

Diagnóstico de fallas en transformadores de potencia usando modelos de redes Neuronales Perceptrón Multicapa

Fault diagnosis in power transformers using Multilayer Perceptron Neural network models

Fabricio Jorge Umaña-Blanco¹, Gustavo Adolfo Gómez-Ramírez², Juan José Montero-Jiménez³

Umaña-Blanco, F. J; Gómez-Ramírez, G. A; Montero-Jiménez, J.J. Diagnóstico de fallas en transformadores de potencia usando modelos de redes Neuronales Perceptrón Multicapa . *Tecnología en Marcha*. Vol. 39 N° especial sobre Inteligencia Artificial. Febrero, 2026. Pág. 352-367.

 <https://doi.org/10.18845/tm.v39i5.8525>



- 1 Escuela de Ingeniería en Electromecánica. Instituto Tecnológico de Costa Rica, Costa Rica.
 fabriciouma@estudiantec.cr
 <https://orcid.org/0009-0001-0111-5200>
- 2 Escuela de Ingeniería en Electromecánica. Instituto Tecnológico de Costa Rica, Costa Rica
 ggomez@itcr.ac.cr
 <https://orcid.org/0000-0001-9195-072X>
- 3 Escuela de Ingeniería en Electromecánica. Instituto Tecnológico de Costa Rica, Costa Rica.
 juan.montero@itcr.ac.cr
 <https://orcid.org/0000-0002-3215-3736>

Palabras clave

Inteligencia artificial; aplicaciones de ordenador; ciencia de la computación; sistemas expertos; reconocimiento de patrones; pruebas; análisis matemático.

Resumen

Los transformadores de potencia constituyen uno de los componentes más onerosos e indispensables en la operación de los sistemas eléctricos. La evaluación de gases disueltos (DGA) facilita la identificación de concentraciones de gases disueltos presentes en el aceite aislante, vinculadas a fallos térmicos, descargas parciales y descargas de alta y baja energía. Estas correlaciones gaseosas facilitan la identificación del estado del transformador. En años recientes, la implementación de técnicas de Aprendizaje Automático, tales como las redes neuronales artificiales, ha experimentado un incremento en la predicción, diagnóstico y gestión de fallos, evidenciando un buen rendimiento para identificar anomalías y apoyar la toma de decisiones en el ámbito del mantenimiento. Este estudio implementó un modelo de Perceptrón Multicapa (MLP) de enfoque multietiqueta, en el que se consideran los diagnósticos de fallas en el transformador calculados mediante los métodos de Dornenburg, Rogers, triángulo de Duval y el método de gases recomendados por los estándares IEC e IEEE. Así se logra emplear los múltiples diagnósticos de fallas presentes en cada transformador disponibles por cada método. La validación del modelo se realizó mediante la implementación de la validación cruzada k-Fold, lo que resultó en un índice de coincidencia exacta del 90,95%, correspondiente a los casos en los que el modelo cumple con todas las etiquetas proporcionadas por cada método diagnóstico. La curva ROC, que presenta un área bajo la curva del 99%, y la curva Precisión-Exhaustividad, que presenta una precisión media del 99.3%, fueron desarrolladas gráficamente.

Keywords

Artificial intelligence; computer applications; computer science; expert systems; pattern recognition; testing; mathematical analysis.

Abstract

Power transformers are among the most expensive and essential elements in the functioning of electrical networks. Dissolved gas analysis (DGA) enables the detection of dissolved gas concentrations in insulating oil, associated with thermal faults, partial discharges, and both high- and low-energy discharges. These gas correlations enable the assessment of the transformer's condition. In recent years, the use of machine learning techniques, such as artificial neural networks, has seen an increase in the prediction, diagnosis, and management of faults, displaying high performance in spotting anomalies and aiding decision-making in the field of maintenance. The present study developed a multi-label Multilayer Perceptron (MLP) model, which considers transformer fault diagnoses calculated using the Dornenburg, Rogers, Duval triangle, and gas procedures recommended by IEC & IEEE standards. This enables the utilization of several fault diagnosis for each transformer via each approach. The model underwent validation by k-Fold cross-validation, achieving an exact match rate of 90.95%, which pertains to instances where the model aligned with all labels specified by each diagnostic procedure. The ROC curve, with an area under the curve of 99%, and the Accuracy-Completeness curve, with an average accuracy of 99.3%, were generated graphically.

Introducción

Los transformadores de potencia constituyen uno de los componentes primordiales en el sistema de energía. Su funcionamiento óptimo es crucial para garantizar un flujo eléctrico ininterrumpido que garantice la operatividad de la red. La aparición de fallos incipientes en los transformadores puede constituir una amenaza significativa para la estabilidad de la red, con un elevado riesgo de pérdida de conexión, así como un considerable gasto económico asociado al mantenimiento. En años recientes, se ha observado un incremento significativo en la implementación de modelos de Aprendizaje Automático (Machine Learning) en el campo de la administración de la salud y la predicción de fallos en transformadores de potencia. Esta metodología se fundamenta en tres modelos fundamentales: el pronóstico, el índice de salud y la identificación de fallos y diagnóstico, en el que el último tiene como objetivo identificar anomalías en el sistema con el fin de determinar el estado operativo del equipo [1].

Las redes neuronales artificiales se destacan como uno de los modelos predominantes en el campo del aprendizaje automático. Las neuronas artificiales replican el funcionamiento de las neuronas biológicas, que reciben diversas señales provenientes de otras neuronas adyacentes y las procesan. La emisión de información en una señal de salida se determina en función de este procesamiento. Las redes neuronales artificiales exhiben una notable capacidad para aprender los procesos que originan los datos, lo que les ha permitido una amplia gama de aplicaciones en el ámbito del procesamiento de datos [2,3]. Este estudio propone un modelo de red neuronal artificial denominado perceptrón multicapa, en el que se aplican los hallazgos de cuatro métodos para el diagnóstico de fallas en transformadores: análisis de gases IEC, Rogers, Dornenburg y triángulo de Duval, entre otros. Esta metodología multitiqueta posibilita al modelo la utilización de diversos diagnósticos, sin la necesidad de recurrir a un único método, con la posibilidad de identificar fallos múltiples en los equipos.

El desarrollo de un modelo de perceptrón multicapa para el análisis de fallas en transformadores de potencia ha sido objeto de múltiples investigaciones. En estudios anteriores, se han implementado modelos que se apoyan exclusivamente en los hallazgos derivados del pentágono de Duval o el triángulo de Duval, obviando la posibilidad de diagnóstico mediante métodos alternativos como el de Dornenburg, Rogers y el método de gases IEC. Esta metodología restringe la identificación de fallos múltiples en un transformador de potencia, lo cual podría resultar en una falla inminente del equipo. Autores han elaborado un modelo de perceptrón multicapa con retro propagación para estimar la condición de los transformadores [4]. Se elabora un modelo con dos niveles de cálculo, en el cual la primera considera los datos del DGA, así como los de furano, factor de potencia, edad del transformador y historiales de mantenimiento y funcionamiento. Existen tres alternativas de salida: Excelente, Aviso y Deficiente. En caso de que la capa inicial genere resultados de alerta o un estado inadecuado, se activa el nivel 2. Este nivel emplea como parámetros de evaluación la relación de transformación, la impedancia de cortocircuito, la resistencia del devanado de corriente continua, el análisis de respuesta en frecuencia y el grado de polimerización, resultando en un estado de Deficiente o Advertencia. El esquema de la red se compone de dos estratos ocultos cada uno con diez nodos. Para la evaluación de la red neuronal, se emplea la validación cruzada mediante el método k-fold. El modelo evidencia una precisión del 92,4% para el nivel 1, y un 99,5% para el nivel 2.

Autores han empleado un modelo de perceptrón multicapa con el objetivo de diagnosticar la condición de los transformadores [5]. Esta investigación implementa un modelo de dos estratos ocultos de 64 neuronas, utilizando la función de activación (ReLU). Las posibles categorías de descargas comprenden descargas de alta energía, descargas de baja energía, calentamiento térmico y operación normal. Los gases que se consideran son el hidrógeno,

metano, etileno, acetileno y etano. El funcionamiento del modelo se inicia con la determinación de si la concentración de gases se encuentra por debajo de los límites prescritos por el IEEE C57-104, estableciendo así un estado normal del transformador. En cambio, se procede a la capa inicial de la red que comprende los tres tipos de diagnósticos prescritos por la norma, y se calculan los porcentajes de los gases para determinar las relaciones del triángulo de Duval y determinar el tipo de falla. El modelo es validado mediante el desarrollo del cálculo de error cuadrático medio y una matriz de confusión que evalúa la precisión, exactitud y sensibilidad del modelo en cuestión. Los hallazgos obtenidos se caracterizaron por una precisión del 94.4%, una sensibilidad y especificidad del 98.6 %, y una exactitud general del 92.5%.

Otra investigación elabora un modelo de perceptrón multicapa (MLP) que se fundamenta en los resultados de diagnóstico de fallas en transformadores derivados del pentágono de Duval [6]. La estructura del modelo se articula en una capa oculta compuesta por 50 neuronas, con la función de activación ReLu y un entrenamiento de 200 iteraciones respectivamente. La investigación se centra en contrastar el rendimiento del modelo en función del procedimiento de estandarización de los datos de entrada. Se lleva a cabo una comparación de los resultados correspondientes al MLP con la Desviación estándar, el Escalado Robusto y el Escalado Mínimo Máximo. A continuación, se lleva a cabo la comparación correspondiente para un modelo de Impulso de Gradiente Extremo (XGB). Para ambas instancias, los resultados más favorables se derivan de la estandarización mediante Escalado Robusto, lo cual se justifica debido a la abundancia de datos atípicos presentes en la base de datos. Se implementaron como métodos de evaluación la exactitud, la precisión y el área bajo la curva de la Curva Característica Operativa del Receptor (ROC). El rendimiento del MLP fue de 91.87%, 92.05% y 99.15% respectivamente, mientras que para el XGB se registró un 90.36%, 90.45% y 99.05% respectivamente. De este modo, la investigación concluye que el modelo MLP posee una superioridad diagnóstica en comparación con el modelo XGB.

Materiales y métodos

El análisis de gases disueltos (DGA) incorpora a la cuantificación, detección y evaluación de los gases disueltos en el líquido aislante del transformador de potencia. Este método posibilita la detección de los niveles de concentración de gases tales como hidrógeno, metano, acetileno, etileno y etano en el aceite del equipo. La concentración de dichos gases se correlaciona con diversas categorías de fallos en los transformadores, siendo su concentración un indicativo del problema existente en el equipo. La existencia de hidrógeno suele ser resultado de descargas parciales de corona y gasificación involuntaria del aceite. El metano, etano y etileno se generan a través del proceso de calentamiento del aceite o papel. El acetileno se identifica mediante arcos presentes en aceite o papel a temperaturas superiores a los 1000°C. Mediante el DGA, se pueden diagnosticar fallos en transformadores de forma visual, basándose en el estado del papel, tales como descargas de alta y baja energía, descargas parciales, y fallas térmicas menores a 300°C (T1), mayores a 300°C (T2), y superiores a 700°C [7,8]. Estos diagnósticos se vinculan a patrones de relación entre los gases disueltos, resultando en diversas relaciones gaseosas que posibilitan el análisis del estado del transformador.

Método de Dornenburg

La metodología de Dornenburg se fundamenta en la determinación de cuatro relaciones (R1, R2, R3 y R4) correspondientes a las concentraciones de gases disueltos tal y como se observa en ecuaciones 1,2,3 y 4. Mediante la estimación de estas relaciones, el enfoque de Dornenburg propone tres diagnósticos de fallo conforme a el cuadro 1. Para establecer un diagnóstico de falla, los resultados derivados de cada relación deben corresponder con los valores que equivalen a cada intervalo descritos en [9] y de acuerdo con la Guía para la interpretación de

gases generados en transformadores sumergidos en aceite mineral [7], para implementar el método de Dornenburg, es necesario primero comparar los valores de los gases con los valores especiales con el objetivo de determinar si la generación de cada gas es adecuada para que el análisis de gases sea válido.

$$R1 = \frac{CH_4}{H_2} \text{ (ec.1)}; R2 = \frac{C_2H_2}{C_2H_4} \text{ (ec.2)}; R3 = \frac{C_2H_2}{CH_4} \text{ (ec.3)}; R4 = \frac{C_2H_6}{C_2H_2} \text{ (ec.4)}$$

Cuadro 1. Clasificación de las fallas de acuerdo con las Relaciones de Dunenburg.

Diagnóstico de falla sugerido	Relación 1 (R1)		Relación 2 (R2)		Relación 3 (R3)		Relación 4 (R4)	
1. Descomposición térmica	> 1.0	> 0.1	< 0.75	< 1.0	< 0.3	<0.1	> 0.4	> 0.2
2. Corona (descarga parcial de baja intensidad)	< 0.1	< 0.01	No Significativo		< 0.3	<0.1	> 0.4	> 0.2
3. Arqueo (descarga parcial de alta intensidad)	> 0.1 <1.0	> 0.01 < 0.1	> 0.75	>1.0	> 0.3	>0.1	< 0.4	< 0.2

Cuadro 2. Gases clave para el análisis por Relaciones de Dunenburg.

Gas clave	Concentración (ppm)
Hidrógeno (H ₂)	100
Metano (CH ₄)	120
Monóxido de carbono (CO)	350
Acetileno (C ₂ H ₂)	1
Etileno (C ₂ H ₄)	50
Etano (C ₂ H ₆)	65

En caso de que al menos uno de los valores de concentración de H₂, CH₄, C₂H₂ y C₂H₄ supere el doble del valor límite especificado en el cuadro 2, y uno de los gases CO o C₂H₆ sobrepase el valor límite se interpreta como una falla en el transformador y se procede a cuantificar las métricas correspondientes.

Método de Rogers

La metodología propuesta por Rogers establece una correlación (ver cuadro 3) entre los gases etileno y acetileno, cuya generación requiere temperaturas relativamente elevadas. No obstante, se determina que los gases metano y etano no aportan información significativa para la detección de averías, conforme a lo indicado en [10]. Esta relación delimita únicamente un rango reducido de descomposición térmica, sin ofrecer una identificación precisa de los tipos de falla, según lo señalado en [11]. Las ecuaciones 5,6 y 7 muestran las relaciones correspondientes de acuerdo con la concentración de los gases obtenidos en el análisis.

$$R1 = \frac{CH_4}{H_2} \text{ (ec.5)}; R2 = \frac{C_2H_2}{C_2H_4} \text{ (ec.6)}; R3 = \frac{C_2H_4}{C_2H_6} \text{ (ec.7)}$$

Pese a su utilidad, el método presenta limitaciones relevantes, ya que se estima que en aproximadamente el 35 % de los casos de falla no logra identificar el tipo de defecto, debido a que los valores de concentración no se ajustan a los márgenes establecidos en la columna 1, incluso cuando dichos valores son elevados y existe evidencia de falla conforme a [7].

Cuadro 3. Relaciones para el análisis por Relaciones de Rogers.


Caso	C ₂ H ₂ /C ₂ H ₄	CH ₄ /H ₂	C ₂ H ₄ /C ₂ H ₆	Diagnóstico de falla sugerido
0	< 0.1	0.1 a 1.0	< 1.0	Unidad normal
1	< 0.1	< 0.1	< 1.0	Arqueo de baja densidad de energía y descargas parciales
2	0.1 a 3.0	0.1 a 1.0	> 3.0	Arqueo — Descarga de alta energía
3	< 0.1	0.1 a 1.0	1.0 a 3.0	Térmica de baja temperatura
4	< 0.1	> 1.0	1.0 a 3.0	Térmica < 700 °C
5	< 0.1	> 1.0	> 3.0	Térmica > 700 °C

Método de Triángulo de Duval

El método desarrollado por Duval emplea los porcentajes de concentración de metano (CH₄), etileno (C₂H₄) y acetileno (C₂H₂), representados en un triángulo equilátero en cuyos vértices se ubica cada uno de los gases [10]. Esta metodología permite el diagnóstico de siete tipos distintos de fallas en transformadores de potencia, cuyos resultados se resumen en la figura 1. Para efectuar los cálculos, se asignan los valores en partes por millón (ppm) de acetileno, etileno y metano a las variables **x**, **y** y **z**, respectivamente. Posteriormente, se aplica la ecuación 7, 8 y 9 se determinan las coordenadas de los porcentajes normalizados. La ubicación del punto resultante dentro del triángulo define el área correspondiente al tipo de falla, lo que permite identificar el diagnóstico específico del transformador.

$$\%C_2H_2 = \frac{100 \times x}{(x + y + z)} \quad (\text{ec.7}); \quad \%C_2H_4 = \frac{100 \times y}{(x + y + z)} \quad (\text{ec.8}); \quad \%CH_4 = \frac{100 \times z}{(x + y + z)} \quad (\text{ec.9})$$

El uso específico de estos gases se fundamenta en su relación teórica con la naturaleza y severidad de las fallas presentes en el transformador. El metano (CH₄) se asocia con fallas de baja energía y temperatura, el etileno (C₂H₄) se vincula con condiciones de alta temperatura, mientras que el acetileno (C₂H₂) se genera ante fallas de muy alta temperatura, elevada energía o presencia de arco eléctrico [7].



PD	Descarga Parcial de tipo Corona
D1	Descargas de baja energía
D2	Descargas de alta energía
T1	Falla térmica, $t < 300^{\circ}\text{C}$
T2	Falla térmica, $300^{\circ}\text{C} < t < 700^{\circ}\text{C}$
T3	Falla térmica, $t > 700^{\circ}\text{C}$
DT	Mezcla de fallas térmicas y eléctricas

Figura 1. Clasificación de fallas en transformadores mediante el diagrama de Duval.

Método de los Gases IEC

Este método emplea tres relaciones gaseosas equivalentes a las utilizadas en el método de Rogers; no obstante, define rangos de diagnóstico diferenciados. En el caso particular de las fallas D1 y D2, se observa una superposición parcial en las zonas de detección, lo que puede generar coincidencias en la clasificación de los eventos. Aun así, resulta esencial establecer una distinción precisa entre ambas categorías, dado que la diferencia radica en el grado de severidad del daño potencial en el equipo y en las acciones preventivas de mantenimiento que deben adoptarse en cada situación [12,13].

Cuadro 4. Relaciones para el análisis por Método de las Gases IEC.

Caso	Falla Característica	$\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$	CH_4/H_2	$\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$
PD	Descarga Parcial	NS	< 0.1	< 0.2
D1	Descarga de baja energía	> 1	$0.1-0.5$	> 1
D2	Descarga de alta energía	$0.6-2.5$	$0.1-1$	> 2
T1	Falla térmica $< 300^{\circ}\text{C}$	NS	> 1	< 1
T2	Falla térmica 300°C a 700°C	< 0.1	> 1	$1 - 4$
T3	Falla térmica $> 700^{\circ}\text{C}$	< 0.2	> 1	> 4

El cuadro 4 presenta las relaciones de concentración entre gases disueltos utilizadas por el método de los gases de la norma IEC para el diagnóstico de fallas en transformadores de potencia. Estas proporciones permiten diferenciar entre descargas parciales, descargas eléctricas de baja o alta energía y fallas térmicas de diversa severidad. Cada tipo de falla se identifica mediante los cocientes $\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$, CH_4/H_2 y $\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$, los cuales reflejan el comportamiento químico del aceite aislante ante distintos niveles de temperatura y energía. Este enfoque posibilita establecer un diagnóstico cualitativo del origen térmico o eléctrico de la anomalía, contribuyendo a la evaluación del estado operativo del transformador.

Método de Redes Neuronales perceptrón multicapa

El perceptrón multicapa (MLP) constituye una de las arquitecturas de redes neuronales artificiales más empleadas en problemas de clasificación, dada su versatilidad y capacidad de generalización. Esta herramienta resulta altamente flexible, ya que puede aproximar y predecir relaciones complejas entre datos provenientes de fenómenos reales, alcanzando niveles

elevados de precisión y confiabilidad [14]. Previo al entrenamiento de la red, es esencial realizar un preprocesamiento adecuado de los datos, el cual incluye el escalado o normalización de las variables.

Este procedimiento permite ajustar los valores de entrada a un rango común, reduciendo el efecto de posibles valores atípicos y mejorando la estabilidad numérica del modelo. Aunque no todos los conjuntos de datos requieren obligatoriamente este paso, su aplicación es altamente recomendable para optimizar el rendimiento y la convergencia del algoritmo. Diversos estudios han demostrado que la selección apropiada del método de normalización puede incrementar de manera significativa la precisión del modelo de aprendizaje automático [15]. El modelo MLP procesa la información a través de tres tipos de capas: una capa de entrada, una o varias capas ocultas y una capa de salida. La capa de entrada recibe los datos originales y los transmite a las capas ocultas, donde se ejecuta el proceso de aprendizaje mediante la asignación de pesos y sesgos a cada neurona. Dichos parámetros determinan la influencia relativa de cada variable en la respuesta del sistema. La cantidad de capas ocultas y de neuronas por capa se ajusta en función de la complejidad del problema, permitiendo que la red capture relaciones no lineales más profundas. En configuraciones con múltiples capas ocultas, la salida de una neurona actúa como entrada de las neuronas de la siguiente capa, conformando una estructura jerárquica que refina progresivamente la representación de los datos.

Para que una red neuronal sea capaz de aprender patrones complejos, resulta imprescindible incorporar no linealidad al modelo. Este comportamiento se logra mediante la implementación de funciones de activación en las capas ocultas, las cuales determinan si la salida de una neurona se transmite a la siguiente capa o se desactiva. Entre las funciones más utilizadas destaca la Rectified Linear Unit (ReLU), reconocida por su simplicidad computacional y alto rendimiento durante el entrenamiento [16].




Figura 2. Estructura general de una red neuronal de perceptrón multicapa (MLP).

Esta función permite el paso de la información únicamente cuando el valor de entrada es mayor que cero, y devuelve cero para valores negativos, inhabilitando así la neurona correspondiente. El proceso de aprendizaje se fundamenta en la minimización del error entre la salida generada por la red y la salida esperada [17]. Para ello se emplea el algoritmo de retropropagación del error, mediante el cual se ajustan iterativamente los pesos sinápticos de la red. Este mecanismo permite que el modelo mejore progresivamente su precisión, repitiendo el ciclo de ajuste hasta alcanzar la convergencia deseada. La figura 2 la estructura básica de un perceptrón multicapa (MLP), mostrando el flujo de información desde la capa de entrada, a través de una o varias capas ocultas, hasta la capa de salida. Cada conexión entre neuronas representa un peso ajustable, cuyo valor se optimiza durante el proceso de entrenamiento para mejorar la capacidad predictiva del modelo.

Resultados

El conjunto de datos utilizado en este estudio proviene de registros físicos del Análisis de Gases Disueltos (DGA) realizados en 107 transformadores de potencia instalados en distintas redes eléctricas de Centroamérica durante varios años. Los datos fueron suministrados con fines académicos y fueron anonimizados para proteger información sensible como el nombre de la empresa, el año de muestreo y la marca del transformador, al no ser relevantes para el diagnóstico de fallas. Todos los registros se derivan de informes reales de pruebas de aceite y sus análisis correspondientes, los cuales fueron digitalizados para conformar una base de datos histórica que facilite el desarrollo de modelos de diagnóstico basados en datos. La base de datos utilizada que debe estar conformada por los valores de los gases disueltos —hidrógeno, acetileno, etileno, etano y metano— junto con los diagnósticos obtenidos mediante los métodos de Rogers, Dornenburg, Duval y el método de relaciones de gases disueltos. En este trabajo se propone una redefinición de las etiquetas diagnósticas con el propósito de facilitar el procesamiento de la información por parte del modelo de aprendizaje automático.

En los métodos de Rogers y IEC, las fallas se describen con nomenclaturas extensas, tales como “Falla térmica $>700\text{ }^{\circ}\text{C}$ ” o “Falla térmica, baja temperatura $<300\text{ }^{\circ}\text{C}$ ”. Dado que dichos intervalos de temperatura coinciden con los definidos por el método de Duval, se propone una unificación de la nomenclatura utilizando las mismas abreviaturas de este último. Así, una falla térmica por encima de $700\text{ }^{\circ}\text{C}$ se designa como T3, una falla térmica intermedia ($300\text{--}700\text{ }^{\circ}\text{C}$) como T2, y una falla térmica de baja temperatura ($<300\text{ }^{\circ}\text{C}$) como T1. De forma análoga, la descarga de baja energía se representa como D1. Los cambios realizados en la nomenclatura unificada se resumen en el cuadro 5. En el caso del diagnóstico por el método de Dornenburg, no se efectuaron modificaciones, ya que este tipo de falla no se asocia directamente a un rango definido de temperatura, por lo que se considera una categoría térmica independiente.

Cuadro 5. Cambios propuestos en etiquetas.

Método de Diagnóstico	Falla	Nueva Abreviatura
Rogers	Falla Térmica $> 700^{\circ}\text{C}$	T3
	Falla Térmica $< 700^{\circ}\text{C}$	T2
	Falla Térmica, baja temperatura $< 300^{\circ}\text{C}$	T1
	Descarga de baja energía	D1
Relación IEC	Falla Térmica $> 700^{\circ}\text{C}$	T3
	Falla Térmica, entre 300°C y 700°C	T2
	Falla Térmica, $< 300^{\circ}\text{C}$	T1
	Descarga de Baja Energía (D1)	D1
Dornenburg	Descarga Parcial de Baja Energía	D1
	Posible falla por arco, descarga parcial de alta energía	D2

Este artículo propone un modelo de red neuronal multietiqueta diseñado para procesar y correlacionar los diagnósticos de fallas en transformadores de potencia obtenidos mediante los métodos de Rogers, Dornenburg, Triángulo de Duval y la relación de gases del estándar IEC. Este enfoque permite integrar de forma simultánea los resultados de múltiples métodos, evitando la dependencia de un único criterio diagnóstico y considerando la posibilidad de ocurrencia conjunta de distintos tipos de falla. El modelo desarrollado corresponde a un perceptrón multicapa (MLP) compuesto por tres capas ocultas de 64 neuronas cada una. Los datos de entrada corresponden a las concentraciones de gases disueltos obtenidas del análisis de gases disueltos (DGA), mientras que la capa de salida genera los diagnósticos asociados

a los diferentes métodos de estudio. Para garantizar la estabilidad numérica y la convergencia del modelo, los datos de entrada fueron preprocesados mediante estandarización o escalado. En este caso, se aplicó la técnica de Escalado Robusto, que ajusta los valores de las variables utilizando la mediana y los rangos intercuartílicos del conjunto de datos, reduciendo así la influencia de valores atípicos [6,18].

La selección de hiperparámetros constituye un aspecto crítico para alcanzar un desempeño óptimo. En este trabajo, la cantidad de neuronas por capa y el número de épocas de entrenamiento fueron determinados mediante una búsqueda en cuadrícula (Grid Search), herramienta que permite comparar el rendimiento del modelo bajo diferentes combinaciones de parámetros [19]. La base de datos presenta un desbalance significativo entre clases de diagnóstico. Etiquetas como DT aparecen con menor frecuencia en comparación con T2 y T3, mientras que la clase UF es la más representada. Para mitigar este problema, se implementó un ajuste de umbral óptimo por clase, técnica recomendada en aplicaciones de aprendizaje multietiqueta [20]. Este procedimiento consiste en determinar, para cada etiqueta, el valor de umbral que maximiza el puntaje F1 (F1-score) en el subconjunto de validación. De este modo, se optimiza el rendimiento del modelo por clase y se reduce la incidencia de falsos positivos y falsos negativos, logrando un balance más preciso en la clasificación final.

El cuadro 6 presenta la distribución de las etiquetas de falla contenidas en la base de datos. El método del triángulo de Duval identificó en cuatro ocasiones la presencia potencial de descargas parciales en transformadores. Este tipo de falla, por su naturaleza, suele diagnosticarse mediante ensayos eléctricos directos realizados sobre el equipo, utilizando pruebas de alta tensión no destructivas que permiten cuantificar el grado de deterioro dieléctrico del aislamiento [21]. Si bien es posible aplicar técnicas de simulación de datos para generar casos representativos de este diagnóstico, en el presente estudio se optó por excluir dichos datos simulados, dejando su incorporación como una línea de investigación futura.

Cuadro 6. Distribución de las etiquetas.

UF	T1	T2	T3	D1	D2	DT	PD	Descomposición Térmica
5364	628	476	704	110	94	26	4	36

En cuanto a la evaluación del desempeño del modelo, se utilizaron métricas ampliamente reconocidas en el ámbito del aprendizaje automático. La precisión (Precision) mide la proporción de aciertos entre las fallas diagnosticadas por el modelo, es decir, evalúa cuántos de los diagnósticos emitidos son correctos. La exhaustividad (Recall) refleja la capacidad del modelo para identificar correctamente las fallas reales, evitando omitir aquellas que efectivamente están presentes (reducción de falsos negativos). Por su parte, el puntaje F1 (F1-score) representa el promedio armónico entre precisión y exhaustividad, proporcionando una medida equilibrada del rendimiento global [22].

Dado que el modelo aborda un problema de clasificación multietiqueta, se empleó el Índice de Coincidencia Exacta, métrica que cuantifica el porcentaje de casos en los que el modelo predice correctamente todas las etiquetas presentes y ausentes para un transformador. Además, se generó una matriz de confusión individual por etiqueta y subconjunto de validación, con el propósito de ofrecer una visualización detallada del comportamiento del modelo a lo largo de los distintos pliegues del entrenamiento.

Para la evaluación del rendimiento, se aplicó el método de validación cruzada k-fold, que consiste en dividir el conjunto de datos en k subgrupos. En cada iteración, $k - 1$ subgrupos se utilizan para el entrenamiento y el restante para la prueba, garantizando que cada subconjunto

sea empleado al menos una vez como conjunto de validación [4]. En este trabajo se adoptó un valor de $k = 10$, lo que permite mejorar la estimación del desempeño del modelo y reducir la varianza asociada a la partición de los datos.

Discusión

En la Figura 3 se presenta el rendimiento del modelo para cada etiqueta en los distintos subconjuntos de validación. En la barra lateral derecha se aprecia una degradación cromática que representa el valor del puntaje F1 (F1-Score) correspondiente a cada etiqueta. Un mayor valor de F1-Score indica un mejor desempeño del modelo, evidenciando una adecuada capacidad para evitar tanto falsos positivos como falsos negativos. Las etiquetas con tonalidades más oscuras reflejan diagnósticos más precisos, mientras que los tonos más claros sugieren menor consistencia en la clasificación dentro del subconjunto respectivo.




Figura 3. Distribución del puntaje F1 por etiqueta y subconjunto en la validación cruzada k-fold).

La etiqueta UF (Sin Falla) alcanza el F1-Score más alto y estable, lo que se atribuye a su alta frecuencia en la base de datos, factor que facilita el aprendizaje del modelo y mejora su capacidad para identificar esta condición con fiabilidad. Este comportamiento es consistente con lo reportado en la literatura de clasificación multietiqueta, donde el desbalance de clases favorece el rendimiento en etiquetas mayoritarias y reduce la sensibilidad en categorías de baja representación [20]. La figura permite así visualizar los diferentes comportamientos del modelo según la etiqueta, así como las variaciones de rendimiento entre los subconjuntos, las cuales se relacionan directamente con el desbalance de clases existente en los datos de entrenamiento.

No obstante, es importante interpretar con cautela los valores elevados del F1-Score en etiquetas con baja representación. En estos casos, un puntaje alto no necesariamente implica un aprendizaje real del modelo, ya que puede deberse a aciertos fortuitos derivados del número reducido de muestras por subconjunto. Este fenómeno ha sido documentado en modelos de diagnóstico basados en aprendizaje automático aplicados al análisis de gases disueltos, donde la escasez de datos limita la capacidad de generalización ante fallas poco frecuentes [22]. Esto sugiere que, para dichas clases, el modelo podría acertar por coincidencia más que por una comprensión efectiva de los patrones asociados a la falla.

La Figura 4 presenta la relación entre la exhaustividad (Recall) y la precisión (Precision) obtenidas por el modelo. La exhaustividad mide la capacidad del modelo para detectar correctamente las fallas reales presentes en los transformadores, mientras que la precisión cuantifica qué proporción de los diagnósticos positivos emitidos corresponde efectivamente a fallas reales.

En términos visuales, se observa que, para valores bajos de exhaustividad, la precisión se mantiene cercana a 1, lo que indica que, aunque el modelo diagnostica un número reducido de fallas, los diagnósticos emitidos poseen alta confiabilidad. Conforme aumenta la exhaustividad, se incrementa el número de etiquetas diagnosticadas correctamente, manteniéndose una precisión elevada. El valor de precisión promedio obtenido ($AP = 0,993$) evidencia la robustez del modelo y su baja propensión a producir falsos positivos, comportamiento esperado en clasificadores con adecuada separación de clases según métricas estándar de evaluación en aprendizaje automático [22].




Figura 4. relación entre la exhaustividad (Recall) y la precisión (Precision) obtenidas.

Con el fin de establecer un punto de comparación, se entrenó un modelo con menor número de épocas, graficando nuevamente la curva Precisión–Exhaustividad (Figura 5). En este caso, se aprecia que, a medida que el modelo intenta diagnosticar un mayor número de etiquetas, la precisión disminuye de forma significativa. Este comportamiento refleja una tendencia al sobreajuste y a la activación de diagnósticos para fallas inexistentes, fenómeno ampliamente documentado cuando los modelos no alcanzan una convergencia adecuada durante el entrenamiento [19]. La comparación evidencia la importancia de una selección apropiada de hiperparámetros para garantizar estabilidad y confiabilidad diagnóstica.




Figura 5. curva Precisión–Exhaustividad.

Por otra parte, la Curva Característica Operativa del Receptor (ROC) permite visualizar la relación entre la exhaustividad y la tasa de falsos positivos, mostrando cómo varía la detección de diagnósticos a medida que aumenta la cantidad de clasificaciones erróneas. En la Figura 6 se observa una trayectoria próxima al vértice superior izquierdo, con un área bajo la curva (AUC) de 0,998, lo que confirma un excelente desempeño en la discriminación entre fallas reales y no reales. Resultados similares han sido reportados en modelos basados en perceptrones multicapa aplicados al diagnóstico de transformadores, donde se alcanzan valores de AUC superiores a 0,99 al emplear datos de DGA preprocesados adecuadamente [6]. En contraste, al entrenar un modelo con menor número de iteraciones (Figura 7), la curva evidencia un valor de exhaustividad más bajo incluso para altos valores de falsos positivos, indicando una reducción en la capacidad predictiva del modelo.




Figura 6. Curva ROC del modelo propuesto.




Figura 7. Análisis al modelo propuesto.

Como resultado global, se obtuvo un índice de coincidencia exacta (EMR) promedio del 90,95 %, lo que refleja la proporción de casos en los que el modelo acierta simultáneamente todas las etiquetas diagnósticas asociadas a un transformador. Este indicador resulta especialmente exigente en problemas multietiqueta, ya que requiere la predicción correcta de todas las fallas concurrentes. El valor alcanzado es comparable con investigaciones previas que emplean

redes neuronales para el diagnóstico de transformadores, donde se reportan precisiones globales entre 91 % y 94 % dependiendo de la arquitectura y del conjunto de datos utilizado [4], [5]. El cuadro 7 resume los resultados globales de precisión obtenidos del modelo propuesto.

Cuadro 7. Resultados globales de precisión del modelo.

Subconjunto	EMR (%)
1	88.71
2	87.70
3	83.96
4	91.94
5	93.05
6	93.01
7	94.09
8	90.91
9	93.55
10	92.55
Total	90.95

En términos generales, los resultados evidencian un desempeño altamente satisfactorio del modelo propuesto. Los valores del F1-Score muestran un rendimiento consistente en la mayoría de las etiquetas, destacando la categoría UF por su robustez y estabilidad. Las variaciones observadas entre subconjuntos se explican principalmente por el desbalance de clases y la limitada representación de ciertas fallas.

Finalmente, es importante resaltar que el enfoque multietiqueta implementado constituye una ventaja frente a modelos tradicionales basados en un único método diagnóstico. La integración simultánea de los resultados de Rogers, Dornenburg, Duval e IEC permite capturar la coexistencia de múltiples fallas en un mismo transformador, proporcionando una representación más realista de su condición operativa. Este enfoque coincide con tendencias recientes en monitoreo inteligente de activos eléctricos, donde el uso combinado de múltiples fuentes diagnósticas mejora la precisión y la toma de decisiones en mantenimiento predictivo [1].

Conclusiones

El modelo desarrollado mediante un perceptrón multicapa (MLP) demostró la viabilidad de aplicar técnicas de aprendizaje automático multietiqueta para el diagnóstico de fallas en transformadores de potencia. Este enfoque permite identificar de manera simultánea distintos tipos de fallas térmicas y eléctricas en un mismo equipo, integrando los resultados de los métodos de Rogers, Dornenburg, Duval y la relación de gases IEC, a partir de los datos obtenidos del Análisis de Gases Disueltos (DGA) en el aceite dieléctrico. El modelo alcanzó un Índice de Coincidencia Exacta del 90,95 %, lo que confirma su alta precisión para reproducir correctamente la totalidad de los diagnósticos de falla en cada muestra, incluso en casos con fallas concurrentes. Los valores de precisión promedio ($AP = 0,993$) y de área bajo la curva ROC ($AUC = 0,998$) reflejan un desempeño sobresaliente en la detección de fallas, caracterizado por una baja incidencia de falsos positivos y falsos negativos. En consecuencia, el modelo se consolida como una herramienta eficaz para el diagnóstico de fallas y el análisis de la condición de transformadores de potencia, contribuyendo a la toma de decisiones técnicas en mantenimiento predictivo y gestión de activos eléctricos. Sin embargo, se identificó un desbalance de clases en la base de datos, particularmente en etiquetas de baja frecuencia, lo

que puede limitar la generalización del modelo frente a nuevos escenarios de falla. Por ello, se propone como trabajo futuro la ampliación y balanceo de la base de datos mediante la inclusión de registros experimentales y técnicas de simulación que generen casos de falla específicos y verificados. Con ello se busca fortalecer la capacidad predictiva del modelo y avanzar hacia la detección temprana de fallas incipientes, potenciando su aplicación en estrategias de monitoreo inteligente y diagnóstico avanzado en sistemas eléctricos de potencia.

Limitaciones

El presente estudio presenta algunas limitaciones que deben considerarse al interpretar los resultados. En primer lugar, el modelo fue desarrollado a partir de una base de datos compuesta por registros de 107 transformadores de potencia, lo que restringe la diversidad de condiciones operativas y tipologías de falla analizadas. Asimismo, se identificó un desbalance significativo en la distribución de las etiquetas diagnósticas, con predominio de la clase Sin Falla (UF) frente a categorías de baja frecuencia como PD y DT, lo cual puede influir en el proceso de aprendizaje y en la capacidad de generalización del modelo, especialmente para fallas poco representadas.

Adicionalmente, el análisis se fundamenta exclusivamente en datos provenientes del Análisis de Gases Disueltos (DGA) y en registros de transformadores ubicados en redes eléctricas de Centroamérica. La ausencia de variables complementarias —como ensayos eléctricos, parámetros dieléctricos o historiales de mantenimiento— y la limitación geográfica de la muestra podrían afectar la extrapolación de los resultados a otros contextos operativos. Futuras investigaciones deberían considerar la ampliación y balanceo de la base de datos, así como la integración de fuentes diagnósticas adicionales para fortalecer la robustez del modelo propuesto.

Agradecimientos

Esta investigación forma parte del proyecto VIE-1341025: Mantenimiento predictivo: desarrollo de sistemas de diagnóstico y pronóstico. Las personas autoras expresan su agradecimiento a la Vicerrectoría de Investigación y Extensión del Instituto Tecnológico de Costa Rica por su apoyo financiero y asistencia durante esta investigación.

Referencias

- [1] R. Zemouri, "Power Transformer Prognostics and Health Management Using Machine Learning: A Review and Future Directions," *Machines*, vol. 13, no. 2, Art. no. 125, Feb. 2025, doi: 10.3390/machines13020125. Available: <https://www.mdpi.com/2075-1702/13/2/125>
- [2] J. Zupan, "Introduction to Artificial Neural Network (ANN) Methods: What They Are and How to Use Them," *Acta Chimica Slovenica*, vol. 41, no. 3, pp. 327–352, 1994. Available: <https://acta.chem-soc.si>
- [3] W. Wu, G. C. Dandy, and H. R. Maier, "Protocol for Developing ANN Models and Its Application to the Assessment of the Quality of the ANN Model Development Process in Drinking Water Quality Modelling," *Environmental Modelling & Software*, vol. 54, pp. 108–127, Apr. 2014, doi: 10.1016/j.envsoft.2013.12.016.
- [4] P. H. Mukti, F. A. Pamuji, and B. S. Munir, "Implementation of Artificial Neural Networks for Determining Power Transformer Condition," in *Proc. 10th Int. Conf. Information Technology and Electrical Engineering (ICITEE)*, Surabaya, Indonesia, 2022, pp. 1–6, doi: 10.1109/ICITEE56409.2022.9970234.
- [5] J. D. Moposita, D. G. Pujos, S. Marrero-Ramírez, and R. Salazar-Archig, "Aplicación de Redes Neuronales en el Análisis de Gases Disueltos para el Mantenimiento Preventivo de Transformadores de Potencia," *Revista Ibérica de Sistemas e Tecnologías de Informação (RISTI)*, no. E73, pp. 312–327, Sep. 2024. Available: <https://www.risti.xyz>

- [6] E. Moradi, "A Data-Driven Based Robust Multilayer Perceptron Approach for Fault Diagnosis of Power Transformers," in *Proc. 20th CSI Int. Symp. Artificial Intelligence and Signal Processing (AISP)*, Babol, Iran, 2024, doi: 10.1109/AISP61396.2024.10445872.
- [7] IEEE Power & Energy Society, *IEEE Guide for the Interpretation of Gases Generated in Mineral Oil-Immersed Transformers*, IEEE Std C57.104-2019, New York, NY, USA: IEEE, 2019, doi: 10.1109/IEEESTD.2019.8890040.
- [8] International Electrotechnical Commission, *Mineral Oil-Filled Electrical Equipment in Service — Guidance on the Interpretation of Dissolved and Free Gases Analysis*, IEC 60599, 4th ed., Geneva, Switzerland: IEC, 2022. Available: <https://webstore.iec.ch/publication/67220>
- [9] H.-C. Sun, Y.-C. Huang, and C.-M. Huang, "A Review of Dissolved Gas Analysis in Power Transformers," *Energy Procedia*, vol. 14, pp. 1220–1225, 2012, doi: 10.1016/j.egypro.2011.12.1120.
- [10] J. T. Sarria-Arias, N. A. Guerrero-Bello, and E. Rivas-Trujillo, "Estado del Arte del Análisis de Gases Disueltos en Transformadores de Potencia," *Revista Facultad de Ingeniería*, no. 36, pp. 105–122, 2014. Available: <https://revistas.udea.edu.co>
- [11] R. R. Rogers, "IEEE and IEC Codes to Interpret Incipient Faults in Transformers, Using Gas in Oil Analysis," *IEEE Transactions on Electrical Insulation*, vol. EI-13, no. 5, pp. 349–354, Oct. 1978, doi: 10.1109/TEI.1978.298141.
- [12] M. H. A. Hamid *et al.*, "Dissolved Gas Analysis (DGA) of Natural Ester Oils under Arcing Faults," *Journal of Fundamental and Applied Sciences*, vol. 9, no. 3S, pp. 105–115, Sep. 2017, doi: 10.4314/jfas.v9i3s.8.
- [13] N. Abu Bakar, A. Abu-Siada, and S. Islam, "A Review of Dissolved Gas Analysis Measurement and Interpretation Techniques," *IEEE Electrical Insulation Magazine*, vol. 30, no. 3, pp. 39–49, May–Jun. 2014, doi: 10.1109/MEI.2014.6804740.
- [14] S. Etemadi, M. Khashei, and S. Tamizi, "Reliability-Based Multilayer Perceptrons for Classification and Forecasting," *Information Sciences*, vol. 651, Art. no. 119716, 2023, doi: 10.1016/j.ins.2023.119716.
- [15] A. Hashemi Fath, F. Madanifar, and M. Abbasi, "Implementation of Multilayer Perceptron (MLP) and Radial Basis Function (RBF) Neural Networks to Predict Solution Gas–Oil Ratio of Crude Oil Systems," *Petroleum*, vol. 6, no. 1, pp. 80–91, 2020, doi: 10.1016/j.petlm.2018.12.002.
- [16] A. D. Rasamoelina, F. Adjailia, and P. Sinčák, "A Review of Activation Function for Artificial Neural Network," in *Proc. IEEE 18th World Symp. Applied Machine Intelligence and Informatics (SAMII)*, Herľany, Slovakia, Jan. 2020, pp. 281–286, doi: 10.1109/SAMII48414.2020.9108717.
- [17] M.-C. Popescu, V. E. Balas, L. Perescu-Popescu, and N. Mastorakis, "Multilayer Perceptron and Neural Networks," *WSEAS Transactions on Circuits and Systems*, vol. 8, no. 7, pp. 579–588, Jul. 2009. Available: <https://wseas.com>
- [18] N. V. G. Raju, K. P. Lakshmi, V. M. Jain, A. Kalidindi, and V. Padma, "Study the Influence of Normalization/Transformation Process on the Accuracy of Supervised Classification," in *Proc. 3rd Int. Conf. Smart Systems and Inventive Technology (ICSSIT)*, 2020, pp. 729–734, doi: 10.1109/ICSSIT48917.2020.9214263.
- [19] S. M. Malakouti, M. B. Menhaj, and A. A. Suratgar, "The Usage of 10-Fold Cross-Validation and Grid Search to Enhance ML Methods Performance in Solar Farm Power Generation Prediction," *Cleaner Engineering and Technology*, vol. 15, Art. no. 100664, 2023, doi: 10.1016/j.clet.2023.100664.
- [20] R.-E. Fan and C.-J. Lin, "A Study on Threshold Selection for Multi-Label Classification," *Journal of Machine Learning Research*, vol. 7, pp. 2115–2146, 2007. Available: <https://www.jmlr.org>
- [21] G. A. Gómez-Ramírez, "Medición de Descargas Parciales en Transformadores de Potencia bajo los Estándares Internacionales IEC e IEEE," *Tecnología en Marcha*, vol. 31, no. 1, pp. 70–80, 2018, doi: 10.18845/tm.v31i1.3498.
- [22] S. A. Wani, D. Gupta, M. U. Farooque, and S. A. Khan, "Multiple Incipient Fault Classification Approach for Enhancing the Accuracy of Dissolved Gas Analysis (DGA)," *IET Science, Measurement & Technology*, vol. 13, no. 7, pp. 959–967, 2019, doi: 10.1049/iet-smt.2018.5135.

Declaración sobre uso de Inteligencia Artificial (IA)

Los autores declaramos que hemos utilizado una herramienta de inteligencia artificial *Google AI Studio* para asistirnos en la redacción de este artículo. Esta herramienta nos ayudó a mejorar la estructura y la claridad del texto. Los contenidos generados por la IA fueron revisados minuciosamente por nosotros para asegurar su precisión y coherencia con el objetivo del estudio