



Doi: <https://doi.org/10.70577/ASCE/2107.2124/2025>

Recibido: 2025-08-01

Aceptado: 2025-08-29

Publicado: 2025-09-02

Riesgos y prevención en actividades de campo con transformadores: modelación estadística de la probabilidad de accidentes y fatalidades

Risks and prevention in field activities with transformers: statistical modeling of the probability of accidents and fatalities

Autores:

Evelyn Geovanna Inca Balseca¹

Dirección de Posgrado, Programa de Maestría en Matemática aplicada
con mención en Matemática Computacional

<https://orcid.org/0000-0001-7055-9019>

evelyn.inca@unach.edu.ec

Universidad Nacional de Chimborazo (UNACH)

Riobamba – Ecuador

Andrés Fernando Morocho Caiza²

Facultad de informática y Electrónica, Carrera de Electricidad

<https://orcid.org/0000-0003-3146-8784>

andres.morocho@esPOCH.edu.ec

Escuela Superior Politécnica de Chimborazo (ESPOCH)

Riobamba – Ecuador

Cómo citar

Inca Balseca, E. G., & Morocho Caiza, A. F. (2025). Riesgos y prevención en actividades de campo con transformadores: modelación estadística de la probabilidad de accidentes y fatalidades. *ASCE*, 4(3), 2107–2124.



Resumen

El presente estudio analiza riesgos eléctricos en pruebas de transformadores, siendo un aspecto crítico en ingeniería eléctrica en lo referente a personal como equipos. Se evaluó modelos predictivos como regresión Logística y Árbol de Decisión, mostrando un limitado rendimiento de 29,1 % y 23 % respectivamente de precisión global. Dichos modelos presentaron significativas dificultades en la clasificación de clases minoritarias, mostrando problemas relacionados a la falta de sofisticación y al desequilibrio de datos para determinar complejos patrones en ambientes desafiantes. Adicional se determinó un sesgo hacia mayoritarias categorías, comprometiendo su aplicabilidad práctica en críticos sistemas considerando la protección de subestaciones o también el análisis de fallas internas mediante avanzadas técnicas como al Análisis de Respuesta en Frecuencia (FRA). En la discusión se destaca la necesidad prioritaria de mejorar dichos modelos mediante algunas estrategias como selección de características relevantes, sobre muestreo (SMOTE) y adicional con la implementación de redes neuronales artificiales o algoritmos avanzados como XGBoost. En una mirada práctica, se prioriza en lo importante de integrar los conocimientos teóricos con lo que son herramientas avanzadas de aprendizaje automático para prever patrones de riesgo y la mitigación de fallos operacionales. En cuanto a recomendaciones se debe abordar el desequilibrio de clases, análisis profundo de las variables, adicional complementar los modelos con técnicas de interpretación como LIME o SHAP. Se concluye que es importante adoptar un enfoque multidisciplinario combinando modelos predictivos con pruebas físicas para la optimización de la seguridad en sistemas eléctricos.

Palabras clave: Modelos, Predicción, Riesgos, Seguridad, Transformadores.



Abstract

This study analyzes electrical risks during transformer testing, a critical aspect in electrical engineering to ensure the safety of both equipment and personnel. Predictive models such as Decision Tree and Logistic Regression were evaluated, showing limited performance (23% and 29.1% overall accuracy, respectively). These models presented significant difficulties in correctly classifying minority classes, evidencing problems associated with data imbalance and a lack of sophistication to capture complex patterns in challenging environments. Furthermore, a bias toward majority categories was observed, compromising their practical applicability in critical systems such as substation protection or internal fault analysis using advanced techniques such as Frequency Response Analysis (FRA). The discussion highlights the need to improve these models through strategies such as oversampling (SMOTE), selection of more relevant features, and the implementation of advanced algorithms such as XGBoost or artificial neural networks. From a practical perspective, the importance of integrating theoretical knowledge with advanced machine learning tools to anticipate risk patterns and mitigate operational failures is emphasized. Recommendations include addressing class imbalance, performing more in-depth variable analyses, and complementing models with interpretation techniques such as SHAP or LIME. Finally, it is concluded that a multidisciplinary approach combining physical testing with predictive models is crucial to optimize safety in electrical systems.

Keywords: Models, Prediction, Risks, Security, Transformers.



Introducción

Analizar los riesgos eléctricos durante las pruebas de transformadores es algo esencial en ingeniería eléctrica. No solo se trata de proteger los equipos, sino también de cuidar la seguridad de las personas que trabajan con ellos. Estas pruebas se realizan en condiciones que pueden ser bastante exigentes: sobrecorrientes, voltajes altos, e incluso situaciones de cortocircuito. Por eso, distintos estudios han explorado cómo evaluar estos riesgos y qué estrategias ayudan a reducirlos (Azevedo et al., 2020; López et al., 2023).

Uno de los puntos más críticos es identificar fallas internas en los transformadores. Estas fallas pueden aparecer por muchas razones: fuerzas electromagnéticas, piezas sueltas o descargas eléctricas. Para esto, el Análisis de Respuesta en Frecuencia (FRA) ha demostrado ser una herramienta muy útil. Este tipo de análisis permite detectar alteraciones estructurales internas sin necesidad de desmontar el equipo, facilitando decisiones de mantenimiento más oportunas (Rojas y Martínez, 2021; Wu et al., 2022), con lo cual se pueden programar mantenimientos de forma más efectiva y evitar fallas mayores durante las pruebas o en plena operación.

Otro aspecto clave es cómo se llevan a cabo las pruebas de cortocircuito. Una forma de hacerlas más seguras y eficientes es usando capacitores para compensar la carga reactiva. Esto no solo mejora el rendimiento, sino que también reduce el riesgo de sobrecargas. La compensación paralela de reactivos es una técnica efectiva que estabiliza la respuesta del sistema durante las pruebas de aptitud al cortocircuito (Kucukkaya & Pamuk, 2024; Yang et al., 2024).

Si dichas pruebas no se planifican bien, pueden ocasionar daños importantes en el transformador con su respectivo peligro en la integridad de quienes están a cargo. Por ello, es importante la utilización de equipos dimensionados apropiadamente y mantener protocolos de seguridad. El uso e implementación de sistemas de alta corriente en tensión baja permitiendo el desarrollo de ensayos representativos y seguros en ambientes controlados (Aponte et al., 2023; Luo et al., 2023).

El ambiente en el que se desarrollan pruebas influye también mucho. Factores como la temperatura y la humedad pueden afectar el aislamiento interno del transformador, acelerando su deterioro, dado que las condiciones ambientales alteran las propiedades dieléctricas del aislamiento,

influyendo directamente en la vida útil del equipo (García et al., 2020; Rubbo et al., 2020). Por ello, estos elementos deben estar controlados cuidadosamente durante las pruebas.

Además, en los últimos años se ha propuesto el uso de tecnologías de medición inteligente para monitorear las condiciones del transformador en tiempo real. Esto podría mejorar la seguridad notablemente. Sin embargo, aún no hay suficiente información sobre su aplicación específica en pruebas de campo, así que es un área que merece más investigación (Tarko et al., 2022; Tong et al., 2025).

Considerando lo expuesto anteriormente la preparación del personal técnico es fundamental. Estar bien capacitado y seguir protocolos de seguridad claros hace toda la diferencia, por lo que se debe contar con protocolos adecuados y el conocimiento del personal para reducir significativamente el riesgo de electrocución y daño a los equipos (Shiau et al., 2021; Yogeshpriya et al., 2022).

El análisis de riesgos eléctricos en pruebas de transformadores implica un enfoque integral: se identifican peligros, se aplican metodologías de evaluación y se asegura la correcta protección con relés y sistemas de seguridad (Rodríguez et al., 2021; Li et al., 2022), por lo tanto, esta investigación tuvo como objetivo modelar y evaluar estadísticamente los riesgos eléctricos que se presentan durante pruebas de campo en transformadores de alta, media y baja tensión. Con esta información, buscamos desarrollar estrategias concretas para prevenir accidentes y salvar vidas.

Material y Métodos

Metodologías de evaluación de riesgos: A continuación, se describen las metodologías usadas para la evaluación de riesgos eléctricos:

Identificación de defectos: Se basó en la asignación de valores de probabilidad iniciales a cada índice de riesgo. Estas metodologías, están basadas en condiciones de operación reales, incrementando la precisión en el análisis de riesgos eléctricos.

Análisis del árbol de fallas: Este modelo establece un riesgo estructurado, enfocado en datos históricos y procesos de fabricación para el cálculo de ponderaciones y probabilidades estimado



con una elevada precisión el riesgo de fatales descargas eléctricas en las estaciones transformadoras MV/LV.

Pruebas eléctricas y protección de relés

Métodos de prueba: Dichas pruebas eléctricas son consideradas esenciales para dar garantía en cuanto a fiabilidad como seguridad de los transformadores. En el presente estudio se implementaron varios ensayos destinados a garantizar una desconexión efectiva en fallas, evitando mayores daños en los equipos. También se desarrollaron pruebas de campo usando analizadores portátiles, facilitando la evaluación en cuanto al comportamiento de los transformadores bajo reales solicitaciones de funcionamiento.

Modelos Estadísticos

Datos utilizados

El conjunto de datos revisado incluye información en cuanto a seguridad y rendimiento de transformadores, estructurada en siete principales columnas: Distancias, EPP (Equipos de Protección Personal), Proximidad, Incidentes, Capacitación, Transformador y Tecnologías. Cada elemento fila representa una observación individual, en la que se registran características específicas que están relacionadas con un determinado transformador.

Variables evaluadas

Las variables concernientes al presente estudio consideran información categórica como numérica. Por ejemplo, los elementos columna proximidad y Distancias se expresan en unidades continuas, otras como Incidentes, EPP, Capacitación, Transformador y Tecnologías, representan a variables categóricas o discretas. Estas variables se pueden codificar mediante indicadores binarios (0/1) o también reflejar niveles distintos de clasificación.

El conjunto de datos está orientado a la examinación de cómo diversos factores —como lo referente a la utilización de tecnologías avanzadas o la capacitación del personal— inciden en gran manera en la ocurrencia de incidentes y en cuanto a la seguridad global en los transformadores.

Resultados

Mediante un preliminar análisis ciertos datos representan varios patrones relevantes. Por ejemplo, las variables Proximidad y Distancias varían notoriamente entre algunas observaciones, sugiriendo con esto que dichas métricas están asociadas a la ubicación física o su disposición de los transformadores en una red eléctrica.

Adicional, la columna incidente demuestra una gama amplia de valores, iniciando en 0 incrementándose a números altos, señalando la cantidad de adversos eventos indicados en cada transformador. En cuanto a la variable capacitación describe gran variabilidad, lo que implica relevantes diferencias en cuanto a niveles de preparación del personal encargado de la operabilidad de estos equipos.

Concluyendo, las columnas Tecnologías y EPP son binarias con valores de 0 o 1, sugiriendo que se utilizan como indicadores de si ciertas medidas de protección o tecnologías están implementadas. El presente conjunto de datos provee de una sólida base para desarrollar análisis estadísticos y para un modelado predictivo dirigido a la mejora en seguridad y reducción de incidentes en los sistemas de transformadores.

Los resultados de la Figura 1 indican un rendimiento bajo en contexto global para la clasificación de clases, con una precisión resultante del 23%. El rendimiento asociado a las clases indica relevantes desequilibrios tanto de recall como de precisión. Las clases definidas por 0,1, y 2 presentan valores insignificantes pero moderados tanto de recall como de precisión, mientras que clases como 3,4 y 5 presentan ceros en todas sus métricas, señalando que el modelo no alcanza a clasificar ni predecir adecuadamente instancia alguna como de dichas clases. La discordia entre las métricas indica que el modelo es ineficaz para capturar patrones persistentes de los datos, como clases 4 y 5.

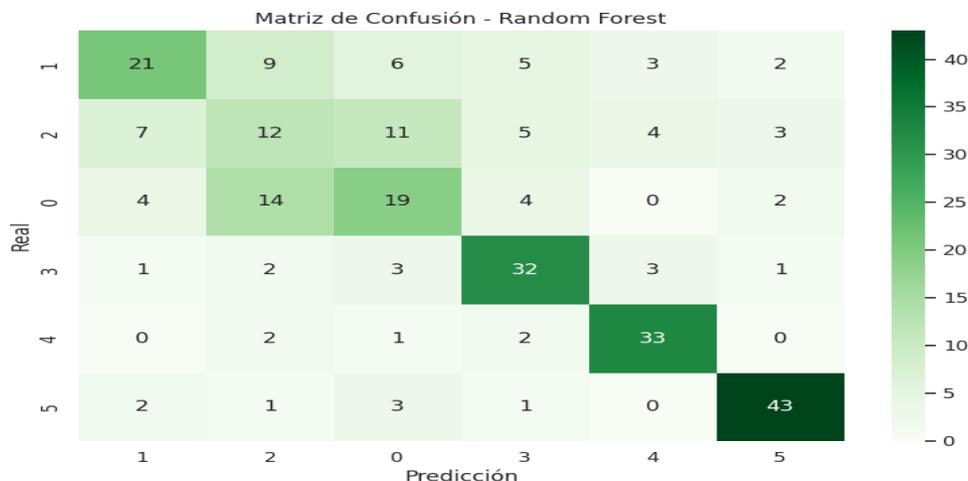


Figura 1. Resultados del árbol de decisiones

En general, el promedio del rendimiento captura mejor la aportación de cada clase a la base total de datos, y registra una precisión de 0.19, un recall de 0.23 y un F1-score de 0.19. Los mismos, sin embargo, siguen siendo bajos, y esto indica que el modelo no es robusto. El macro promedio, aunque no tiene en cuenta la soporte por clase a la hora de calcular el promedio, sigue incluso más bajo, subrayando la falta de inconsistencia del rendimiento entre clases (Tabla1).

Tabla 1. Reporte de regresión logística

=== Logistic Regression Report ===				
	precision	recall	f1-score	support
0	0.50	0.03	0.06	30
1	0.28	0.94	0.44	35
2	0.50	0.03	0.05	38
3	0.00	0.00	0.00	10
4	0.00	0.00	0.00	4
5	0.00	0.00	0.00	3
accuracy		0.29	120	
macro avg	0.21	0.17	0.09	120
weighted avg	0.37	0.29	0.16	120



Esto apoya la idea de que podrían mejorar ajustándolo con un poco más de balance de clases, usando un mayor criterio de características y mediante la aplicación de procedimientos de optimización del modelo, para incrementar su potencia de generalización y predecir más precisamente

El informe de regresión logística muestra un rendimiento global bajo, con un nivel de precisión global del 29%, que indica que menos de un tercio de las predicciones fueron correctas. Si bien la clase 1 tiene indicadores significativamente más altos, con un recall del 0.94 y un F1-score del 0.44, el modelo falla con claridad en la mayoría de las demás clases.

Las clases 0 y 2 tienen precisión relativa aceptable (0.50), pero muy bajos recall de (0.03) para ellas reflejan que el modelo es incapaz de elegir correctamente las instancias veraces de las mismas categorías. Por añadidura, las clases 3, 4 y 5 tienen un valor cero para todas las métricas, que demuestran que el modelo no es capaz de aprender patrones útiles ya que las mismas clases tienen un bajo apoyo.

En conjunto, por lo común, el peso promedio tiene una precisión de 0.37, un recall de 0.29 y un F1-score de 0.16, que destaca un rendimiento inconsistente. El macro promedio, sin embargo, demuestra más nítidamente las fallas del modelo, con muy bajos resultados en todas las mediciones (precisión de 0.21, recall de 0.17 y F1-score de 0.09).

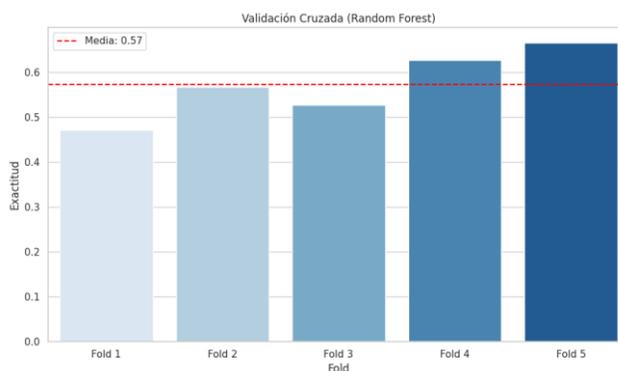
Este análisis indica que el modelo es sesgado hacia la clase 1, por un posible desequilibrio de los datos o una inadecuación del ajuste para abordar clases minoritarias. Para mejorar los resultados, se adoptarían tácticas como balanceo de clases, ajuste de hiperparámetros, o incluso probar modelos más altamente complejos que puedan capturar mejor las relaciones subyacentes a los datos.

La comparación del modelo Regresión Logística y del modelo Random Forest indica que, si bien ambos tienen un rendimiento bajo en cuanto a precisión, la Regresión Logística tiene una mayor precisión y un mayor valor de medio de validación cruzada que el Random Forest. Con una precisión de 0.291667 y un promedio de validación cruzada de 0.351667 (Tabla 2).

Tabla 2. Comparación de modelos.

Comparación de modelos			
Modelo	Exactitud	Validación Cruzada (Promedio)	
0 Random Forest	0.225000	0.275000	
1 regresión Logística	0.291667	0.351667	

La regresión logística demuestra ser más consistente y confiable en sus predicciones en comparación con el Random Forest, cuyos valores respectivos son 0.225000 y 0.275000 (Figura 2).

**Figura 2.** Validación cruzada modelo random forest.

Esto indicaría, en este caso, que el modelo lineal está mejor adaptado para captar las relaciones subyacentes en los datos en comparación con el enfoque basado en árboles del Random Forest.

Discusión

Los resultados obtenidos a partir de los modelos de clasificación aplicados en este estudio evidencian un desempeño limitado en la predicción multiclase. Esta limitación se manifiesta tanto en las métricas específicas de cada categoría como en los promedios ponderados y macro. Un ejemplo claro es el modelo de Árbol de Decisión, que alcanzó únicamente un 23% de exactitud global, lo que refleja una escasa capacidad de generalización y una dificultad considerable para predecir de manera correcta las distintas clases. (Miao, J., & Zhu, 2022; Blockeel, et al., 2023)

En particular, las clases minoritarias —como las clases 3, 4 y 5— no fueron identificadas en absoluto, registrando valores nulos de precisión, *recall* y F1-score. Este resultado es característico de escenarios con datos desbalanceados, en los cuales los modelos tienden a centrar su atención en las clases mayoritarias e ignorar aquellas con menor representación. (Charbuty, & Abdulazeez, 2021, Sun et al., 2024)

Adicionalmente, el modelo de Regresión Logística presentó una funcionalidad superior, presentando una exactitud del 29.1%. Este resultado presenta un sesgo marcado hacia la clase 1, en la que el modelo llegó a un nivel de *recall* de 0.94, adicional presenta un rendimiento deficiente en las otras categorías. Lo anteriormente señalado coincide con lo indicado en investigaciones preliminares acerca de problemas de desbalance en una clasificación multiclase (Das, 2024.; Kolukisa et al., 2024).

El presente desequilibrio señala la necesidad de la implementación de importantes técnicas de balanceo de datos y el desarrollo de ajustes para calibrar el modelo. Varios autores indican que el diseño de sistemas eléctricos de clasificación robustos requiere de un conocimiento profundo tanto en la operabilidad como en las características del entorno en que se aplica aplican (Ray et al., 2024., Zhu et al., 2024).

Desde el punto de vista práctico, dichos resultados tienen relevantes implicaciones en ambientes reales, especialmente en sistemas de protección de transformadores eléctricos (Alenezi et al., 2024; Hussein et al., 2024). La poca certeza en la predicción de forma apropiada de varias categorías puede ocasionar fallos críticos en los mecanismos de protección, vulnerando con ello la seguridad y fiabilidad de equipos.



Como se presentan errores en cuanto a clasificación llegan a comprometer la seguridad en sistemas industriales complejos, particularmente en instalaciones en las cuales el predictivo monitoreo es esencial para prever incidentes eléctricos (Wei et al., 2024.; Khan et al., 2025). Adicional, han señalado peligros letales de los errores sistemáticos referentes a la protección de subestaciones, lo cual señala la relevancia de calibración en cuanto a precisión de los modelos.

Comparando los dos modelos, se determina que el árbol de Decisión fue superado por la Regresión Logística, con un promedio de 27.5% frente al 35.1% del Random Forest. Sin embargo, el modelo lineal denota una adaptabilidad mayor a datos actuales, el rendimiento se presenta insuficiente en cuanto a garantía de resultados predictivos confiables. Es importante la interpretación correcta de las respuestas del sistema y un control riguroso de condiciones de prueba para la mitigación de riesgos en redes eléctricas (Ro et al., 2021.; Nica et al., 2023).

De manera global estos hallazgos importantes señalan que es preciso reformular el enfoque metodológico para la mejora de los modelos en cuanto a la capacidad predictiva. Estrategias tales como el balanceo de clases a través de técnicas como el aumento de datos, SMOTE o la implementación de modelos avanzados, como redes neuronales artificiales p XGBoost, podrían presentarse como claves para abarcar estas limitaciones (Gamel et al., 2024., Han et al., 2024).

Es importante optimizar modelos de predicción , para reducir riesgos eléctricos, estos no dependen solo de pruebas físicas, adicionalmente necesitan de la implementación de sofisticados modelos predictivos que son capaces de señalar patrones de riesgo en ambientes de alta tensión. Dichas mejores marcan una diferencia muy significativa en la prevención de fallos de operabilidad y protección en infraestructuras eléctricas críticas.



Conclusiones

A través de los presnetges resultados y su respectiva discusión, se pueden definir varias conclusiones destacando las limitaciones en los modelos utilizados, así como las oportunidades para mejorar su funcionalidad en contextos prácticos. Los modelos evaluados de clasificación, incluido el de Regresión Logística y el árbol de Decisión, presentan un insuficiente rendimiento en la predicción multiclase, con exactitudes globales del 23% y 29.1%, respectivamente. EL bajo desempeño denota una baja capacidad para la generalización y manipulación de datos desbalanceados, por lo cual se incrementa la omisión casi en su totalidad de minoritarias clases. La situación anterior denota un requerimiento urgente de implementación de técnicas particulares para el abordaje del desequilibrio de clases.

El sesgo señalado en ciertas clases, como en la clase 1 en cuanto a la Regresión Logística, señala que dichos modelos priorizan categorías mayoritarias en relación de las minoritarias, con lo que se puede presentar implicaciones graves en cuanto a aplicaciones críticas como son la protección de sistemas eléctricos. Dicho comportamiento compromete no solo la precisión en cuanto a las predicciones, adicionalmente se incrementan los riesgos de fallos operacionales en entornos industriales en donde es esencial la identificación temprana de patrones.

Aunque el Árbol de Decisión fue superada ligeramente pro la Regresión Logística en cuanto a validación cruzada, estos modelos presentan una carencia en cuanto a sofisticación en el abordaje de problemas complejos referentes a la clasificación multiclase en los datos desbalanceados. Lo anteriormente señalado sugiere la necesidad de explorar alternativas avanzadas, como los modelos basados en redes neuronales artificiales o ensambles, que demuestran ser efectivos en contextos similares. Adicional, la implementación de enfoques híbridos combina técnicas de preprocesado de datos con modelos predictivos potentes que pueden ser claves para mejorar el recall y la precisión en todas las clases.



Referencias bibliográficas

Alenezi, M., Anayi, F., Packianather, M., & Shouran, M. (2024). Enhancing transformer protection: A machine learning framework for early fault detection. Sustainability, 16(23), 10759. <https://doi.org/10.3390/su162310759>

Aponte-Mayor, G., Gómez-Luna, E., & Jaramillo, A. (2023). Importancia estratégica de un sistema de alta corriente en baja tensión en el sector eléctrico colombiano. Información Tecnológica, 34(1), 141-150. <https://dx.doi.org/10.4067/s0718-07642023000100141>

Azevedo, A. S., Duarte, J., & Machado e Moura, A. (2020). Minimization of electrical risks in activities in very high voltage transmission lines. En A. Arezes (Ed.), Occupational and Environmental Safety and Health II (pp. 13–20). Springer. https://doi.org/10.1007/978-3-030-41486-3_2

Blockeel, H., Devos, L., Frénay, B., Nanfack, G., & Nijssen, S. (2023). Decision trees: from efficient prediction to responsible AI. Frontiers in artificial intelligence, 6, <https://doi.org/10.3389/frai.2023.1124553>

Charbuty, B., & Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. Journal of applied science and technology trends, 2(01), 20-28. <https://doi.org/10.38094/jastt20165> .

Das, A. (2024). Logistic regression. In Encyclopedia of quality of life and well-being research (pp. 3985-3986). Cham: Springer International Publishing. http://dx.doi.org/10.1007/978-3-031-17299-1_1689

Gamel, S. A., Ghoneim, S. S., & Sultan, Y. A. (2024). Improving the accuracy of diagnostic predictions for power transformers by employing a hybrid approach combining SMOTE and DNN. Computers and Electrical Engineering, 117, 109232. <https://doi.org/10.1016/j.compeleceng.2024.109232>



García, D., Vásquez, H., & Holguín, A. (2020). Prototipo electrónico para el calentamiento a baja frecuencia de transformadores eléctricos monofásicos. Información Tecnológica, 31(5), 59-70. <https://doi.org/10.4067/s0718-07642020000500059>

Han, Y., Wei, Z., & Huang, G. (2024). An imbalance data quality monitoring based on SMOTE-XGBOOST supported by edge computing. Scientific Reports, 14(1), 10151. <https://doi.org/10.1038/s41598-024-60600-x>

Hussein, R. I. H., Gökşenli, N., Bektaş, E., Teke, M., Tümay, M., Yaseen, E. S. Y., ... & Taha, T. A. (2024). Enhanced transformer protection using fuzzy-logic-integrated differential relays: a comparative study with rule-based methods. Journal of Robotics and Control (JRC), 5(5), 1299-1310. <http://doi.org/10.18196/jrc.v5i5.21937>

Khan, M. I., Ahmad, B., Shoaib, M., Anwar, S., & Ali, Z. (2025). Artificial Intelligence and Machine Learning Applications in Smart Infrastructure and Electrical Systems. The Critical Review of Social Sciences Studies, 3(1), 2005-2016. <https://doi.org/10.59075/z5e95467>

Kolukisa, B., Dedetürk, B. K., Hacilar, H., & Gungör, V. C. (2024). An efficient network intrusion detection approach based on logistic regression model and parallel artificial bee colony algorithm. Computer Standards & Interfaces, 89, 103808. <http://dx.doi.org/10.1016/j.csi.2023.103808>

Kucukkaya, B., & Pamuk, N. (2024). Theoretical and practical analysis of parallel operating conditions of two transformers with different relative short circuit voltages. Sigma Journal of Engineering and Natural Sciences, 42(3), 701-713. <http://dx.doi.org/10.14744/sigma.2023.00025>

Li, J., Chen, F., & Li, S. (2022). Correlation analysis and prevention of electrocution risk factors in the construction industry. Archives of Civil Engineering, 68(4), 537-554. <http://dx.doi.org/10.24425/ace.2022.143053>



López Serrazina, R. H., Jiménez Ayala, J., & Catató Alis, J. (2023). Desarrollo y validación de un nuevo método de evaluación de riesgos eléctricos para la prevención y mitigación de daños a personas e instalaciones. *Ingeniare: Revista Chilena de Ingeniería*, 31(1), 204–214. <https://doi.org/10.4067/S0718-33052023000100204>

Luo, J., Mozaffari, K., Lehman, B., & Amirabadi, M. (2023). Control Strategies for Parallel Capacitive-Link Universal Converters with Low Voltage Stress and Current Stress. In *2023 IEEE Energy Conversion Congress and Exposition (ECCE)* (pp. 2483-2490). IEEE. <http://dx.doi.org/10.1109/ECCE53617.2023.10362819>

Miao, J., & Zhu, W. (2022). Precision–recall curve (PRC) classification trees. *Evolutionary intelligence*, 15(3), 1545-1569. <https://link.springer.com/article/10.1007/s12065-021-00565-2>

Nica, G., Pavel, F., & Hojda, G. (2023). A fast nonlinear dynamic analysis automated approach to produce fragility curves for 3D RC frames. *Engineering Structures*, 281, 115695. <https://doi.org/10.1016/j.engstruct.2023.115695>

Ray, P. K., Sahoo, H. K., Mohanty, A., Bhutto, J. K., Barnawi, A. B., & Alshaya, A. A. (2024). Robust H-infinity filter and PSO-SVM based monitoring of power quality disturbances system. *IEEE Access*, 12, 39041-39057. <http://dx.doi.org/10.1109/ACCESS.2024.3367727>

Ro, K. M., Kim, M. S., & Lee, Y. H. (2021). A simplified approach to modeling vertically irregular structures for dynamic assessment. *Journal Of Asian Architecture And Building Engineering*, 21(6), 2320-2329. <https://doi.org/10.1080/13467581.2021.1971682>

Rodríguez Suárez, J. M., González Sifuentes, K., Trujillo Guajardo, L. A., & Cantú Gutiérrez, P. V. (2023). Análisis de problemática en sistemas eléctricos industriales: arco eléctrico. *Multidisciplinas de la Ingeniería*, 5(6). <https://doi.org/10.29105/mdi.v5i06.126>

Rojas, C. and Martínez, S. (2021). Transformadores de potencia con doble núcleo: análisis de respuesta a la frecuencia. *Ciencia Nicolaita*, (82). <https://doi.org/10.35830/cn.vi82.543>



Rubbo, G. E., Corasaniti, V. F., & Barbieri, M. B. (2020). Estudio de arco eléctrico en una subestación eléctrica. IEEE Biennial Congress of Argentina (ARGENCON). <https://dx.doi.org/10.1109/ARGENCON49523.2020.9505386>

Shiau, Y. R., Lo, F. Y., & Ko, P. C. (2021). Early intervention mechanism for preventing electrocution in construction engineering. Industrial health, 59(1), 4-17. <http://dx.doi.org/10.2486/indhealth.2020-0097>

Sun, Z., Wang, G., Li, P., Wang, H., Zhang, M., & Liang, X. (2024). An improved random forest based on the classification accuracy and correlation measurement of decision trees. Expert Systems with Applications, 237, 121549. <http://dx.doi.org/10.1016/j.eswa.2023.121549>

Tarko, R., Kmak, J., Nowak, W., & Szpyra, W. (2022). Statistical Assessment of Electric Shock Hazard in MV Electrical Power Substations Supplied from Networks with Non-Effectively Earthed Neutral Point. Energies, 15(4), 1560. <http://dx.doi.org/10.3390/en15041560>

Tong, H., Zeng, X., Yu, K., & Zhou, Z. (2025). A fault identification method for animal electric shocks considering unstable contact situations in low-voltage distribution grids. IEEE Transactions on Industrial Informatics. <http://dx.doi.org/10.1109/TII.2025.3538132>

Wei, J., Chammam, A., Feng, J., Alshammari, A., Tehranian, K., Innab, N., ... & Shutaywi, M. (2024). Power system monitoring for electrical disturbances in wide network using machine learning. Sustainable Computing: Informatics and Systems, 42, 100959. <http://dx.doi.org/10.1016/j.suscom.2024.100959>

Wu, Y., Tian, C., Zhang, Z., Chen, B., Liu, S., & Chen, Y. (2022). A novel current transformer based on virtual air gap and its basic measuring characteristics. IEEE Transactions on Power Delivery, 38(1), 13-25. <http://dx.doi.org/10.1109/TPWRD.2022.3179321>



Yang, J., Liu, H., Hou, K., Kang, Z., Li, Q., & Li, Q. (2024). Influence of Ultra-High-Voltage hybrid reactive power compensation on interruption performance of circuit breakers under different faults. International Journal of Electrical Power & Energy Systems, 156, 109714. <http://dx.doi.org/10.2139/ssrn.4089421>

Yogeshpriya, S., Saravanan, M., Selvaraj, P., Sindhu, R., Venkatesan, M., Ramkumar, P. K., & Premalatha, N. (2022). Rare survival of high-tension electrocution shock in a crossbred Jersey cattle: a complete profile on critical care monitoring. Iranian Journal of Veterinary. <http://dx.doi.org/10.22099/IJVR.2022.43453.6356>

Zhu, K., Zhang, N., Jiang, C., & Zhu, D. (2024). IMDAC: A robust intelligent software defect prediction model via multi-objective optimization and end-to-end hybrid deep learning networks. Software: Practice and Experience, 54(2), 308-333. <http://dx.doi.org/10.1002/spe.3274>

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

Este trabajo agradece el respaldo brindado por el Programa de Maestría en Matemática aplicada con mención en Matemática Computacional de la Universidad Nacional de Chimborazo (UNACH), fundamental para la realización de esta investigación.

Nota:

El artículo no es producto de una publicación anterior.