

**IDENTIFICACIÓN DE CAUSA RAÍZ DE FALLAS POR DESCARGAS  
ELÉCTRICAS EN LÍNEAS DE TRANSMISIÓN**



**UNIVERSIDAD POLITÉCNICA SALESIANA  
SEDE QUITO**

**CARRERA:  
INGENIERÍA ELÉCTRICA**

**Trabajo de titulación previo a la obtención del título de  
INGENIERO ELÉCTRICO**

**TEMA:  
IDENTIFICACIÓN DE CAUSA RAÍZ DE FALLAS POR DESCARGAS  
ELÉCTRICAS EN LÍNEAS  
DE TRANSMISIÓN**

**AUTOR:  
DIANA JOSSELYN FLORES FERRIN**

**TUTOR:  
ALEXANDER ÁGUILA TÉLLEZ**

**Quito, febrero 2021**

Diana Josselyn Flores Ferrin

**IDENTIFICACIÓN DE CAUSA RAÍZ DE FALLAS POR DESCARGAS  
ELÉCTRICAS EN LÍNEAS DE TRANSMISIÓN**

Universidad Politécnica Salesiana, Quito – Ecuador 2021

Ingeniería Eléctrica

Breve reseña histórica e información de contacto.



**Diana Josselyn Flores Ferrin** (A'1995 – M'02). Realizó sus estudios de nivel secundario en el “Colegio Modelo Politécnico” de la ciudad de Quito. Egresada de la Carrera de Ingeniería Eléctrica de la Universidad Politécnica Salesiana. Su trabajo se enfoca en el estudio de Identificación de causa raíz de fallas por descargas eléctricas en líneas de transmisión. [dfloresf2@est.ups.edu.ec](mailto:dfloresf2@est.ups.edu.ec)

*Dirigido por:*



**Alexander Águila Téllez** (A'1981 – M'09). Recibió el título de Ingeniero Eléctrico y el de Máster en Eficiencia Energética en los años 2005 y 2010 respectivamente. Actualmente se encuentra estudiando para obtener su título de Doctor en Ingeniería en la Universidad Pontificia Bolivariana-Colombia-Medellín, es miembro del Grupo de Investigación GIREI. Sus principales intereses de investigación incluyen la compensación VOLT-VAR en redes de distribución eléctrica, redes inteligentes, minimización de pérdidas de energía, las energías renovables y la eficiencia energética. Es profesor investigador de la Universidad Politécnica Salesiana-Ecuador. [aaguila@ups.edu.ec](mailto:aaguila@ups.edu.ec)

Todos los derechos reservados:

Queda prohibida, salvo excepción prevista en la ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con la autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos o investigativos por cualquier medio, con la debida notificación a los autores.

**DERECHOS RESERVADOS**

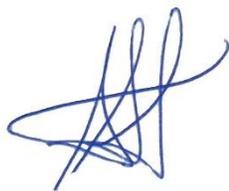
©2021 Universidad Politécnica Salesiana

QUITO - ECUADOR

## DECLARATORIA DE COAUTORÍA DEL DOCENTE TUTOR

Yo, Alexander Águila Téllez declaro que bajo mi dirección y asesoría fue desarrollado el trabajo de titulación IDENTIFICACIÓN DE CAUSA RAÍZ DE FALLAS POR DESCARGAS ELÉCTRICAS EN LÍNEAS DE TRANSMISIÓN realizado por Diana Josselyn Flores Ferrin, obteniendo un producto que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana para ser considerado como trabajo final de titulación.

Quito D.M., febrero de 2021



.....

Alexander Águila Téllez

C.I.:1755983184

## CESIÓN DE DERECHOS DE AUTOR

Yo, Diana Josselyn Flores Ferrin, con documento de identificación N° 2300418635, manifiesto mi voluntad y cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del trabajo de grado/titulación intitulado: IDENTIFICACIÓN DE CAUSA RAÍZ DE FALLAS POR DESCARGAS ELÉCTRICAS EN LÍNEAS DE TRANSMISIÓN mismo que ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia, suscribo este documento en el momento que hago entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito D.M., febrero de 2021



.....

Diana Josselyn Flores Ferrin

C.I.: 2300418635

Quito, D.M., febrero de 2021

## ÍNDICE GENERAL

1	INTRODUCCIÓN.....	4
2	MARCO TEÓRICO .....	7
2.1	Clasificador de Patrones .....	7
2.1.1	Clasificador no supervisado.....	7
2.1.2	Clasificador supervisado .....	7
2.2	Método de vecinos más cercanos (k-nn).....	8
3	METODOLOGÍA Y PLANTEAMIENTO DEL PROBLEMA .....	9
3.1	Problema.....	9
3.2	Implementación en ATPDraw.....	11
4	CARACTERIZACIÓN DE LA FORMA DE ONDA.....	13
4.1	Adquisición de datos en las formas de onda .....	14
4.1.1	Parámetros eléctricos .....	14
4.1.2	Tasa de cambio de corriente .....	15
4.1.3	Parámetros no eléctricos .....	15
5	METODOLOGÍA PROPUESTA .....	16
5.1	Normalización de datos .....	16
5.2	Proceso de identificación de causa raíz .....	17
6	ANÁLISIS DE RESULTADOS.....	18
6.1	Resultados con un modelo k-nn con una constante de precisión k=7 .....	18
6.1.1	Resultados para el modelo de entrenamiento.....	18
6.1.2	Resultados de predicción con el modelo entrenado.....	19
6.2	Resultados con un modelo k-nn con una constante de precisión k=8 .....	19
6.2.1	Resultados para el modelo de entrenamiento.....	19
6.2.2	Resultados de predicción con el modelo entrenado.....	20
6.3	Resultados con un modelo k-nn con una constante de precisión k=9 .....	20
6.3.1	Resultados para el modelo de entrenamiento.....	20
6.3.2	Resultados de predicción con el modelo entrenado.....	21
7	CONCLUSIONES.....	21
8	TRABAJOS FUTUROS .....	22
9	REFERENCIAS .....	22
1.1	Matriz de Estado del Arte.....	26
1.2	Resumen de Indicadores .....	29

## ÍNDICE DE FIGURAS

Figura 1. Esquema de obtención de datos de fallas de la red de transmisión ...	5
Figura 2. Clasificador k-nn con valor de $k=3$ .....	8
Figura 3. Clasificador k-nn con valor de $k=5$ .....	8
Figura 4. Registro de fallas en líneas de transmisión periodo 2015 – 2020.....	9
Figura 5 Distancias torre de transmisión de 230 kV.....	10
Figura 6. Distancias torre de transmisión de 138 kV.....	10
Figura 7 Implementación del circuito Santo Rosa - Pomasqui. Simulación con descarga eléctrica.....	11
Figura 8 Implementación del circuito Santo Rosa - Pomasqui. Simulación con pérdida de rigidez dieléctrica. ....	12
Figura 9. Implementación del circuito Tena - Fco de Orellana. Simulación con descarga eléctrica.....	12
Figura 10. Implementación del circuito Tena – Fco. de Orellana. Simulación con pérdida de rigidez dieléctrica .....	13
Figura 11. Notación matriz k-nn.....	17
Figura 12. Conjunto de muestras entrenadas y validadas para $k=7$ .....	18
Figura 13. Matriz de confusión para $k=7$ .....	19
Figura 14. Resultados del modelo de predicción para $k=7$ .....	19
Figura 15. Conjunto de muestras entrenadas y validadas para $k=8$ .....	19
Figura 16. Matriz de confusión para $k=8$ .....	20
Figura 17. Resultados del modelo de predicción para $k=8$ .....	20
Figura 18. Conjunto de muestras entrenadas y validadas para $k=9$ .....	20
Figura 19. Matriz de confusión para $k=9$ .....	21
Figura 20. Resultados del modelo de predicción para $k=9$ .....	21
Figura 21. Resumen e indicador de la temática - Estado del arte.....	29
Figura 22. Indicador de formulación del problema - Estado del arte.....	30
Figura 23. Indicador de solución - Estado del arte.....	30

## ÍNDICE DE TABLAS

Tabla 1 Circuitos con mayor incidencia de descargas atmosféricas .....	10
Tabla 2 Parámetros línea 230 kV .....	10
Tabla 3 Parámetros línea 138 kV .....	11
Tabla 4 Lista de atributos seleccionados .....	13
Tabla 5 Tipos de fallas según su causa raíz.....	14
Tabla 6 Valor medio y desviación estándar del punto de inyección de falla .....	14
Tabla 7 Lógica difusa para condiciones climáticas.....	16
Tabla 8 Atributos para entrenar el modelo k-nn .....	16
Tabla 9 Distribución datos para entrenar y validar el modelo según su causa de origen.....	16
Tabla 10 Media de los valores de los atributos .....	17
Tabla 12 Resultados de clasificación de datos en entrenamiento para k=7. ....	18
Tabla 13 Resultados de clasificación de datos en entrenamiento para k=8. ....	19
Tabla 14 Resultados de clasificación de datos en entrenamiento para k=9. ....	20
Tabla 15. Matriz de estado del arte .....	26

# IDENTIFICACIÓN DE CAUSA RAÍZ DE FALLAS POR DESCARGAS ELÉCTRICAS EN LÍNEAS DE TRANSMISIÓN

## Resumen

Este artículo desarrolla un algoritmo basado en aprendizaje supervisado mediante la aplicación del clasificador vecinos más cercanos (k-nn) con el objetivo de analizar, caracterizar y clasificar automáticamente una falla eléctrica en función de su causa raíz. En este documento se consideran fallas por descargas eléctricas y fallas por incendios. A partir del análisis detallado de las formas de onda y consideraciones ambientales se pueden encontrar patrones para la caracterización de fallas, estos atributos son: punto de inyección de falla, impedancia de falla, fases en falla, nivel de voltaje y clima. Estas características se obtienen a partir del modelamiento y simulación en el software ATPDraw de las torres de transmisión más representativas con las líneas que registran más fallas del Sistema Nacional de Transmisión del Ecuador. Finalmente, la combinación de estas características y parámetros se utilizan para entrenar y probar el algoritmo k-nn. La prueba exitosa de la metodología propuesta demuestra su validez para la identificación de diferentes tipos de fallas de acuerdo a su causa raíz. Además, el algoritmo desarrollado se ha entrenado y probado utilizando un conjunto de datos reales de campo. Los resultados muestran que la metodología es sólida y cubre una amplia gama de causas fundamentales de fallas.

**Palabras Clave:** Aprendizaje supervisado, Machine Learning, Transitorios en sistemas eléctricos, Fallas en sistemas eléctricos, Métodos de vecinos cercanos.

## Abstract

This research develops an algorithm based on supervised learning by applying the nearest neighbour classifier (k-nn) in order to automatically analyze, characterize and classify an electrical fault based on its root cause. This paper analyzes two kinds of the origin of electric faults: lightning and fire. Taking as a starting point a fully detailed analysis of voltage and current waveforms and environmental considerations, patterns can be found for the characterization of the origin of electrical faults, these attributes are fault inception point, fault impedance, fault phases, voltage level and climate. In this research, these characteristics are obtained from the modelling and simulation in the ATPDraw software of the most representative transmission towers with the lines that register the most failures of the National Transmission System of Ecuador. Finally, the combination of these characteristics and parameters are used to train and test the k-nn algorithm. The successful test of the proposed methodology demonstrates its validity for the identification of different types of failure according to its root cause. Furthermore, the developed algorithm has been trained and tested using a set of real field data. The results show that the methodology is robust and covers a wide range of root causes of failure.

**Keywords:** Supervised learning, Machine Learning, Power system transients, Power system faults, Nearest neighbor methods

# 1 INTRODUCCIÓN

El sector eléctrico a nivel mundial requiere implementar mejores herramientas para el manejo seguro, confiable y de calidad de la demanda de energía. Varias tecnologías consideradas dentro de una Smart Grid (SG), tales como gestión de la demanda, operación de generación distribuida, protecciones adaptivas, entre otras, comienzan a formar parte de los sistemas eléctricos convencionales con el objetivo de mejorar la producción, transporte y consumo de la energía eléctrica de forma flexible e inteligente [1], [2].

El salto hacia las SG se hace en base a una mayor interactividad entre los involucrados en la red eléctrica como son: producción, generación distribución y consumidor, para lograr esto se cuenta con el aporte de varias instituciones científicas y tecnológicas, de carácter público o privado, la red eléctrica se puede transformar en una red de alta interconectividad [3]–[5]. La interconectividad entre todos estos actores en una red eléctrica de gran escala se logra mediante redes que se extienden a gran escala, entre ellas la más común la red WAN (Wide Area Network) como se observa en la Figura 1.

Actualmente en América Latina, países como Chile, Colombia, Argentina, México, entre otros, han empezado a dar sus pasos en la implementación de medición inteligente (Smart Meter) y la automatización en subestaciones con el fin de incorporar inteligencia en sus centros de operaciones [6]. En [3] se propone una modernización del Esquema de Separación de áreas (ESA) entre

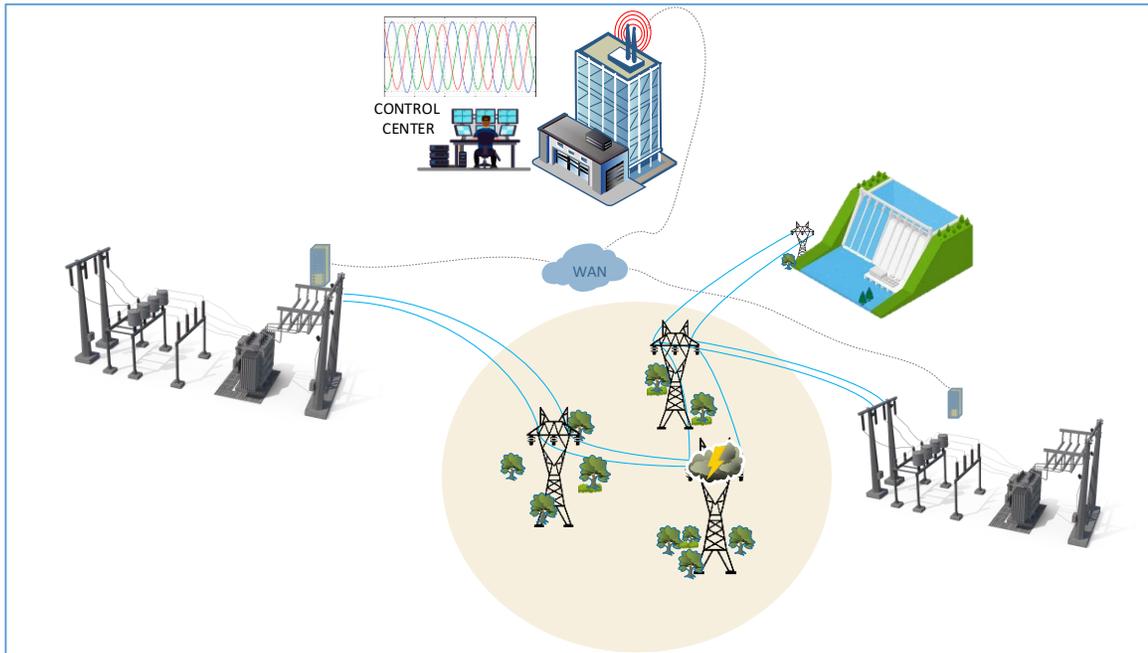
Colombia y Ecuador, motivado en incrementar la flexibilidad y selectividad del ESA durante eventos dinámicos entre ambos países. En transmisión, el objetivo de las SG es tener una mejor seguridad y fiabilidad en el sistema, sin embargo, la mayor cantidad de aportes en la eficiencia, seguridad y fiabilidad en los sistemas de transmisión se han obtenido mediante la implementación de algoritmos inteligentes como: redes neuronales, máquinas de soporte vectorial, algoritmos genéticos, entre otros [7], [8].

Los sistemas de transmisión, debido a su extensión, se encuentran expuestos a diferentes condiciones climáticas y geográficas. Las líneas de transmisión en comparación con los demás componentes del Sistema Eléctrico de Potencia (SEP) presentan una mayor tasa de incidencia de fallas [9]. Como causantes de fallas en líneas de transmisión se tiene a descargas atmosféricas, desastres naturales, vegetación/árbol, contaminación, incendios (causados por flameo de aisladores, quema de caña de azúcar, incendios forestales), fallas por equipo, fallas por maniobras, etc [10]. Estos eventos ponen en riesgo la operación segura de un sistema eléctrico, provocando condiciones operativas de emergencia, además, en algunos casos puede llegar a interrumpir el servicio eléctrico [11].

El diagnóstico de fallas en las líneas es importante al momento que ocurre una alteración en un sistema de transmisión ya que este componente del sistema eléctrico de potencia tiene como función llevar la energía hacia la carga siendo

necesario que muestren una alta confiabilidad en las mismas [11]. Al presentarse una contingencia, los centros de control son los encargados de analizar la causa de la falla con el objetivo de

definir acciones rápidas y adecuadas para su restablecimiento y evaluar el funcionamiento de los equipos involucrados durante el fallo [12].



**Figura 1.** Esquema de obtención de datos de fallas de la red de transmisión

Existen diferentes metodologías que ayudan al personal de estos centros a determinar el circuito perjudicado y a localizar la falla. Sin embargo, aun cuando dicha información ayuda en el proceso de reparación, es de gran beneficio determinar la posible causa raíz de la falla. El sector energético tiene una logística para obtener y almacenar información de perturbaciones o eventos de interés [12].

A lo largo del SEP se hace un despliegue de unidades de medición fasorial (PMU) con el objetivo de establecer una estimación del estado dinámico del sistema. Actualmente, en el Ecuador existen equipos registradores de fallas

capaces de almacenar estados de interruptores y equipos de protección, así como señales analógicas durante eventos de falla. La tasa de muestreo de estos equipos puede alcanzar aproximadamente 15 kHz [13]. Los datos registrados ayudan a extraer patrones estadísticamente significativos por lo cual se emplea la caracterización de la forma de onda con el fin de hallar características comunes que lo relacionen con la causa raíz de la falla [9], [14], [15].

Al momento de producirse fallas en las líneas de transmisión, las formas de onda de voltaje y corriente se distorsionan [16]. Estas formas de onda pueden ser usadas para la identificación de causa

raíz mediante patrones aplicando técnicas de Machine Learning (ML) [17].

ML se puede definir como una herramienta que contribuye eficazmente en la predicción de categorías al usar una gran cantidad de datos, permitiendo entrenar un modelo. En este caso se lo realizará con patrones reales de fallas en líneas de transmisión [18].

Es ampliamente aceptado que, los métodos para procesamiento de información automática desempeñen un importante papel. Estos métodos se conocen actualmente como inteligencia artificial, minería de datos, sistemas inteligentes y reconocimiento de patrones [12].

Varios estudios se han centrado en el desarrollo de diversas técnicas para identificar la causa raíz de las fallas en las líneas de transmisión. En mayor detalle, en [19] se propone un método de identificación de fallas que se basa en el modelo de red adaptativa de creencias profundas (ADBN) y las características de tiempo-frecuencia de una onda viajera, contenida en 2734 muestras de fallas típicas como vegetación, fuego, congelamiento, choque de vehículos, falla externa, animales y descarga eléctrica. El modelo ADBN extrae la información relevante y representa la correlación entre el parámetro tiempo-frecuencia y la causa de la falla. La investigación muestra que el modelo diagnosticó de forma correcta las causas de falla con diferentes niveles de voltaje y longitudes de línea. La metodología propuesta en [20] emplea un enfoque usando Support Vector Machine (SVM)

para caracterizar y clasificar una falla en función de su causa raíz. Este trabajo además emplea un algoritmo genético (GA) usado para seleccionar parámetros adecuados para el clasificador SVM y hacerlo más robusto. La propuesta de [21] menciona entrenar un conjunto de datos de fallas reales mediante un método basado en el clasificador de vecinos más cercanos (k-nn) para predecir la causa raíz empleando características de forma de onda de voltaje y corriente que se producen durante la contingencia. En el trabajo de investigación [22], se utiliza la caracterización de la forma de onda de corriente y voltaje extrayendo datos como tasa de cambio de corriente, caída de voltaje, impedancia de falla y ángulo de fase de inserción. Para la clasificación esta investigación propone dos conjuntos de reglas, todo esto mediante un análisis de conglomerados del reconocimiento de patrones. Se destaca que en [21], [22], las técnicas fueron probadas utilizando datos reales de fallas, mientras que en [19], [20], las técnicas fueron implementadas con datos de fallas simulados que si bien estos trabajos tienen un gran aporte pueden representar una carencia de precisión y complejidad con respecto a datos de eventos reales. Otras investigaciones encontradas en [23], [24], [25] hacen uso de las redes neuronales artificiales para la caracterización de fallas en líneas de distribución. Como se muestra en [26], [27] los retos a causa del flujo de energía bidireccional en generación distribuida causan dificultad en la ubicación e identificación de la causa raíz de la falla en la red, dichos retos han sido planteados por Advanced Metering Infrastructure.

Finalmente, las técnicas expuestas en [28], [29], [30] realizan una metodología para la localización de fallas en líneas de transmisión mediante mediciones sincronizadas, PMU y análisis de transitorios los cuales ofrecen únicamente la ubicación de la falla en la línea sin identificar la causa raíz de la misma, para esto se requiere aplicar técnicas de aprendizaje automático.

En el análisis de las referencias se puede señalar que se ha trabajado mucho en la localización de fallas. Sin embargo, la investigación hacia la identificación de la causa raíz de las fallas en los sistemas de transmisión ha sido comparativamente menor. Bajo estos antecedentes, el presente trabajo pretende establecer una metodología para identificación de causa raíz de fallas en líneas de transmisión mediante la búsqueda de patrones y técnicas de ML.

En adelante, este artículo se estructura de la siguiente manera: en la sección 2 se presenta el marco teórico con la información sobre clasificadores de patrones, en la sección 3 se describe el planteamiento del problema y la metodología propuesta. En la sección 4 se describe la caracterización de la forma de onda. En la sección 5 se analiza los resultados obtenidos aplicando el modelo propuesto. Finalmente, en la sección 6 se establecen las principales conclusiones y trabajos futuros.

## 2 MARCO TEÓRICO

### 2.1 Clasificador de Patrones

Un clasificador de patrones permite categorizar la clase de una muestra en base a información estadística de clases históricas. Con este fin, se realiza una

etapa de entrenamiento previa del clasificador cuya selección depende de la información disponible (función densidad de probabilidad o muestras de eventos anteriores) y el tipo de entrenamiento (supervisada o no supervisada) [31]. En general la función densidad de probabilidad no se conoce con anterioridad, por lo cual el método implementado requiere un entrenamiento en base a muestras históricas y selección de atributo.

Existen dos tipos de clasificadores los cuales se los detalla a continuación:

#### 2.1.1 Clasificador no supervisado

Este clasificador no dispone de datos etiquetados para el entrenamiento, solo se conoce los datos de entrada sin existir datos de salida que permitan su categorización, por ello, su clasificación se basa en relacionar la estructura de los datos ingresados y hallar un tipo de orden que ayude en el análisis [32].

Algunos métodos usados en este clasificador son los siguientes:

- Agrupamiento de K-Medias.
- Clusterización Jerárquica.
- Agrupamiento Jerárquico.
- Modelo de Agrupamiento Gaussiano.

#### 2.1.2 Clasificador supervisado

A diferencia del anterior, este clasificador trabaja con datos etiquetados, busca relación con los datos de entrada para asignar una etiqueta de salida correcta. El algoritmo relaciona entre los datos ingresados y sus etiquetas y aplica esa relación de entrenamiento para clasificar nuevos datos que no hayan sido ingresados ni entrenados con anterioridad [33].

Este clasificador se emplea en problemas de clasificación y problemas de regresión.

Existen diferentes tipos de algoritmos de clasificación supervisado citando algunos:

- Regresión por mínimos cuadrados.
- Support Vector Machines (SVM).
- Regresión Logística.
- Bayesiano Ingenuo.
  
- Vecinos más cercanos (k-nn).
- Árboles de decisión.

Mencionando los dos tipos de aprendizaje en los clasificadores es difícil identificar el mejor algoritmo para usar sin aplicarlo. La selección de un algoritmo depende del tamaño de los datos, el tipo de los mismos y las conclusiones que se quieran extraer de él [34].

El algoritmo k-nn es uno de los clasificadores más utilizados para el reconocimiento de patrones, por tal motivo, sería el algoritmo a utilizarse en el análisis de identificación de causa raíz de fallas en líneas de transmisión [35].

## 2.2 Método de vecinos más cercanos (k-nn)

Es un algoritmo que pertenece a la categoría de clasificador probabilístico de aprendizaje supervisado, el método de k vecinos más cercanos (k-nn por sus siglas en inglés) es un clasificador que permite asignar una categoría a un nuevo objetivo (dato, número) se basa en sus k vecinos más cercanos, a los cuales con

anterioridad durante la etapa de entrenamiento se les asigna una categoría [36].

El método consiste en elegir un valor adecuado de k, donde k es el número de clases vecinas más cercanas a un caso de prueba. Durante la etapa de predicción los k datos más cercanos al nuevo punto que se requiere predecir se tomará como solución como se muestra en la Figura 3 y 4. Definido el valor de k, para clasificar, el algoritmo k-nn calcula la distancia del nuevo objeto hacia cada uno de los datos existentes basándose en sus vecinos más cercanos, ordenando las distancias de menor a mayor para asignar al grupo al que pertenece.

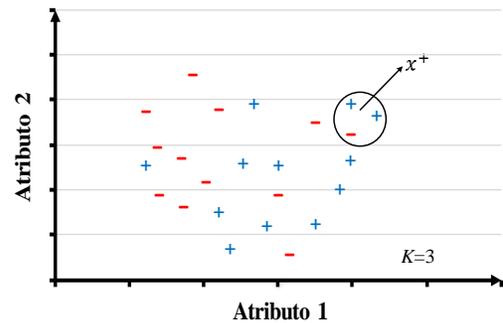


Figura 2. Clasificador k-nn con valor de k=3

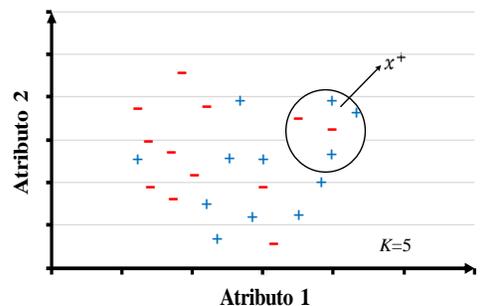


Figura 3. Clasificador k-nn con valor de k=5

En la implementación de este método, cada evento se representa por un vector como se muestra en (1):

$$(x_s, y_t) = (x_{s1}, x_{s2}, \dots, x_{sp}, y_t) \quad (1)$$

Las ecuaciones para hallar los puntos más cercanos están dadas por (2), (3), (4) y (5):

Distancia Euclidiana

$$d_{st}^2 = (x_s - y_t)(x_s - y_t)' \quad (2)$$

Distancia Manhattan:

$$d_{st} = \sum_{j=1}^k |x_{sj} - y_{tj}| \quad (3)$$

Distancia Minkowski:

$$d_{st} = \sqrt[p]{\sum_{j=1}^n |x_{sj} - y_{tj}|^p} \quad (4)$$

Distancia Chebychev

$$d_{st} = \max_j \{|x_{sj} - y_{tj}|\} \quad (5)$$

Donde:

$d_{st}$ : Distancia a calcular.

$x_s$ : Variables predictoras.

$y_t$ : Etiqueta o categoría.

Siendo la más conocida y utilizada la distancia euclidiana (2), la misma que será empleada en este trabajo.

El cálculo de la distancia detecta la similitud entre los datos entrenados y los datos de prueba, posterior al cálculo ordena esas distancias de menor a mayor para asignar al grupo al que pertenece [37]. Para evaluar la precisión del método se calcula el error absoluto descrito en la ecuación (6):

$$E_{abso} [\%] = \frac{f(x_{qest}) - f(x_{qreal})}{x_{qtotal}} \times 100 \quad (6)$$

Donde:

$x_{qest}$ : distancia estimada por el método.

$x_{qreal}$ : distancia real al punto de etiqueta correcto.

$x_{qtotal}$ : distancia total entre el conjunto de datos.

### 3 METODOLOGÍA Y PLANTEAMIENTO DEL PROBLEMA

En el actual artículo, el modelo basado en el cálculo entre las distancias del conjunto a clasificar y un conjunto de referencia se utiliza para la identificación y el diagnóstico de fallas en líneas de transmisión.

#### 3.1 Problema

El Sistema Nacional de Transmisión del Ecuador comprende alrededor de 6.016 km de líneas operadas a voltajes de 138, 230 y 500 kV, de las cuales la mayoría son líneas de 138 kV y 230 kV. Para el período de 2015 a 2020, se registraron aproximadamente 637 fallas de línea [38].

Las descargas atmosféricas fueron responsables del 26% de las fallas, el 16% fueron causadas por vegetación, incendios (causados por flameo de aisladores, quema de caña y/o incendios forestales), contaminación y el 58% restante catalogado como otros contempla fallas por equipo, por maniobras, etc. (Figura 2).

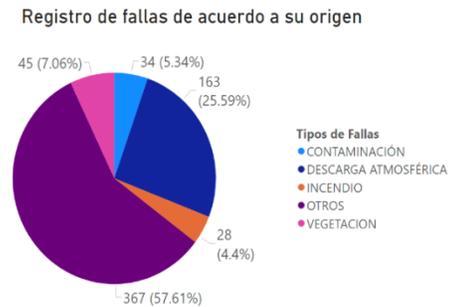


Figura 4. Registro de fallas en líneas de transmisión periodo 2015 – 2020

De acuerdo con los datos de la Figura 2, las fallas por descargas atmosféricas son las que mayor porcentaje de incidencia presentan, causando un considerable impacto en la red eléctrica. Bajo estos antecedentes, se tiene como objetivo establecer una metodología para caracterizar fallas por descargas eléctricas en líneas de transmisión mediante la búsqueda de patrones utilizando minería de datos.

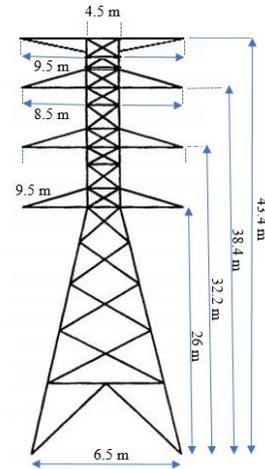
Se ha fijado probar el modelo k-nn estableciendo tres casos de estudio k=7,8 y 9 con el objetivo de elegir el valor de k más adecuado y el que mejor precisión presente.

Para el análisis de los efectos de las descargas atmosféricas se determinó el tipo de torre más representativo de la línea con más fallas registradas para modelarla. Las líneas con más fallas registradas se muestran en la tabla 1:

**Tabla 1** Circuitos con mayor incidencia de descargas atmosféricas

Nivel de tensión [kV]	Circuito	N° de eventos
138	Tena- Francisco de Orellana	26
230	Pomasqui – Santa Rosa	39

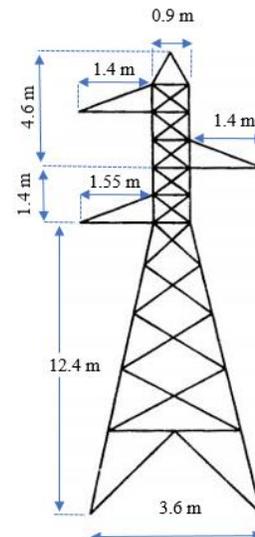
Los parámetros para la modelación en ATPDraw de las torres se muestran en la Figura 5 y Figura 4:



**Figura 5** Distancias torre de transmisión de 230 kV

**Tabla 2** Parámetros línea 230 kV

Parámetro	Descripción
Distancia	46 km
Circuito	Línea de doble circuito
Nivel de voltaje	230 kV
Conductores de fase	2 x 750 ACAR
Resistividad del suelo	100 m*Ω
Frecuencia	60 Hz
Hilo de guarda	Tipo Allumoweld AW No.9



**Figura 6.** Distancias torre de transmisión de 138 kV

**Tabla 3** Parámetros línea 138 kV

Parámetro	Descripción
Distancia	142 km
Circuito	Línea de un circuito
Nivel de voltaje	138 kV
Conductor	ACSR BRANT 397.5
Resistividad del suelo	100 m*Ω
Frecuencia	60 Hz
Cable de guarda	Acero galvanizado

### 3.2 Implementación en ATPDraw

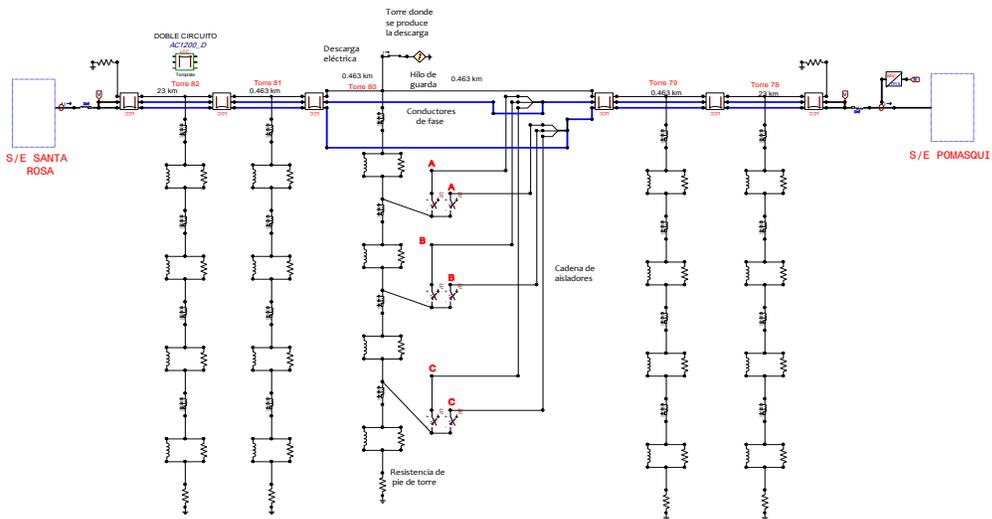
Con la finalidad de identificar la influencia de sobrevoltajes causados por descargas atmosféricas se modeló en ATPDraw la estructura de una torre tanto para 138 kV y 230 kV con el objetivo de analizar el sobrevoltaje que se produce en la torre afectada y como este llega a producir una descarga en una de las fases de la línea de transmisión, con estas consideraciones se simuló una onda de rayo con características estándar.

Para el estudio de la influencia por incendios que se producen cercanos a la línea de transmisión e incluso torres de transmisión, se simuló la reducción de la

rigidez dieléctrica que hay en un aislador y/o entre fases reduciendo la rigidez dieléctrica. Los aisladores fueron simulados mediante interruptores controlados por voltaje por lo tanto fue posible reducir la rigidez para simular el comportamiento de un incendio.

Adicionalmente se tomó en consideración la influencia de la puesta a tierra de las torres que influye positiva y negativamente en los sobrevoltajes producidos por rayos. Para el análisis de los efectos de sobrevoltajes por descargas atmosféricas e incendio, no es necesario representar la línea completa, en esta investigación, se modeló la torre afectada con sus respectivos aisladores y a cada lado de esta se representó dos vanos con sus respectivas estructuras, entre cada torre hay una distancia de 0.436 kilómetros. La representación de la torre por ser superior a una altura de 25 metros en ambos casos se empleó el modelo multipiso.

A continuación se muestran los circuitos implementados en el entorno de ATPDraw .



**Figura 7** Implementación del circuito Santo Rosa - Pomasqui. Simulación con descarga eléctrica.

En la Figura 8, se presenta el circuito simulando una falla por incendio (flameo en aisladores, incendio por quema de caña de azúcar) en la línea de 230 kV, se puede observar en la fase C que se encuentra marcada con líneas entrecortadas es el punto donde se simuló el aislador mediante un interruptor de voltaje con el cual es posible reducir la rigidez dieléctrica.

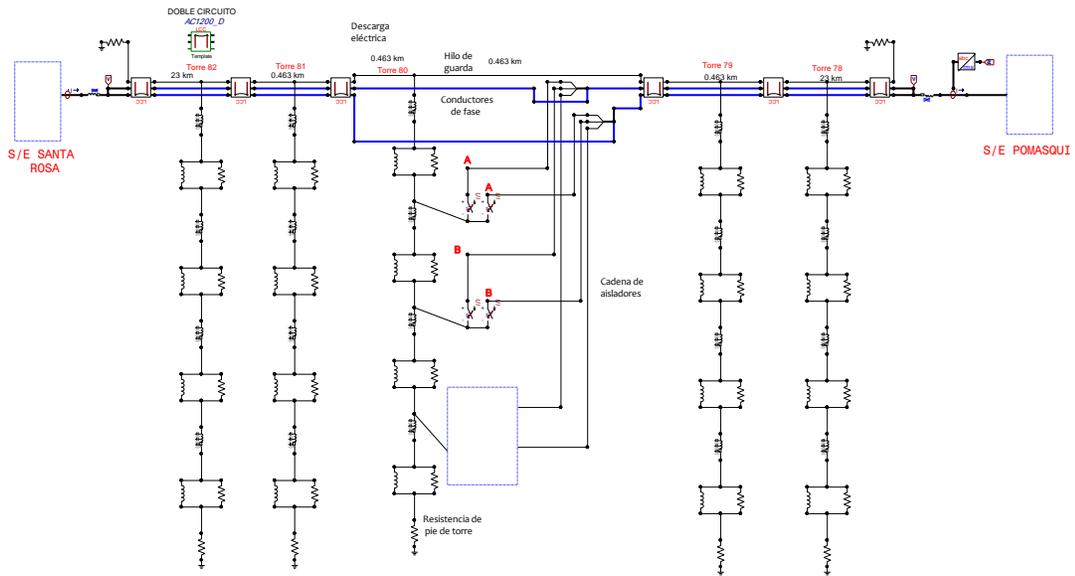


Figura 8 Implementación del circuito Santo Rosa - Pomasqui. Simulación con pérdida de rigidez dieléctrica.

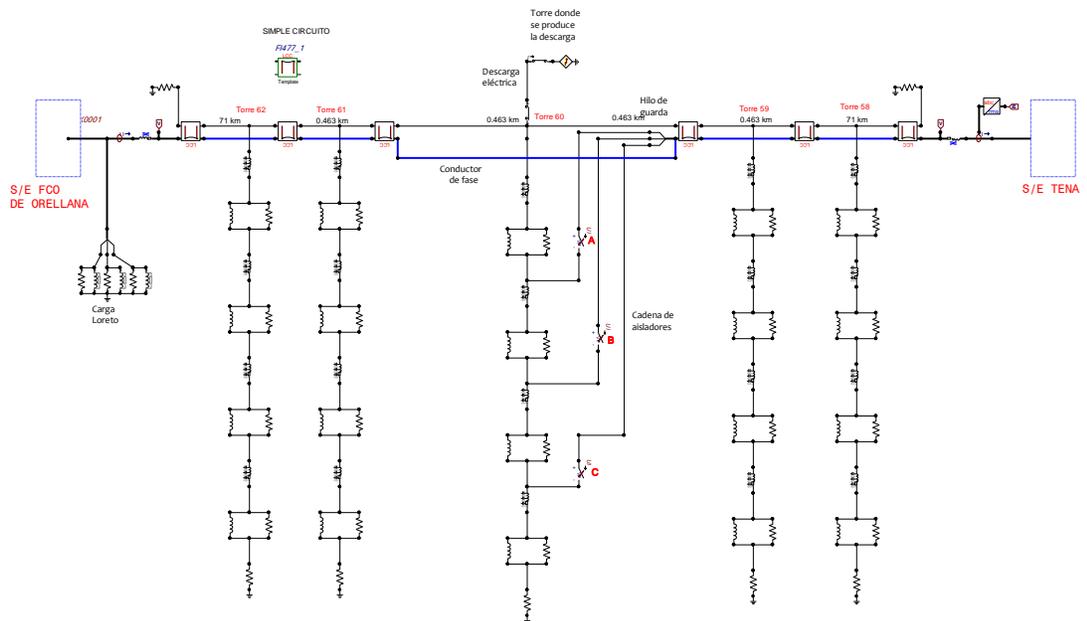
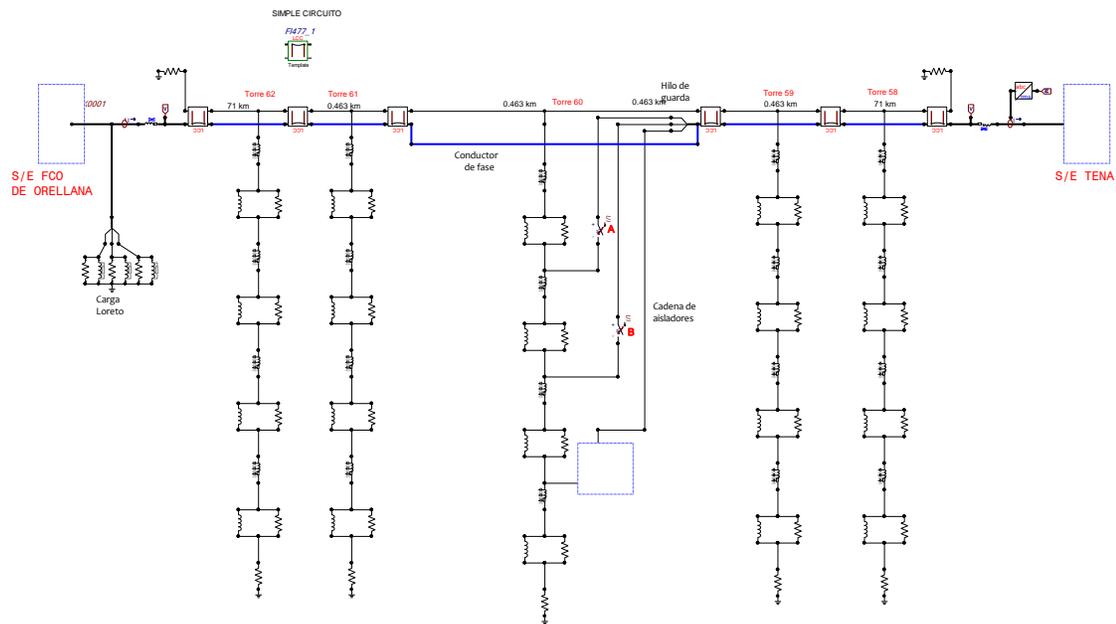


Figura 9. Implementación del circuito Tena - Fco de Orellana. Simulación con descarga eléctrica.

En la Figura 10, se presenta el circuito simulando una falla por incendio (flameo en aisladores, incendio por quema de caña de azúcar) en la línea de 138 kV, se puede observar como en la estructura de la torre en la fase C que se encuentra marcada con líneas entrecortadas es el punto donde se simuló el aislador mediante un interruptor de voltaje con el cual es posible reducir la rigidez dieléctrica.



**Figura 10.** Implementación del circuito Tena – Fco. de Orellana. Simulación con pérdida de rigidez dieléctrica

La selección de atributos se realizó mediante el análisis de señales de corriente y voltaje obtenidos en la simulación de fallas por descargas atmosféricas e incendio, mediante la herramienta de ATPDraw, para las líneas de transmisión indicadas en la tabla 1. Una vez ejecutadas las simulaciones antes mencionadas, los atributos escogidos para cada entrenamiento del clasificador se muestran en la tabla 4:

**Tabla 4** Lista de atributos seleccionados

No	Atributo
1	Fases falladas
2	Punto de inceptión de falla
3	Impedancia de falla
4	Nivel de voltaje

#### 4 CARACTERIZACIÓN DE LA FORMA DE ONDA

Aplicando minería de datos en los registros de fallas de los últimos cinco años proporcionada por CELEC EP TRANSELECTRIC, se realizó la exploración de toda la información de los eventos de interés. Inicialmente se contaba con una base de 191 registros entre fallas por descargas atmosféricas e incendios, posterior al análisis se hizo una limpieza de registros obteniendo un total de 147 eventos, los registros descartados presentaban información incompleta, oscilografías no requeridas por lo cual no fueron considerados.

Esta base de datos proporciona la causa de la falla, el nivel de tensión de la línea de transmisión, corrientes y voltajes de falla, además las condiciones climáticas. Esta información se traduce en una adecuada base de datos para realizar la identificación de la causa de falla.

Una vez definidos los 147 registros de fallas útiles se procedió a la extracción de características mediante sus oscilografías tomando en cuenta los atributos expuestos en la tabla 4 definidos a partir de la modelación en ATPDraw.

#### 4.1 Adquisición de datos en las formas de onda

Para la identificación de la causa raíz de las fallas, es importante contar con la mayor cantidad de características que permitan representar su causa de origen. En esta investigación se analizan parámetros eléctricos y no eléctricos con el objetivo de extraer dichas características.

##### 4.1.1 Parámetros eléctricos

Estas características se obtienen mediante el análisis de la forma de onda, de las cuales a partir de los datos de corriente y voltaje se obtienen los atributos necesarios para la caracterización. Las contingencias por descargas atmosféricas e incendios muestran diferentes mecanismos de falla, esto produce características que se muestran en las formas de onda permitiendo discriminar una falla de la otra.

##### 4.1.1.1 Tipos de fallas

En las fases defectuosas encontradas en la identificación de la causa raíz, se toman las fases que fueron afectadas

como una característica de la señal, esto nos ayuda a encontrar patrones de acuerdo con la causa de origen considerando en qué fase se presentan mayor incidencia de fallas. Los resultados se exponen en la tabla 5.

**Tabla 5** Tipos de fallas según su causa raíz

Fases Fallidas	Descarga atmosférica	Incendio
Línea tierra	90	15
Doble línea	10	7
Doble línea tierra	7	4
Trifásica	12	2
Total	119	28

##### 4.1.1.2 Punto de inyección de falla

Al producirse una falla en un tiempo  $t$  segundos, los datos obtenidos en la onda de voltaje en 10 ms posteriores a la falla son extraídos como características con el fin de encontrar el punto de inyección y calcular la tasa de cambio con respecto al voltaje operativo que tenía la línea de transmisión antes del fallo para conocer el punto de origen en el que se produce la contingencia.

Una vez analizadas las oscilografías de corriente y voltaje de 147 eventos entre descargas atmosféricas e incendios se muestra la media y la desviación estándar de esos resultados.

**Tabla 6** Valor medio y desviación estándar del punto de inyección de falla

Tipo	Media	Desviación estándar
Fallas por descargas atmosféricas	0.811	9.96
Fallas por incendio	0.8515	0.124

#### 4.1.1.3 Impedancia de falla

La magnitud de impedancia de falla es un buen indicador en la identificación de la causa de la falla, este parámetro se calcula a partir del voltaje de fase y la corriente como se describe en (6). Se toma el valor mínimo de la impedancia de falla para coordinar con la peor condición de falla que el voltaje de la fase durante la falla haya alcanzado con respecto a su caída máxima de voltaje [39].

$$Z_{falla} = \min \left( \left| \frac{V_i \angle \theta_i}{I_n \angle \phi_i} \right| \right) \quad (6)$$

Donde:

$V_i$ : Magnitud del voltaje de la fase afectada.

$\theta_i$ : Ángulo de fase del voltaje de la fase afectada.

$I_n$ : Magnitud fundamental de la corriente.

$i$ : Número del ciclo de corriente, tensión en la falla.

$\phi_i$ : Ángulo de fase de la corriente.

En base a los resultados obtenidos, se tiene que la impedancia de falla por descargas atmosféricas es inferior a  $10 \Omega$ , por otra parte, la impedancia de falla por incendio es superior a  $100 \Omega$ . Este atributo contribuye a discriminar con mayor facilidad eventos por descargas atmosféricas e incendios.

#### 4.1.2 Tasa de cambio de corriente

Esta característica, en la forma de onda de corriente representa la pendiente que se produce debido al aumento de la corriente de falla. Debido a que la corriente neutra permanece en el mismo patrón independientemente de la

ubicación y la impedancia de la falla se escogió este tipo de corriente.

$$I_n(t, \lambda) = 1 - e^{-\lambda t} \quad (7)$$

Donde:

$I_n(t, \lambda)$ : Magnitud de la raíz cuadrada media (rms) de la corriente neutra tomada con una constante.

$t$ : Tiempo en milisegundos

$\lambda$ : Tasa de cambio de la corriente neutra en pu/ ms.

#### 4.1.3 Parámetros no eléctricos

Esta característica se la obtiene mediante un análisis basado en factores ambientales.

##### 4.1.3.1 Condiciones climáticas

Esta característica tiene una gran importancia en la identificación de la causa raíz de las fallas, cada evento tiene una probabilidad de ocurrir en un cierto ambiente, en mayor detalle, las fallas por descargas atmosféricas tienen gran probabilidad de ocurrir en un ambiente lluvioso, con tormentas eléctricas.

Por otra parte, las contingencias por incendio que en Ecuador mayoritariamente son de tipo forestal producto de la quema de caña, se presentan en ambientes secos y con viento. Por lo tanto, se manejarán 5 tipos de clima: nublado, lluvia, tormentas eléctricas, despejado y viento.

El método k-nn requiere que los datos de entrada se mantengan numéricos; por tanto, para poder usar el atributo de clima se aplicó lógica difusa para describir las condiciones climáticas en un valor

numérico. Se manejó el criterio de ir en tendencia de clima cálido hacia clima con menor temperatura.

Para aplicar el método de lógica difusa se realiza las siguientes consideraciones:

- Los términos usados para describir el clima son los manejados por el centro de operaciones del Ecuador durante el registro de fallas en líneas de transmisión.
- Se maneja un eje horizontal que va desde 0% a 100%.
- Rangos por encima del 50%, indican buenas condiciones climáticas (viento, soleado).
- Rango igual a 50% indica clima nublado.
- Rangos por debajo del 50%, indican temperaturas inferiores con mayor probabilidad de lluvias y tormentas eléctricas.

Mediante la implementación de la técnica lógica difusa, se puede definir en qué porcentaje se encuentra la condición climática en cada evento de falla de forma normalizada.

**Tabla 7** Lógica difusa para condiciones climáticas

Condición Climática	Aplicando lógica difusa	Entrada método k-nn
Despejado	100%	1
Viento	70%	0.70
Nublado	50%	0.50
Lluvia	30%	0.30
Tormentas eléctricas	10%	0.10

Finalmente, en la tabla 8 se muestra los atributos que en su conjunto servirán para entrenar el modelo:

**Tabla 8** Atributos para entrenar el modelo k-nn

No	Atributo
1	Tipo de falla
2	Punto de inyección de falla
3	Impedancia de falla
4	Tasa de cambio de corriente
5	Nivel de voltaje de la torre
6	Condiciones climáticas

## 5 METODOLOGÍA PROPUESTA

En este trabajo se analizan las fallas causadas por dos factores externos, incendios y descargas atmosféricas, basándose en un modelo de aprendizaje supervisado. El clasificador para implementar es el algoritmo de k-nn, el cual reconoce patrones en los datos, solo calculando la distancia entre grupos de datos.

El conjunto de muestras se dividió en un conjunto de entrenamiento y un conjunto de prueba como se muestra en la tabla 9.

El número de muestras de entrenamiento se estableció en el 60% del número total de muestras, mientras que el 40% restante se estableció para prueba y posterior validación del modelo.

**Tabla 9** Distribución datos para entrenar y validar el modelo según su causa de origen

Causa de la falla	Muestras totales	Muestras de entrenamiento	Muestras de prueba
Descargas atmosféricas	119	71	48
Incendio	28	17	11

### 5.1 Normalización de datos

En este trabajo los atributos definidos para entrenar el modelo cuentan con variables que se miden en diferentes unidades (Amperios, Voltios, Ohmios), por lo tanto, para hacer que los datos sean

comparables y poder calcular las distancias entre los atributos, se requiere normalizar los valores.

Para la normalización de atributos se emplea la ecuación (8):

$$X_s = \frac{X - \min}{\max - \min} \quad (8)$$

Donde:

$X$ : Valor a estandarizar

$\min$ : Valor mínimo de la muestra a la que pertenece

$\max$ : Valor máximo de la muestra a la que pertenece

Una vez generados los atributos normalizados para la implementación del modelo k-nn se obtiene una matriz de dimensiones 177 x 6, la cual representa los registros de fallas con sus atributos.

Debido a la gran cantidad de datos, en la tabla 10 se muestra un resumen de los atributos normalizados considerando la media para cada uno de ellos.

**Tabla 10** Media de los valores de los atributos

Atributo	Valor medio
Tipo de falla	0.20
Punto de origen de falla	0.81
Impedancia de falla	0.34
Nivel voltaje	0.89
Tasa de cambio de falla	0.29
Condiciones climáticas	0.50

## 5.2 Proceso de identificación de causa raíz

Para la implementación del modelo k-nn se utilizó la herramienta de MATLAB, se crea una matriz con los

datos de cada uno de los atributos involucrados como se muestra en la Figura 11, estos datos son procesados en Matlab mediante el toolbox Apps / Clasificador Learner / Clasificador KNN, en donde se define el porcentaje para entrenar y probar el modelo, posterior se ingresa el valor de k.

	$X_1$	..	$X_3$	..	$X_5$	C
$(x_1, c_1)$	$x_{1-1}$	..	$x_{3-1}$	..	$x_{5-1}$	$c_1$
$(x_{88}, c_1)$	$x_{1-88}$	..	$x_{3-88}$	..	$x_{5-88}$	$c_1$
$(x_{177}, c_2)$	$x_{1-177}$	..	$x_{3-177}$	..	$x_{5-177}$	$c_2$
x	$x_{1-177}$	..	$x_{3-177}$	..	$x_{5-177}$	?

**Figura 11.** Notación matriz k-nn

El pseudocódigo correspondiente a esta metodología se muestra a continuación:

### Pseudocódigo método k-nn

**Paso 1:** Entrada de datos para entrenamiento del método.

$$D = \{(x_1, c_1), \dots, (x_N, c_N)\}$$

**Paso 2: Clasificar:**

$$x = (x_1, \dots, x_n)$$

Nuevos datos a categorizar, muestras de prueba de descargas e incendio.

**Paso 3: Calcular:** Distancias a partir de los datos entrenados y categorizados.

$$d_i = d(x_i, x)$$

**Paso 4: Ordenar:** Distancias calculadas en orden ascendente.

$$d_i (i = 1, \dots, N)$$

**Paso 5: Indicar:** Casos  $D_x^K$  ya categorizados próximos a x, y.

**Paso 6: Asignar:** La categoría x (datos incendio), y (datos descargas atmosféricas)

**Paso 7 Calcular:** La precisión del modelo bajo el criterio del k que se haya escogido

**Paso 8: Resultados:**  
 Grafica de dispersión  
 Matriz de confusión

FIN

## 6 ANÁLISIS DE RESULTADOS

Con el objetivo de obtener la mejor precisión del modelo se fijaron tres escenarios para k=7,8 y 9.

Los resultados del modelo k-nn se presentan por medio de una matriz de confusión, en la diagonal de la matriz se encuentran los resultados positivos que fueron etiquetados de forma correcta.

Como se indicó en la sección 5 de este documento, para la comprobación del modelo se reservaron el 40% del total de las muestras de cada categoría (11 datos para incendio y 48 datos para descargas eléctricas).

Bajo estas consideraciones se tienen los siguientes resultados:

### 6.1 Resultados con un modelo k-nn con una constante de precisión k=7

#### 6.1.1 Resultados para el modelo de entrenamiento

En la figura 9, se muestran las categorías generadas por el modelo k-nn mediante una gráfica de dispersión, considerando un valor de k=7. La figura 9 muestra los datos que fueron reconocidos mediante patrones de forma correcta y también los datos que fueron etiquetados de forma incorrecta.



Figura 12. Conjunto de muestras entrenadas y validadas para k=7

La tabla 11 resume la cantidad de datos que fueron validados correctamente por el modelo con respecto al tipo origen causa de falla eléctrica. El entrenamiento el modelo genera una precisión de clasificación del 91.67% para Descargas atmosféricas y un 90% para Incendio.

Tabla 11 Resultados de clasificación de datos en entrenamiento para k=7.

<b>Origen de falla: Descargas atmosféricas</b>	
Datos a validar	48
Datos válidos	44
<b>Origen de falla: Incendio</b>	
Datos a validar	10
Datos válidos	9

Finalmente, la figura 10 presenta la matriz de confusión del modelo entrenado.

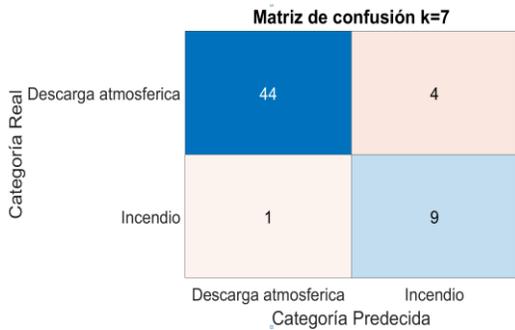


Figura 13. Matriz de confusión para k=7

### 6.1.2 Resultados de predicción con el modelo entrenado

Una vez el modelo fue entrenado con el 60% de los datos generados, se utilizó el 40% restantes de los cuales se conoce desde un inicio la categoría de tipo de origen de falla a la cual pertenecen (Descargas atmosféricas o Incendio) a fin de determinar la exactitud con la que el modelo clasificará los datos.

En la figura 11, se puede observar que la exactitud de predicción para datos de falla de origen descarga atmosférica es del 91.7% y la exactitud para fallas de origen incendio es del 90%. Ambos valores indican que este modelo tiene una exactitud elevada y es perfectamente capaz de identificar las fallas de acuerdo a su causa-origen.

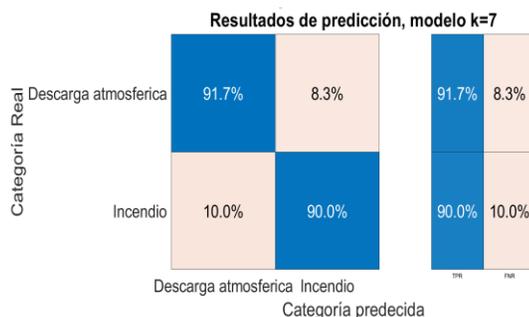


Figura 14. Resultados del modelo de predicción para k=7

## 6.2 Resultados con un modelo k-nn con una constante de precisión k=8

### 6.2.1 Resultados para el modelo de entrenamiento

En la figura 12, se muestran las categorías generadas por el modelo k-nn mediante una gráfica de dispersión, considerando un valor de k=8. En esta figura se muestra que datos fueron reconocidos mediante patrones de forma correcta y también los datos que fueron etiquetados de forma incorrecta.

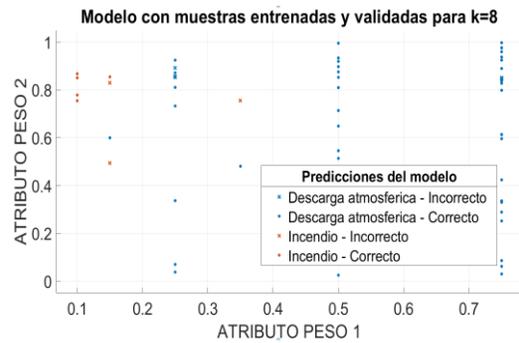


Figura 15. Conjunto de muestras entrenadas y validadas para k=8

Como se puede observar en la tabla 12, el entrenamiento el modelo genera una precisión de clasificación del 93.75% para Descargas atmosféricas y un 50% para Incendio.

Tabla 12 Resultados de clasificación de datos en entrenamiento para k=8.

Origen de falla: Descargas atmosféricas	
Datos a validar	48
Datos válidos	45
Origen de falla: Incendio	
Datos a validar	10
Datos validos	5

Finalmente, la figura 13 presenta la matriz de confusión del modelo entrenado.

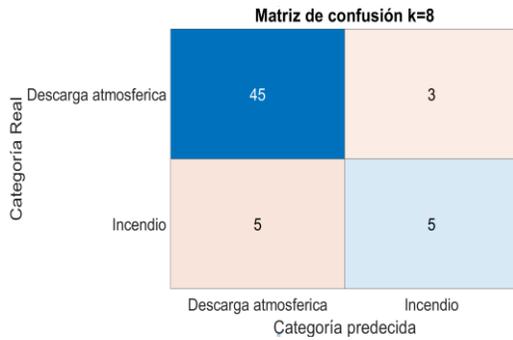


Figura 16. Matriz de confusión para k=8

### 6.2.2 Resultados de predicción con el modelo entrenado

Al igual que en la sección 6.1.2, una vez el modelo fue entrenado con el 60% de los datos generados, se utilizó el 40% restantes para la validación de la exactitud de la predicción del modelo.

En la figura 14, se puede observar que la exactitud de predicción para datos de falla de origen descarga atmosférica es del 93.8% y la exactitud para fallas de origen incendio es del 50% la cual quiere decir que el modelo no puede definir si estos datos corresponden a fallas de origen de descarga atmosférica o incendio.

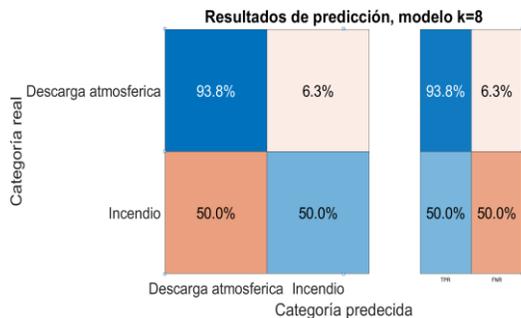


Figura 17. Resultados del modelo de predicción para k=8

## 6.3 Resultados con un modelo k-nn con una constante de precisión k=9

### 6.3.1 Resultados para el modelo de entrenamiento

En la figura 15, se muestran las categorías generadas por el modelo k-nn mediante una gráfica de dispersión, considerando un valor de k=9. En esta figura se muestra que datos fueron reconocidos mediante patrones de forma correcta y también los datos que fueron etiquetados de forma incorrecta.

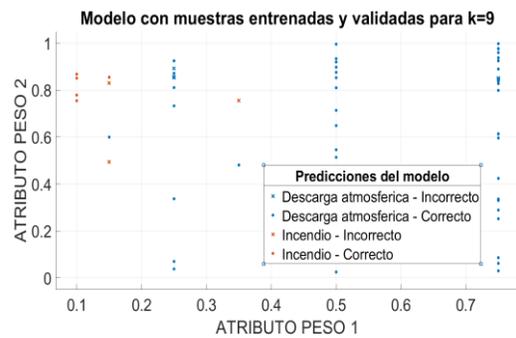


Figura 18. Conjunto de muestras entrenadas y validadas para k=9

La tabla 13 resume la cantidad de datos que fueron validados correctamente por el modelo con respecto al tipo origen causa de falla eléctrica. El entrenamiento el modelo genera una precisión de clasificación del 93.75% para Descargas atmosféricas y un 50% para Incendio (ambos resultados idénticos al escenario de k=8).

Tabla 13 Resultados de clasificación de datos en entrenamiento para k=9.

Origen de falla: Descargas atmosféricas	
Datos a validar	48
Datos válidos	45
Origen de falla: Incendio	
Datos a validar	10
Datos válidos	5

Finalmente, la figura 16 presenta la matriz de confusión del modelo entrenado.

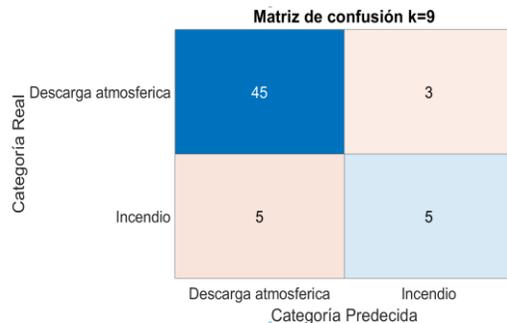


Figura 19. Matriz de confusión para k=9

### 6.3.2 Resultados de predicción con el modelo entrenado

Al igual que en las secciones anteriores, una vez el modelo fue entrenado con el 60% de los datos generados, se utilizó el 40% restantes para la validación de la exactitud de la predicción del modelo.

En la figura 17, se puede observar que la exactitud de predicción para datos de falla de origen descarga atmosférica es del 93.8% y la exactitud para fallas de origen incendio es del 50%, por tanto, el modelo se comporta de forma idéntica que con k=8 y no es capaz de definir si estos datos (incendio) corresponden a fallas de origen de descarga atmosférica o incendio.

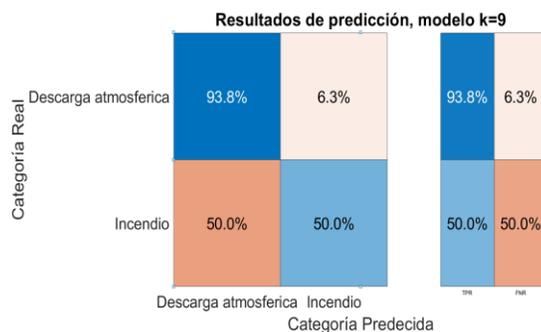


Figura 20. Resultados del modelo de predicción para k=9

## 7 CONCLUSIONES

A partir de los resultados obtenidos, se puede concluir que:

En este artículo se propuso una metodología que ayude en la identificación de la causa raíz de fallas en líneas de transmisión mediante la búsqueda de patrones utilizando minería de datos.

El software ATPDraw permite simular fenómenos transitorios, para esta investigación la herramienta permitió realizar la simulación de descargas atmosféricas directas e indirectas y por pérdida de rigidez dieléctrica en los aisladores en dos estructuras de torres para 138 kilovoltios y 230 kilovoltios, bajo el modelo JMarti y la modelación de las torres se pudo establecer características que permitan discriminar cada tipo de falla permitiendo definir los atributos usados en el modelo vecinos más cercanos k-nn.

El método empleado, el clasificador k-nn, que para este caso utilizó parámetros eléctricos y no eléctricos con el propósito de demostrar la efectividad del mismo cumpliendo con su objetivo, la aplicación de prueba de los tres valores de k (k=7,8 y 9) tuvieron por objeto mostrar el valor de vecinos más cercanos que se ajuste mejor al modelo con una mayor precisión, con esto también se pudo determinar que la parte más importante del método k-nn es seleccionar un valor adecuado de k, ya que si el valor es muy pequeño o muy grande se puede sobreajustar el modelo arrojando resultados erróneos. Durante la realización del artículo se tuvo en consideración normalizar todos los datos para el entrenamiento del método con la

finalidad que la predicción sea lo más real posible.

El escenario propuesto con valor de  $k=7$ , alcanzó una precisión del 91.4%.

Para el escenario con valor de  $k=8$  y  $k=9$ , la precisión alcanzada es de 86.2%.

Bajo esos resultados se toma como mejor opción el valor de  $k=7$ , la prueba exitosa del método propuesto demuestra su validez para la identificación de fallas por descargas atmosféricas.

La herramienta de MATLAB brinda una rápida y fácil implementación del modelo  $k$ -nn, por tal motivo, combinado con la modelación realizada en ATPDraw aporta una mejor precisión de los resultados obtenidos, brindando un alto grado de confianza de la metodología propuesta.

El método propuesto tiene el propósito de ayudar en la rápida identificación de la causa raíz de fallas en las líneas de transmisión brindando como beneficio una rápida y adecuada intervención según el tipo de falla, reduciendo el gasto y tiempo en el despliegue de personal para identificar la falla, dando como ventaja, solucionar la falla en el menor tiempo posible y la intervención de personal solo en casos que así lo requieran.

## 8 TRABAJOS FUTUROS

El presente trabajo, posterior a las observaciones realizadas y durante su realización brinda las siguientes opciones de trabajos futuros.

Generar una metodología considerando un enfoque basado en la magnitud de corriente rms, con el fin de obtener más atributos que permitan caracterizar con mayor precisión.

Analizar la influencia de la contaminación y vegetación/árboles con el fin de abarcar más fallas del sistema de transmisión.

Extraer características, como la caída de voltaje de pu en la fase con falla, para determinar la causa raíz de las fallas, esto implica la cuantificación de la relevancia de estas características y la extracción de patrones para formar un conjunto de reglas.

## 9 REFERENCIAS

- [1] S. Klingert, F. Niedermeier, C. Dupont, G. Giuliani, T. Schulze, and H. de Meer, "Renewable Energy-aware Data Centre Operations for Smart Cities - The {DC}4Cities Approach," in *Proceedings of the 4th International Conference on Smart Cities and Green {ICT} Systems*, 2015.
- [2] A. Águila Téllez, G. López, I. Isaac, and J. W. González, "Optimal reactive power compensation in electrical distribution systems with distributed resources. Review," *Heliyon*, vol. 4, no. 8, p. e00746, Aug. 2018.
- [3] J. Pablo, V. Villa, D. Villegas, J. Felipe, and Q. Zuluaga, "Modernización del esquema de separación de áreas -ESA- entre Colombia y Ecuador con base en medición fasorial," no. August 2020, 2019.
- [4] L. Ortiz, R. Orizondo, A. Aguila, J. W. Gonz, I. Isaac, and J. L. Gabriel, "Hybrid AC / DC microgrid test system simulation: grid-connected mode," *Heliyon*, vol. 5, no. August, p. 21, 2019.
- [5] E. M. García Torres, A. Águila, I. Isaac, J. W. González, and G. López, "Analysis of Voltage Profile to determine Energy Demand using

- Monte Carlo algorithms and Markov Chains (MCMC),” in *Power Engineering Conference (UPEC), 2016 51st International Universities*, 2016, no. Mcmc, pp. 1–6.
- [6] E. M. Inga Ortega, “Redes de Comunicación en Smart Grid,” *Ingenius*, no. 7, pp. 36–55, 2012.
- [7] S. Gómez Alban, “Diagnóstico de fallas en sistema de transmisión por medio del algoritmo de Prony,” p. 21, 2016.
- [8] R. Perez *et al.*, “Fault diagnosis on electrical distribution systems based on fuzzy logic,” *Int. Conf. Sens. Imaging*, vol. 1, pp. 142–150, 2018.
- [9] P. Arias, “Análisis de la estabilidad en pequeña señal del Sistema Nacional Interconectado del Ecuador,” 2013.
- [10] J. A. Calderón, J. Moreno Cadavid, and D. A. Ovalle, “Red neuronal para la clasificación de fallas en líneas de transmisión a partir de registros de osciloperturbografía,” *DYNA*, vol. 75, no. 156, pp. 99–107, 2008.
- [11] M. I. Ridwan, M. R. A. Rahman, B. Yunus, and A. Musa, “Transmission line fault clearing system reliability assessment: Application of life data analysis with weibull distribution and reliability block diagram,” *J. Emerg. Technol. Web Intell.*, vol. 5, no. 2, pp. 107–116, 2013.
- [12] J. Morais, Y. Pires, C. Cardoso, and A. Klautau, “A framework for evaluating automatic classification of underlying causes of disturbances and its application to short-circuit faults,” *IEEE Trans. Power Deliv.*, vol. 25, no. 4, pp. 2083–2094, 2010.
- [13] W. L. A. Neves *et al.*, “Sampling rate of digital fault recorders influence on fault diagnosis,” *2004 IEEE/PES Transm. Distrib. Conf. Expo. Lat. Am.*, pp. 406–411, 2004.
- [14] J. Vasco and A. Aguila, “Design of Automatic Reclosing scheme in distribution feeders,” *IEEE Lat. Am. Trans.*, vol. 13, no. 8, pp. 2587–2593, 2015.
- [15] E. Inga, D. Carrión, A. Aguila, E. García, and R. Hincapié, “Minimal Deployment and Routing Geographic of PMUs on Electrical Power System based on MST Algorithm,” *IEEE Lat. Am. Trans. (Volume 14, Issue 5)*, vol. 14, no. 5, pp. 2264–2270, 2016.
- [16] F. A. Castillo Munoz, A. Aguila Tellez, and J. W. Gonzalez Sanchez, “Analysis of Stability of Tension and Losses of Electric Power in Distribution Networks with Distributed Generation,” *IEEE Lat. Am. Trans.*, vol. 14, no. 11, pp. 4491–4498, 2016.
- [17] J. Arauz and M. Ruiz, “Identificación de fallas en sistemas eléctricos de potencia basado en el reconocimiento de patrones,” p. 20, 2020.
- [18] W. W. Shi, H. S. Van, and K. P. Ma, “A new method of early fault diagnosis based on machine learning,” *2005 Int. Conf. Mach. Learn. Cybern. ICMLC 2005*, no. August, pp. 3271–3276, 2005.
- [19] H. Liang, Y. Liu, G. Sheng, and X. Jiang, “Fault-cause identification method based on adaptive deep belief network and time-frequency characteristics of travelling wave,” *IET Gener. Transm. Distrib.*, vol. 13, no. 5, pp. 724–732, 2019.
- [20] L. Li and H. Zang, “A Fault Cause Identification Methodology for Transmission Lines Based on Support Vector Machines,” *IEEE PES Asia-Pacific Power Energy Conf.*, pp. 1430–1434, 2016.
- [21] M. A. Shuvra, S. Member, and A. Del Rosso, “Root Cause Identification of Power System Faults using

- Waveform Analytics,” *IEEE Lat. Am. Trans.*, pp. 1–8, 2018.
- [22] R. Hongdilokkul and C. Banmongkol, “Classification of Transmission Line Faults with Waveform Characterization,” *IEEE Lat. Am. Trans.*, pp. 1–5, 2016.
- [23] V. B. Núñez, S. Kulkarni, S. Santoso, and J. M. F., “Feature Analysis and Classification Methodology for Overhead Distribution Fault Events,” *IEEE / PES IEEE Transm. Distrib.*, 2010.
- [24] Y. Cai, S. Member, M. Chow, W. Lu, and L. Li, “Data in Distribution Fault Diagnosis,” *Power*, vol. 25, no. 2, pp. 642–648, 2010.
- [25] S. Kulkarni, D. Lee, A. J. Allen, S. Santoso, and T. A. Short, “Waveform Characterization of Animal Contact , Tree Contact , and Lightning Induced Faults,” *IEEE Lat. Am. Trans.*, pp. 1–7, 2010.
- [26] L. Souto, G. Manassero, and S. G. Di Santo, “Fault location in distribution feeders with distributed generation,” *Clemson Univ. Power Syst. Conf. PSC 2016*, 2016.
- [27] I. Kim and R. G. Harley, “A study on the effect of distributed generation on short-circuit current,” *Clemson Univ. Power Syst. Conf. PSC 2016*, 2016.
- [28] J. A. Jiang, Y. H. Lin, J. Z. Yang, T. M. Too, and C. W. Liu, “An adaptive PMU based fault detection/location technique for transmission lines - Part II: PMU implementation and performance evaluation,” *IEEE Trans. Power Deliv.*, vol. 15, no. 4, pp. 1136–1146, 2000.
- [29] T. P. Hinge and S. S. Dambhare, “Novel fault location algorithm for transmission line using synchronized measurements,” *Proc. IEEE Power Eng. Soc. Transm. Distrib. Conf.*, vol. 2016-July, pp. 16–21, 2016.
- [30] G. Rivera and M. Ruiz, “Ubicación de fallas en líneas de transmisión eléctrica basado en el análisis de señales transitorias,” 2020.
- [31] A. Singhal and D. E. Seborg, “Pattern matching in multivariate time series databases using a moving-window approach,” *Ind. Eng. Chem. Res.*, vol. 41, no. 16, pp. 3822–3838, 2002.
- [32] X. Pei and F. N. Chowdhury, “Unsupervised neural network for fault detection and classification in dynamic systems,” *IEEE Conf. Control Appl. - Proc.*, vol. 1, pp. 640–645, 1999.
- [33] J. Quansheng and J. Minping, “Supervised Laplacian Eigenmaps for machinery fault classification,” *2009 WRI World Congr. Comput. Sci. Inf. Eng. CSIE 2009*, vol. 7, pp. 116–120, 2009.
- [34] X. Liu, Y. Wang, and Y. Yang, “Fault Diagnosis Based on Sparse Semi-supervised GAN Model,” *Proc. 32nd Chinese Control Decis. Conf. CCDC 2020*, pp. 5620–5624, 2020.
- [35] Y. Yinghua and W. Xiulong, “Fault diagnosis optimization algorithm based on k nearest neighbor,” *Proc. 31st Chinese Control Decis. Conf. CCDC 2019*, pp. 457–461, 2019.
- [36] S. K. Shukla and E. Koley, “Fault detection and classification in six-phase transmission system using k-nearest neighbour algorithm,” *2017 Int. Conf. Intell. Comput. Instrum. Control Technol. ICICICT 2017*, vol. 2018-January, pp. 542–546, 2018.
- [37] P. P. Wasnik, N. J. Phadkule, and K. D. Thakur, “Fault detection and classification based on semi-supervised machine learning using KNN,” *Proceeding - 1st Int. Conf. Innov. Trends Adv. Eng. Technol. ICITAET 2019*, pp. 79–83, 2019.
- [38] C. TRANSELECTRIC,

“Infraestructura del Sistema Nacional de Transmisión (SNT),” *CELEC Web Site*, 2021. .

- [39] K. Pandakov and H. K. Høidalen, “Distance protection with fault impedance compensation for distribution network with DG,” *2017 IEEE PES Innov. Smart Grid Technol. Conf. Eur. ISGT-Europe 2017 - Proc.*, vol. 2018-January, no. I, pp. 1–6, 2017.

## 1.1 Matriz de Estado del Arte

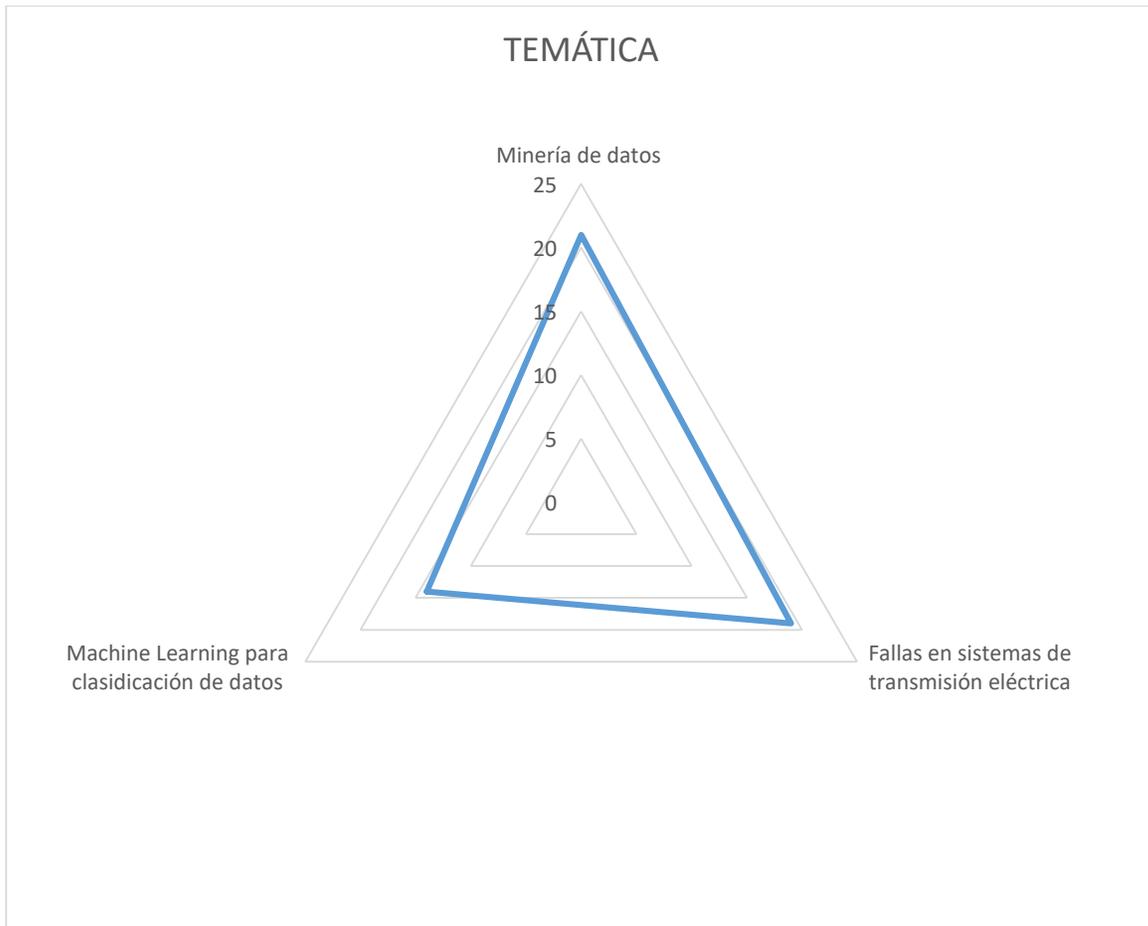
Tabla 14. Matriz de estado del arte

ITEM	DATOS			TEMÁTICA			FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO			RESTRICCIONES DEL PROBLEMA			PROPUESTAS PARA RESOLVER EL PROBLEMA			SOLUCIÓN PROPUESTA				
	AÑO	TÍTULO DEL ARTÍCULO	PAÍS	CITAS	Minería de datos	Fallas en sistemas de transmisión eléctrica	Machine Learning para clasificación de datos	Clasificación de fallas eléctricas de acuerdo a su causa-origen	Análisis de transitorios durante fallas eléctricas	Reconocimiento de patrones para clasificación de fallas	Parámetros eléctricos Del sistema nacional de transmisión eléctrica del Ecuador	Fallas eléctricas tipo origen descarga eléctrica e incendio	Algoritmos supervisados para la clasificación de datos basados en machine learnign	Técnicas computacionales, de machine learning para nearest neighbour classifiers	Extracción de parámetros característicos de señales de corriente y voltaje de acuerdo al origen de falla	Validación de modelos de clasificación de datos en función de la exactitud para predicción de clasificación	Modelamiento de torres de transmisión eléctrica y líneas del sistema nacional de transmisión en ATPDraw	Extracción de atributos de las señales eléctricas durante falla: tipo de falla, inyección de falla, impedancia de falla, tasa de cambio de corriente, etc.	Implementación y entrenamiento de modelo k-nearest para la clasificación de fallas, tomando como punto de partida los atributos extraídos	Verificación del modelo generado mediante la predicción de clasificación de datos con atributos reales de origen conocido
1	2015	Renewable Energy-aware Data Centre Operations for Smart Cities	PORTUGAL	3	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
2	2019	Modernización del esquema de separación de áreas -ESA- entre Colombia y Ecuador con base en medición fasorial	COLOMBIA	2	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3	2012	Redes de Comunicación en Smart Grid	ECUADOR	20	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
4	2016	Diagnóstico de fallas en sistema de transmisión por medio del algoritmo de Prony	ECUADOR	4	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
5	2013	Análisis de la estabilidad en pequeña señal del Sistema Nacional Interconectado del Ecuador	ECUADOR	5	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

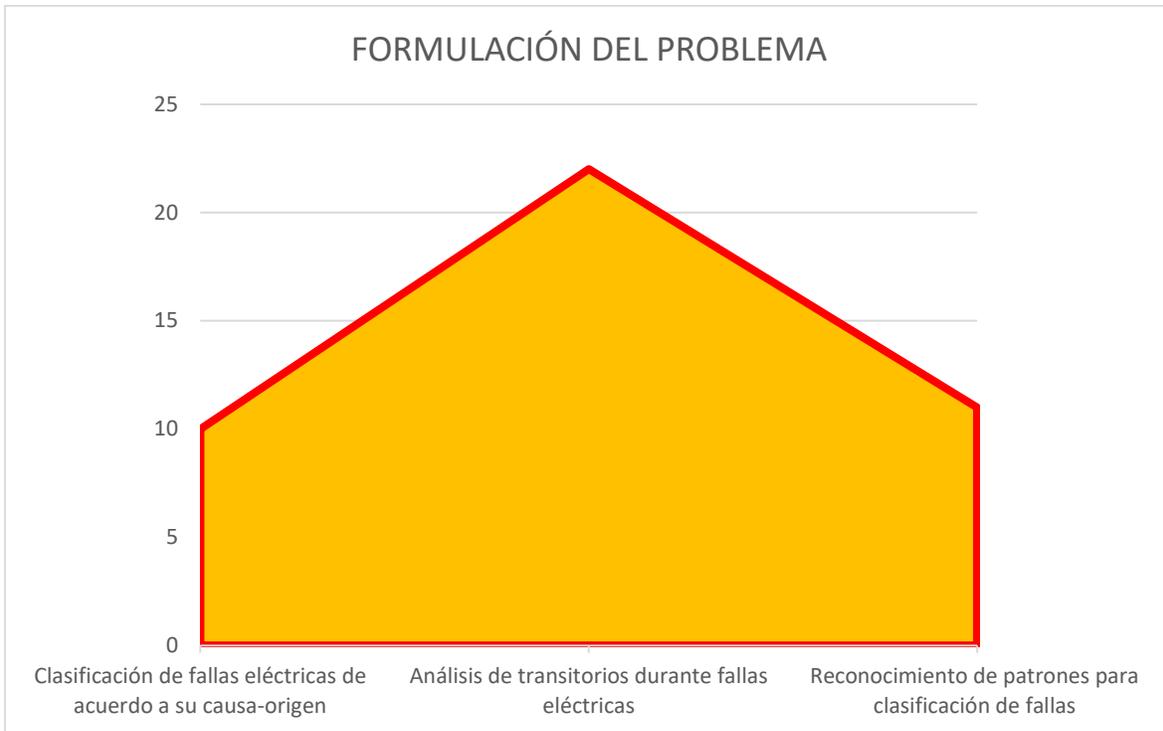
6	2008	Red neuronal para la clasificación de fallas en líneas de transmisión a partir de registros de osciloperturbografía	COLOMBIA	10	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
7	2013	Transmission line fault clearing system reliability assessment: Application of life data analysis with weibull distribution and reliability block diagram	Malaysia	8	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
8	2010	A framework for evaluating automatic classification of underlying causes of disturbances and its application to short-circuit faults	BRAZIL	10	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
9	2004	Sampling rate of digital fault recorders influence on fault diagnosis	BRAZIL	6	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
10	2020	Identificación de fallas en sistemas eléctricos de potencia basado en el reconocimiento de patrones	ECUADOR	3	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
11	2005	A new method of early fault diagnosis based on machine learning	ESTADOS UNIDOS	11	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
12	2019	Fault-cause identification method based on adaptive deep belief network and time-frequency characteristics of travelling wave	REINO UNIDO	3	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
13	2016	A Fault Cause Identification Methodology for Transmission Lines Based on Support Vector Machines	CHINA	3	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
14	2018	Root Cause Identification of Power System Faults using Waveform Analytics	ESTADOS UNIDOS	6	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
15	2016	Classification of Transmission Line Faults with Waveform Characterization	ESTADOS UNIDOS	5	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
16	2010	Feature Analysis and Classification Methodology for Overhead Distribution Fault Events	ESTADOS UNIDOS	9	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
17	2010	Data in Distribution Fault Diagnosis	ESTADOS UNIDOS	4	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
18	2010	Waveform Characterization of Animal Contact , Tree Contact , and Lightning Induced Faults	ESTADOS UNIDOS	25	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
19	2016	Fault location in distribution feeders with distributed generation	ESTADOS UNIDOS	4	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

20	2016	A study on the effect of distributed generation on short-circuit current	ESTADOS UNIDOS	8	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
21	2000	An adaptive PMU based fault detection/location technique for transmission lines - Part II: PMU implementation and performance evaluation	ESTADOS UNIDOS	147	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
22	2016	Novel fault location algorithm for transmission line using synchronized measurements	ESTADOS UNIDOS	11	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
23	2020	Ubicación de fallas en líneas de transmisión eléctrica basado en el análisis de señales transitorias	ECUADOR	2	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
24	2002	Pattern matching in multivariate time series databases using a moving-window approach	ESTADOS UNIDOS	74	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
25	2004	Unsupervised neural network for fault detection and classification in dynamic systems	ESTADOS UNIDOS	3	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
26	2009	Supervised Laplacian Eigenmaps for machinery fault classification,	ESTADOS UNIDOS	7	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
27	2020	Fault Diagnosis Based on Sparse Semi-supervised GAN Model	CHINA	2	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
28	2019	Fault diagnosis optimization algorithm based on k nearest neighbor	CHINA	2	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
29	2018	Fault detection and classification in six-phase transmission system using k-nearest neighbour algorithm	INDIA	4	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
30	2019	Fault detection and classification based on semi-supervised machine learning using KNN	INDIA	2	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
31	2021	Infraestructura del Sistema Nacional de Transmisión (SNT),	ECUADOR	1	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
32	2017	Distance protection with fault impedance compensation for distribution network with DG	ITALY	3	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
				CANTIDAD	21	19	14	10	22	11	4	15	12	10	17	8	11	14	12	6

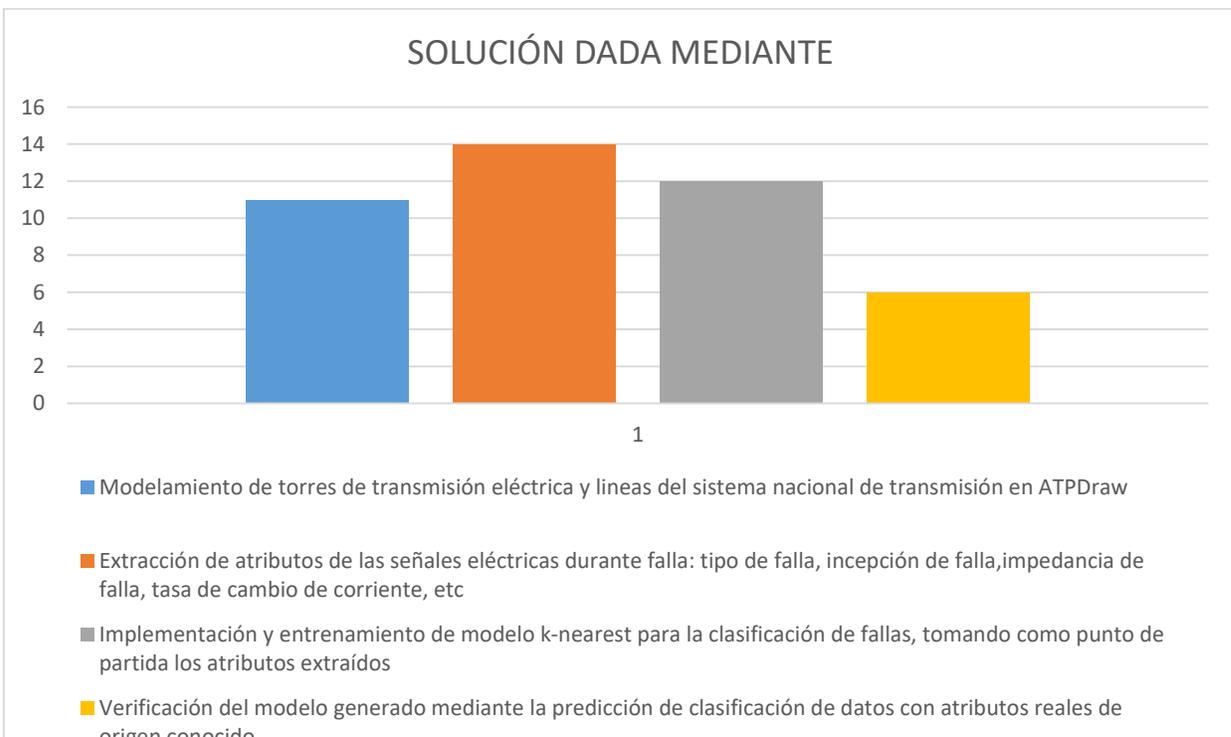
## 1.2 Resumen de Indicadores



**Figura 21.** Resumen e indicador de la temática - Estado del arte



**Figura 22.** Indicador de formulación del problema - Estado del arte



**Figura 23.** Indicador de solución - Estado del arte