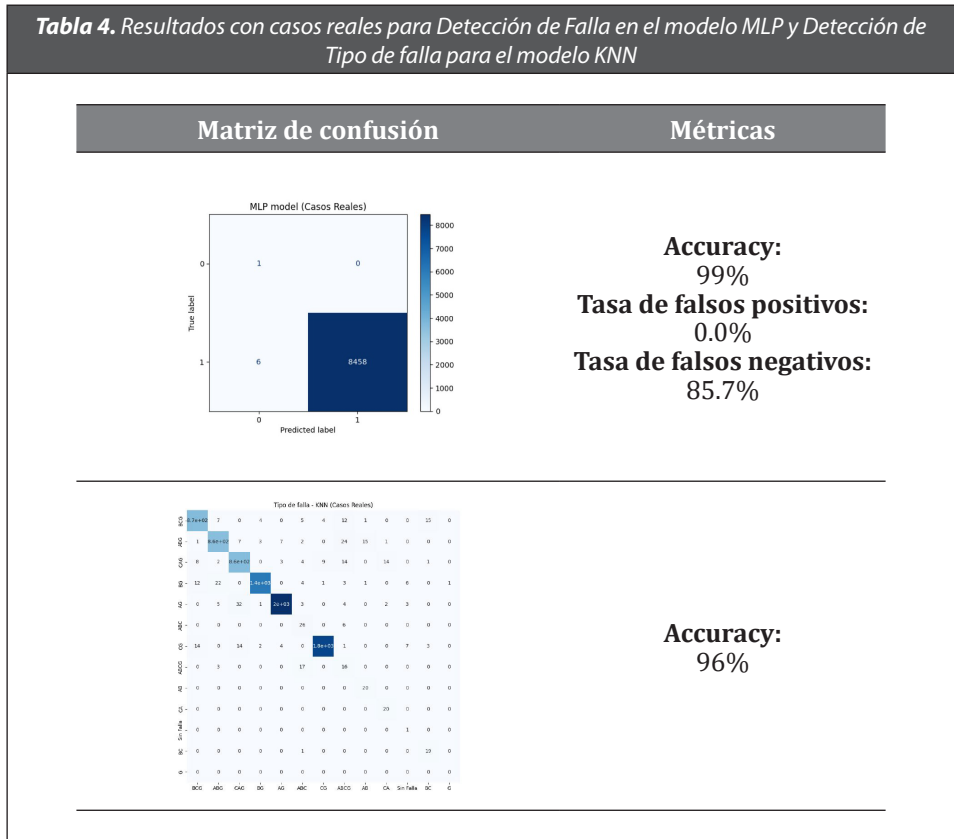
En la Tabla 3, se exponen los resultados obtenidos para el modelo MLP para el caso general y para los casos específicos de polos abiertos y polos cerrados, como puntos de referencia sobre el análisis realizado. El proceso de evaluación de los otros modelos se realizó de manera análoga.

Resultados de entrenamiento con casos reales

Como el proceso de evaluación y adecuación de los modelos también se realizó considerando casos reales obtenidos de los

registros de eventos en la empresa, a continuación, se exponen algunos de los resultados obtenidos en la evaluación de los modelos de entrenamiento con estos casos con MLP para detección de Falla y KNN para Detección de Tipo de falla a partir de las matrices de confusión.

De los resultados obtenidos con casos reales, se debe destacar que a nivel general los modelos entrenados para la detección de falla y tipo de falla presentan muy buenas predicciones, destacándose principalmente los modelos MLP y KNN.



Evaluación de los modelos entrenados

Luego de obtener los diferentes modelos entrenados, se desarrolló un entorno de pruebas que posibilita la evaluación de los modelos entrenados con los casos reales que ocurren en la empresa y de esta manera determinar cuál de los algoritmos es el más adecuado para cada una de las etapas de análisis de fallas en líneas de transmisión. Esta evaluación se realiza de manera detallada

caso por caso a partir de múltiples técnicas que permiten el análisis de los resultados desde diferentes perspectivas y así poder tomar decisiones robustas desde el punto de vista técnico complementado con la experiencia y necesidades de los analistas. Para la evaluación se escogieron 118 casos de fallas reales en diferentes niveles de tensión (ver Tabla 5), localización e impedancia, los cuales eran exigentes para los modelos, pero que permitían valorar desde un entorno real los resultados obtenidos.

Tabla 5. Caracterización de los casos para la evaluación de modelos entrenados

Nivel de impedancia	Localización	Nivel de tensión (kV)	Número de casos
Alta-Muy Alta	Adelante	115-110-66	7
Alta-Muy Alta	Adelante	500-230-220	11
Alta-Muy Alta	Atrás	500-230-220	3
Baja-Media	Adelante	115-110-66	23
Baja-Media	Adelante	500-230-220	56
Baja-Media	Atrás	115-110-66	5
Baja-Media	Atrás	500-230-220	13

Detección de falla

Se presentan a continuación los resultados obtenidos en la detección de fallas, empleando los modelos de análisis expuestos en la metodología. Se destaca la exactitud del mejor o mejores modelos para cada conjunto de fallas separados según sus características (Impedancia de Falla, Ubicación, Nivel de tensión, ver Tabla 6).

Tabla 6. Resultados de desempeño para modelos de análisis en detección de fallas para diferentes conjuntos de datos

Características de la falla	Mejor modelo	Exactitud del mejor modelo
AltaMuyAlta_ADELANTE 115-110-66 kV	DT	85,7 %
AltaMuyAlta_ADELANTE 500-230-220 kV	KNN	63,6 %
AltaMuyAlta_ATRÁS 500-230-220 kV	KNN, MLP, MLP0	100 %
BajaMedia_ADELANTE 115-110-66 kV	MLP, MLP0	91,3 %
BajaMedia_ADELANTE 500-230-220 kV	MLP	83,9 %
BajaMedia_ATRÁS 115-110-66	MLP, MLP0	100 %
BajaMedia_ATRÁS 500-230-220 kV	KNN, MLP0	92,3 %

De estos resultados se evidencia que en los casos de alta impedancia (“Adelante de 500 kV, 230 kV y 220 kV”) se tienen los desempeños más bajos debido a que los modelos de falla tienden a presentar diagnósticos erróneos como falsos positivos. El análisis de estos falsos positivos se presenta más adelante.

Para la característica de Baja y Media impedancia se tienen los mejores resultados y se destacan los modelos KNN, MLP y MLP0 para dicho análisis. Es de resaltar que este tipo de fallas representan el mayor porcentaje de casos reales que se presentan en las líneas de transmisión y subtransmisión y por ello son los resultados que se espera sean los de mejores resultados para que los modelos puedan ser usados en entornos reales.

Tipo de falla

En la Tabla 7, se exponen los resultados con los modelos seleccionados y su validación a partir de los diferentes conjuntos de datos con variedad de características de fallas.

Tabla 7. Resultados de desempeño para modelos de análisis en detección de tipo de fallas para diferentes conjuntos de datos

Características de la falla	Mejor modelo	Exactitud del mejor modelo
AltaMuyAlta_ADELANTE 115-110-66 kV	MLP	71,4%
AltaMuyAlta_ADELANTE 500-230-220 kV	MLP	81,8%
AltaMuyAlta_ATRÁS 500-230-220 kV	MLP, RF	100%
BajaMedia_ADELANTE 115-110-66 kV	MLP, MLP0	91,3 %
BajaMedia_ADELANTE 500-230-220 kV	MLP	96,4 %
BajaMedia_ATRÁS 115-110-66 kV	MLP, MLP0	100 %
BajaMedia_ATRÁS 500-230-220 kV	MLP0	84,6 %

Se observa en este caso, que los análisis realizados para identificación de tipo de falla son menos susceptibles a presentar falsos positivos, lo que mejora las métricas de desempeño en los casos de alta y muy alta impedancia. Gracias a lo anterior, también se mejora de manera considerable los resultados de desempeño obtenidos para el análisis en casos de baja y media impedancia (Adelante de 500 kV, 230 kV y 220 kV), con porcentaje de exactitud superior al 96%.

En este caso se destaca en mayor medida el modelo MLP que ha mostrado el mejor desempeño para todos los niveles de tensión y los casos de estudio o conjuntos de datos previamente establecidos.

Ubicación de la falla

Finalmente, se exponen los resultados para desempeño de los modelos, obtenidos en el proceso de identificación de ubicación de la falla. Se destacan los modelos con mejor desempeño en dichos procesos (ver Tabla 8).

Tabla 8. Resultados de desempeño para modelos de análisis en ubicación de fallas para diferentes conjuntos de datos

Características de la falla	Mejor modelo	Exactitud del mejor modelo
AltaMuyAlta_ADELANTE 115-110-66 kV	MLP	71,4 %
AltaMuyAlta_ADELANTE 500-230-220 kV	KNN, DT, MLP	63,6 %
AltaMuyAlta_ATRÁS 500-230-220 kV	DT, RF, SVM	100%
BajaMedia_ADELANTE 115-110-66 kV	MLP	91,3 %
BajaMedia_ADELANTE 500-230-220 kV	MLP	80,3 %
BajaMedia_ATRÁS 115-110-66 kV	KNN	100 %
BajaMedia_ATRÁS 500-230-220 kV	SVM, RF	76,9%

Los resultados presentados muestran que, a diferencia de los modelos de identificación de falla y análisis de tipo de falla, se evidencian modelos que funcionan mejor para clasificar fallas hacia Atrás (como el SVM y RF), y otros que funcionan mejor en fallas hacia Adelante, como el MLP. En los casos de Alta impedancia hacia Adelante y de impedancia de baja y media hacia atrás (500 kV, 230 kV y 220 kV) se obtienen los desempeños más bajos.

Análisis de falsos positivos

Una vez realizado el proceso de validación con los casos reales, se complementa el análisis de los resultados exponiendo los casos que presentan falsos positivos. Con dicha información se pueden verificar algunos casos que generan comportamientos indeseados de los modelos. Los resultados de este proceso se presentan en la Tabla 9.

Tabla 9. Análisis de falsos positivos y comportamientos indeseados en el proceso de pruebas.

Descripción de la anomalía	Número de casos	Conclusiones
Falsos positivos totales solo en modelos de detección de falla	81	Los modelos de detección de falla son muy sensibles y tienden a equivocarse de manera recurrente. Por ende, se sugiere descartar el resultado de análisis de detección de falla y usar solo el análisis de tipo de falla.
Falsos positivos totales en modelo de tipo de falla con DT (Decision Tree)	35	Se concluye que este modelo es bastante sensible y se debe descartar.
Falsos positivos en todas las clases de predicción	13	Es necesario hacer una revisión detallada de estos casos.
No hay pronóstico.	2	Es necesario hacer una revisión de estos casos.

A partir de estos resultados, se tiene una mejor clasificación de la información y se establecen parámetros de corrección o ajustes en el proceso de análisis para determinar los eventos de falla, con mayor precisión. De estos resultados se identifica que el número de casos en los que se presenta falsos positivos en modelos de detección de falla es considerablemente alto. Sin embargo, bajo las características planteadas para los nuevos modelos de análisis y la identificación de características particulares de los eventos, los falsos positivos para la detección de falla resultan poco relevantes, pues solamente el análisis de tipo de falla puede asumir los dos papeles como lo ha hecho el modelo del sistema DAE actual e igualmente podría suceder con el de ubicación.

Otro fenómeno frecuente es la presencia de falsos positivos solo para el modelo DT de tipo de falla, concluyendo que es un modelo muy sensible y que sus pronósticos pierden confiabilidad. Por otro lado, de forma menos frecuente se pueden ver falsos positivos en todas las etapas de predicción para más de un modelo.

Comparación de resultados con el modelo actual del DAE

Ahora bien, estos resultados de los modelos de analítica planteados en este proyecto fueron contrastados con los obtenidos al emplear la herramienta DAE que actualmente utiliza la empresa. En la Tabla 10, se exponen dicha comparación tomando como referencia la detección del tipo de fallas. Aquí se observa si los resultados obtenidos con cada modelo se ajustan o no, a la descripción original de la falla planteada para contrastar los análisis. Asimismo, en la Tabla 11 se presenta el análisis de la eficacia entre el sistema DAE actual y modelos de analítica implementados para diagnóstico de fallas en líneas en este proyecto.

Tabla 10. Ejemplos de eventos resultados obtenidos en la comparación de la solución actual DAE y los nuevos modelos de análisis

Caso	Descripción de la falla	Red Neuronal DAE	MLP0	MLP	SVM	DT	KNN	RF
1	Falla en B y luego en BC Adelante	Se registra falla en B y luego en BC	No	No	No	No	No	No
2	Falla AG Adelante	Apertura en monopolar en B	Si	Si	Si	Si	Si	Si
3	Falla en CG Adelante	Sin Falla ABC	Si	Si	Si	Si	Si	Si
4	Falla CG Adelante	Se registra falla fase C y apertura en C	No	No	No	Si	No	Si
5	Falla CG Adelante	Se registra falla fase C y apertura en C	Si	Si	No	Si	Si	Si

Tabla 11. Análisis de la eficacia entre DAE actual y modelos de analítica implementados para diagnóstico de fallas en líneas.

Análisis	Detección	Tipo	Ubicación
DAE	72%		N/A
MLP0	83,30%	88,90%	63,90%
MLP	80,60%	88,90%	69,40%
KNN	80,60%	75,00%	75,00%
SMV	<67%	72,20%	58,30%
RF	<67%	86,10%	80,60%
DT	<67%	55,60%	72,20%

Cabe resaltar que la herramienta DAE en su versión actual realiza de manera conjunta los análisis de detección y tipo de falla y no contempla el conjunto de escenarios asociados a la ubicación de falla, que si son contemplados con los modelos de análisis implementados en este artículo.

Adicionalmente, es preciso mencionar que las pruebas de validación realizadas en la comparación de modelos tuvieron menor cantidad de casos para prueba, dado que para hacer equivalente el análisis se utilizaron únicamente aquellos casos para los cuales fue diseñado el sistema DAE actual

Adicionalmente, es preciso mencionar que las pruebas de validación realizadas en la comparación de modelos tuvieron menor cantidad de casos para prueba, dado que para hacer equivalente el análisis se utilizaron únicamente aquellos casos para los cuales fue diseñado el sistema DAE actual.

De los resultados obtenidos destaca la alta eficacia de MLP0 y MLP para la detección y tipo de falla, mientras que el modelo con mejor eficacia en ubicación de falla fue RF. Por otra parte, el modelo con menor eficacia en los procesos de análisis en general fue DT.

5. Conclusiones

EL proceso de entendimiento y diagnóstico de datos, complementado con el entrenamiento de los modelos, fue fundamental para establecer las características de uso e hiperparámetros empleados

en los modelos de análisis, con lo cual se logró establecer una alta eficacia en los procesos de análisis, reflejando su aplicabilidad para diagnóstico de eventos en líneas de transmisión con diferentes niveles de tensión.

Los modelos entrenados cuentan con una mejor eficacia para análisis con las líneas de 34.5 kV, 66 kV, 110 kV, 230 kV y 500 kV, lo que representa una mejora significativa con respecto al DAE actual y su red neuronal que actualmente tiene una predicción con alta eficacia en líneas de 230 y 500 KV. Adicionalmente, los desarrollos garantizan la detección de fallas de polo abierto y polo cerrado a partir de un algoritmo integrado, siendo un valor agregado en contraste con el actual diagnóstico automático e incluye el diagnóstico de la falla independientemente de su ubicación (Adelante o Atrás).

Con el análisis e identificación de falsos positivos se concluye que este tipo de casos no son tan comunes en los modelos de tipo y de ubicación, por lo cual se infiere que los modelos de detección de falla no están aportando una mayor confiabilidad a los demás diagnósticos. Sin embargo, esta limitante se suple con un modelo de detección del tipo de fallas, que evita la necesidad de contar con un proceso de análisis de falsos positivos.

A partir de los resultados obtenidos por el equipo de trabajo se observa que, el modelo MLP tiene un mejor desempeño a nivel general en todas las etapas, por lo que se concluye que es el modelo que más se adecua a los diagnósticos de eventos para el componente de líneas de transmisión.

Los resultados expuestos en el presente artículo exponen importantes hallazgos al ser contrastados con la herramienta DAE que actualmente emplea la empresa y se observa que el nuevo modelo entrenado del tipo de falla tiene mejores resultados, con una capacidad más amplia hacia los niveles de tensión de subtransmisión y fallas de alta impedancia.

6. Agradecimientos

El presente artículo se realiza en el marco del proyecto **“Optimización del proceso de gestión de eventos y fallas en el sistema de transmisión nacional operado por las empresas de ISA a través de la integración de las nuevas versiones de los sistemas SAGES (Sistema Automático de Gestión de Equipos de Subestaciones) y DAE (Diagnóstico Automático de Eventos)”** avalado por Minciencias y ejecutado por Interconexión Eléctrica – ISA S.A. en compañía del Grupo T&T de la Universidad Nacional de Colombia sede Medellín, fortaleciendo los lazos entre industria y academia. Un agradecimiento especial para los equipos de trabajo de estas instituciones.

Bibliografía

- Aizpurua, O., (2010). Una nueva metodología para la administración de alarmas masivas en sistemas de potencia utilizando técnicas de inteligencia artificial y minería de datos. Dialnet [en línea]. [Consultado el 14 de agosto de 2023]. Disponible en: <https://dialnet.unirioja.es/servlet/tesis?codigo=185513&info=resumen&idioma=SPA>
- Ajagekar, A. y You, F., (2021). Quantum computing based hybrid deep learning for fault diagnosis in electrical power systems. Applied Energy [en línea]. **303**, 117628. [Consultado el 14 de agosto de 2023]. Disponible en: doi: 10.1016/j.apenergy.2021.117628
- Al-Mtawa, Y., Haque, A. y Halabi, T., (2022). A Review and Taxonomy on Fault Analysis in Transmission Power Systems. Computation [en línea]. **10**(9), 144. [Consultado el 2 de agosto de 2023]. Disponible en: doi: 10.3390/computation10090144
- Barrientos, E., Cruz, N. y Acosta, G., (2009). Árboles de decisión como herramienta en el diagnóstico médico. Revista Médica de la Universidad Veracruzana [en línea]. **19**(2), 19–24. [Consultado el 14 de agosto de 2023]. Disponible en: <http://www.uv.mx/rm>
- Benner, C. L. y Russell, B. D., (2009). Automated fault analysis using an intelligent monitoring system. En: 2009 62nd Annual Conference for Protective Relay Engineers, 30 de marzo–2 de abril de 2009, College Station, TX, USA [en línea]. IEEE. [Consultado el 2 de agosto de 2023]. Disponible en: doi: 10.1109/cpre.2009.4982515

- Biau, G. y Scornet, E., (2016). A random forest guided tour. TEST [en línea]. **25**(2), 197–227. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1007/s11749-016-0481-7
- Bisong, E., (2019). Building machine learning and deep learning models on Google Cloud Platform : a comprehensive guide for beginners [en línea]. Apress. [Consultado el 14 de agosto de 2023]. Disponible en: <https://www.oreilly.com/library/view/building-machine-learning/9781484244708/>
- Calderón, J. A., (2007). Modelo adaptativo de inteligencia artificial para el diagnóstico automático de fallas a partir de registros de osciloperturbografía. Tesis de maestría, Universidad Nacional de Colombia.
- Calderón, J. A., Zapata, G. D. y Ovalle, D. A., (2007). Algoritmo Neuro-Difuso para la Detección y Clasificación de Fallas en Líneas de Transmisión Eléctrica Usando ANFIS. Revista Avances en Sistemas e Informática - Universidad Nacional de Colombia [en línea]. **4**(1), 101–107. [Consultado el 2 de agosto de 2023]. Disponible en: <https://docplayer.es/37785749-Revista-avances-en-sistemas-e-informatica-issn-universidad-nacional-de-colombia-colombia.html>
- Calderón, J., Cadavid, M. y Ovalle, D., (2008). Red neuronal para la clasificación de fallas en líneas de transmisión a partir de registros de osciloperturbografía. Dyna [en línea]. **75**(156), 99–107. [Consultado el 8 de septiembre de 2023]. Disponible en: <https://revistas.unal.edu.co/index.php/dyna/article/view/1770>
- Castillo-Barvo, L., Ossa-Urrea, A., Camargo-Sánchez, L. F., González-Vásquez, J. A., Vélez-Cano, O. F. y Giraldo, J. C., (2022). Diagnóstico de calidad de la energía eléctrica en Colombia 2021 [en línea]. Bogotá. [Consultado el 4 de junio de 2023]. Disponible en: <https://www.superservicios.gov.co/sites/default/files/inline-files/Informe-de-Calidad-del-Servicio-de-Energia-2021.pdf>
- Deshmukh, S., Glicksman, L. y Norford, L., (2018). Case study results: fault detection in air-handling units in buildings. Advances in Building Energy Research [en línea]. **14**(3), 305–321. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1080/17512549.2018.1545143
- DNP, (2022). CONPES Consejo Nacional De Política Económica y Social - Política de Transición Energética. Bogotá.
- Fan, W. y Liao, Y., (2012). Automated analysis of voltage and current waveforms during faults. En: 2012 Southeastern Symposium on System Theory (SSST), 11–13 de marzo de 2012, Jacksonville, FL, USA [en línea]. IEEE. [Consultado el 2 de agosto de 2023]. Disponible en: doi: 10.1109/ssst.2012.6195144
- Ferreira, V. H., Zanghi, R., Fortes, M. Z., Sotelo, G. G., Silva, R. B. M., Souza, J. C. S., Guimarães, C. H. C. y Gomes, S., (2016). A survey on intelligent system application to fault diagnosis in electric power system transmission lines. Electric Power Systems Research [en línea]. **136**, 135–153. [Consultado el 2 de agosto de 2023]. Disponible en: doi: 10.1016/j.epsr.2016.02.002

- Fuente, M. J. y Represa, C., (1997). A comparative study of neural networks based approach for fault detection. *IFAC Proceedings Volumes [en línea]*. **30**(18), 471–476. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1016/s1474-6670(17)42446-3
- Ghadiri, H., (2016). Fault detection based on type 2 fuzzy systems for a single-rod electrohydraulic actuator. *Journal of Artificial Intelligence in Electrical Engineering*. **5**(19).
- Gómez-Ramírez, G. A., (2016). Evolución y tendencias de índices de confiabilidad en sistemas eléctricos de potencia. *Revista Tecnología en Marcha [en línea]*. **29**(2), 3. [Consultado el 2 de agosto de 2023]. Disponible en: doi: 10.18845/tm.v29i2.2687
- Ibrahim, M. A., (2012). Disturbance analysis for power systems [en línea]. IEEE. [Consultado el 4 de junio de 2023]. Disponible en: <https://ieeexplore.ieee.org/book/6047600>
- Inés, L., Mesa, H., Rincón, J., Zapata, G. D., Vásquez, L. y Castillo, W., (2011). IEC 61850 Driver for automatic download and distribution event diagnosis in a power transmission system. [Consultado el 19 de junio de 2023]. Disponible en: <https://docplayer.es/76611409-Luz-ines-hincapie-mesa-1-jorge-rincon-bonilla-2-german-zapata-madrigal-3-leonardo-vasquez-ruiz-4-y-wilson-castillo-bautista-5.html>
- Kezunovic, M., (2000). Practical applications of automated fault analysis. En: *International Conference on Power System Technology (POWERCON 2000)*, Perth, WA, Australia [en línea]. IEEE. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1109/icpst.2000.897127
- Li, S., Frey, M. y Gauterin, F., (2023). Evaluation of Different Fault Diagnosis Methods and Their Applications in Vehicle Systems. *Machines [en línea]*. **11**(4), 482. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.3390/machines11040482
- Lima, M., Ovidio, A., Fiallo, R., Fernández, S., Rómulo, G. y Barrios, J. P., (2011). Sistema para diagnóstico de fallas en transformadores a través de lógica difusa. *Ingeniería Energética [en línea]*. **24**(3), número de artículo: 187. [Consultado el 14 de agosto de 2023]. Disponible en: <https://rie.cujae.edu.cu/index.php/RIE/article/view/187>
- Lin, G., Pritoni, M., Chen, Y. y Granderson, J., (2020). Development and implementation of fault-correction algorithms in fault detection and diagnostics tools. *Energies [en línea]*. **13**(10), 2598. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.3390/en13102598
- Lin, L., Chen, Q., Wang, Z., Xue, B. y Sun, M., (2019). A substation fault diagnosis method based on substation alarm signal analysis. En: *2019 IEEE 3rd International Electrical and Energy Conference (CIEEC)*, 7–9 de septiembre de 2019, Beijing, China [en línea]. IEEE. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1109/cieec47146.2019.cieec-2019569

- LLano, L., Zapata, G. y Ovalle, D., (2007). Sistema de inferencia difuso para identificar eventos de falla en tiempo real del ste usando registros SOE. *Avances en Sistemas e Informática [en línea]*. **4**(2). [Consultado el 19 de junio de 2023]. Disponible en: <https://revistas.unal.edu.co/index.php/avances/article/view/9762>
- Meng, J. y Jingyi, D., (2020). Research on magnetizing inrush current and fault identification of transformer based on VMD-SVM. En: *2020 IEEE international conference on information technology, big data and artificial intelligence (ICIBA)*, 6–8 de noviembre de 2020, Chongqing, China [en línea]. IEEE. Disponible en: doi: 10.1109/iciba50161.2020.9277268
- Moseler, O., Heller, T. y Isermann, R., (1999). Model-Based fault detection for an actuator driven by a brushless DC motor. *IFAC Proceedings Volumes [en línea]*. **32**(2), 7873–7878. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1016/s1474-6670(17)57343-7
- Moujahid, A., Inza, I. y Larrañaga, P., (2008). Tema 5. Clasificadores K-NN. Pamplona, España. pp. 1–8. [Consultado el 14 de agosto de 2023]. Disponible en: <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t9knn.pdf>
- Mukherjee, A., Kundu, P. K. y Das, A., (2021). Transmission Line Faults in Power System and the Different Algorithms for Identification, Classification and Localization: A Brief Review of Methods. *Journal of The Institution of Engineers (India): Series B [en línea]*. [Consultado el 2 de agosto de 2023]. Disponible en: doi: 10.1007/s40031-020-00530-0
- Musaruddin, M. y Zivanovic, R., (2009a). Automated Fault Analysis in the Indonesian power utility: A case study of South Sulawesi transmission system. En: *2009 Australasian Universities Power Engineering Conference, Adelaide, Australia [en línea]*. IEEE Conference Publication | IEEE Xplore. [Consultado el 4 de junio de 2023]. Disponible en: <https://ieeexplore.ieee.org/document/5356640>
- Musaruddin, M. y Zivanovic, R., (2009b). Web Services for Automated Fault Analysis in Electrical Power System. En: *2009 Fifth International Joint Conference on INC, IMS and IDC, 25–27 de agosto de 2009, Seoul, South Korea [en línea]*. IEEE. Disponible en: doi: 10.1109/ncm.2009.352
- Ortiz, C. y Salazar, G., (2020). Metodología para la planificación y control de la ejecución de mantenimientos preventivos y correctivos de líneas de subtransmisión. *Revista Técnica “Energía” [en línea]*. **16**(2), 135–147. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.37116/revistaenergia.v16.n2.2020.361
- Parikh, U. B., Das, B. y Maheshwari, R., (2010). Fault classification technique for series compensated transmission line using support vector machine. *International Journal of Electrical Power & Energy Systems [en línea]*. **32**(6), 629–636. [Consultado el 14 de agosto de 2023]. Disponible en: doi: 10.1016/j.ijepes.2009.11.020

- Prasad, A., Belwin Edward, J. y Ravi, K., (2018). A review on fault classification methodologies in power transmission systems: Part—I. *Journal of Electrical Systems and Information Technology* [en línea]. **5**(1), 48–60. [Consultado el 2 de agosto de 2023]. Disponible en: doi: 10.1016/j.jesit.2017.01.004
- Quintero, E., (2010). Desarrollo de un modelo para la localización de fallas en sistemas de transmisión de energía eléctrica utilizando técnicas de inteligencia artificial. Universidad Nacional de Colombia.
- Raza, A., Benrabah, A., Alquthami, T. y Akmal, M., (2020). A Review of Fault Diagnosing Methods in Power Transmission Systems. *Applied Sciences* [en línea]. **10**(4), 1312. [Consultado el 2 de agosto de 2023]. Disponible en: doi: 10.3390/app10041312
- Sánchez-Anzola, N., (2016). Máquinas de soporte vectorial y redes neuronales artificiales en la predicción del movimiento USD/COP spot intradiario. *ODEON* [en línea]. (9), 113. [Consultado el 14 de agosto de 2023]. Disponible en: doi: 10.18601/17941113.n9.04
- Sevcik, D. y Lunsford, R., (2007). Automated analysis of faults and disturbances: utility expectations and benefits - Centerpoint Energy. En: 2007 IEEE Power Engineering Society General Meeting, 24–28 de junio de 2007, Tampa, FL, USA [en línea]. IEEE. Disponible en: doi: 10.1109/pes.2007.386192
- UPME, (2019). Plan Energético Nacional 2020-2050 [en línea]. Bogotá. [Consultado el 4 de junio de 2023]. Disponible en: https://www1.upme.gov.co/DemandaEnergetica/PEN_documento_para_consulta.pdf
- Vaschetti, J. C., Magnago, F. y Sauchelli, V. H., (2012). Control automático de voltaje en sistemas eléctricos de potencia basado en sistemas expertos. *Información tecnológica* [en línea]. **23**(5), 69–84. [Consultado el 14 de agosto de 2023]. Disponible en: doi: 10.4067/s0718-07642012000500008
- Vásquez, L., (2010). Modelo híbrido utilizando agentes de software inteligentes y lógica difusa para el diagnóstico automático de fallas en sistemas de transmisión de energía. Tesis de Maestría, Universidad Nacional de Colombia. [Consultado el 4 de junio de 2023]. Disponible en: <https://repositorio.unal.edu.co/handle/unal/8043>
- Vásquez, L., Arboleda, A. y Zapata, G. D., (2011). Sistema Multiagente para diagnóstico de fallas en sistemas de transmisión de energía eléctrica. En: XVIII International Congress of Electronic - INTERCON, 17 de agosto de 2011, Lima, Perú. IEEE. pp. 1–8.
- Vatsa, A. y Hati, A. S., (2022). Transformer faults detection using inrush transients based on multi-class SVM. En: 2022 IEEE 6th International Conference on Condition Assessment Techniques in Electrical Systems (CATCON), 17–19 de diciembre de 2022, Durgapur, India [en línea]. IEEE. [Consultado el 2 de agosto de 2023]. Disponible en: doi: 10.1109/catcon56237.2022.10077668

- Wang, J., Zhang, S. y Hu, X., (2021). A fault diagnosis method for lithium-ion battery packs using improved RBF neural network. *Frontiers in Energy Research* [en línea]. **9**. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.3389/fenrg.2021.702139
- Wen, F. y Qing, L., (2021). Fault diagnosis of substation secondary system based on association analysis. En: *2021 IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS)*, 29–31 de julio de 2021, Shenyang, China [en línea]. IEEE. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1109/icpics52425.2021.9524150
- Yan-Zhang, Sprintson, A. y Singh, C., (2012). An integrative approach to reliability analysis of an IEC 61850 digital substation. En: *2012 IEEE Power & Energy Society General Meeting. New Energy Horizons - Opportunities and Challenges*, 22–26 de julio de 2012, San Diego, CA [en línea]. IEEE. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1109/pesgm.2012.6345699
- Zhao, D., Wang, Y. y Song, Y., (2019). Petri Net Based Intelligent Substation Fault Diagnosis. En: *2019 IEEE 3rd Conference on Energy Internet and Energy System Integration (EI2)*, 8–10 de noviembre de 2019, Changsha, China [en línea]. IEEE. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1109/ei247390.2019.9062127
- Zong, P., Gao, Z., Yang, T., & Zhou, F. (2020). A method of fault diagnosis for secondary loop in intelligent substation based on bayesian algorithm. En *2020 IEEE Student Conference on Electric Machines and Systems (SCEMS)*. IEEE. <https://doi.org/10.1109/scems48876.2020.9352294>
- Zuleta, L. E. L., Madrigal, G. Z. y Carranza, D. A. O., (2007). Hybrid System based on Fuzzy Inference and Colored Petri Nets to Identify Electrical Fault Events in Real Time. En: *Electronics, robotics and automotive mechanics conference (CERMA 2007)*, 25–28 de septiembre de 2007, Cuernavaca, Morelos, Mexico [en línea]. IEEE. [Consultado el 20 de agosto de 2023]. Disponible en: doi: 10.1109/cerma.2007.4367720