

Evaluación, diseño y estimación de indicador de vida útil remanente (indicador de salud) de los transformadores de potencia de una Central Térmica

Juan Pablo Luna Espitia

Trabajo de Grado para Optar al Título de Magister en Gerencia de Mantenimiento

Director:

Jabib Eduardo Quiroga Méndez

PhD. en Ingeniería Mecánica

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingeniería Mecánica

Maestría en Gerencia de Mantenimiento

Bucaramanga

2025

Dedicatoria

A Dios, por darme la fuerza para culminar una vez más un proyecto académico en mi vida.

A mi papá, ejemplo de vida, perseverancia y fortaleza.

A mi mamá, que desde el cielo me acompaña hace muchos años.

Agradecimientos

A la Universidad Industrial de Santander, institución que ha marcado mi historia profesional y personal, y que me ha permitido formarme como Ingeniero Electricista, Especialista en Gerencia de Mantenimiento y ahora como Magister en Gerencia de Mantenimiento. Gracias por el conocimiento recibido y por seguir siendo parte fundamental de mi crecimiento.

Tabla de Contenido

| | Pág. |
|---|-------------|
| Introducción | 14 |
| 1. Planteamiento del problema..... | 17 |
| 2. Objetivos..... | 20 |
| 2.1. Objetivo General..... | 20 |
| 2.2. Objetivos Específicos..... | 20 |
| 3. Justificación del Proyecto | 21 |
| 4. Marco Teórico..... | 24 |
| 4.1. Transformador de potencia | 24 |
| 4.2. Generación de energía en central térmica | 24 |
| 4.3. Vida útil de los transformadores | 28 |
| 4.4. Indicador de salud de un activo | 29 |
| 4.5. Métodos tradicionales de cálculo..... | 29 |
| 4.6. Métodos basados en inteligencia artificial..... | 30 |
| 4.7. Factores que influyen en la estimación del índice de salud..... | 31 |
| 4.8. Criterios de evaluación del envejecimiento | 32 |
| 4.9. Integración de datos y algoritmos inteligentes..... | 32 |
| 5. Desarrollo del plan de trabajo | 33 |
| 5.1. Identificación de factores más significativos en el índice | 33 |
| 5.2. Relevancia de factores y variables del índice | 41 |
| 5.2.1. Edad cronológica | 42 |

| | |
|--|----|
| 5.2.2. Pruebas dieléctricas y fisicoquímicas del aceite (ADFQ)..... | 42 |
| 5.2.3. Análisis de gases disueltos (DGA) | 44 |
| 5.2.4. Prueba de furanos / índice de polimerización | 45 |
| 5.2.5. Pruebas eléctricas..... | 47 |
| 5.2.6. Estado físico..... | 48 |
| 5.2.7. Historial de fallas | 50 |
| 5.2.8. Condiciones de operación..... | 51 |
| 5.2.9. Ubicación geográfica | 53 |
| 5.3. Metodología para la evaluación, diseño y estimación de indicador de vida útil | 56 |
| 5.3.1. Metodología y explicación del algoritmo | 57 |
| 5.3.1.1. Flujo de trabajo en MATLAB..... | 57 |
| 5.3.1.2. Algoritmo Levenberg-Marquardt (trainlm). | 59 |
| 5.3.2. Configuración y resultados de la red neuronal (ANN) | 59 |
| 5.3.2.1. Fundamentación de la elección: 10 neuronas en la capa oculta..... | 60 |
| 5.3.2.2. Red con una capa oculta y 10 neuronas | 63 |
| 5.3.2.3. Red con dos capas ocultas (10 neuronas en cada capa)..... | 66 |
| 5.3.2.4. Comparación de configuraciones en ANN | 69 |
| 5.3.3. Fundamentos de ANFIS..... | 70 |
| 5.3.4. Resultados del ANFIS para estimar la vida útil en transformadores | 71 |
| 5.3.4.1. Curva de aprendizaje..... | 72 |
| 5.3.4.2. Dispersión real vs. Predicho. | 72 |
| 5.3.4.3. Métricas globales | 73 |
| 5.3.5. Comparación entre ANFIS y ANN..... | 74 |

| | |
|--|----|
| 5.3.6. Resultados del cálculo del indicador de vida útil remanente | 77 |
| 6. Conclusiones | 81 |
| Bibliografía | 85 |

Lista de Tablas

| | Pág. |
|---|-------------|
| Tabla 1 <i>Listado de transformadores de la central térmica</i> | 28 |
| Tabla 2 <i>Listado de pruebas dieléctricas y fisicoquímicas</i> | 33 |
| Tabla 3 <i>Listado de gases de falla claves</i> | 34 |
| Tabla 4 <i>Resultados de análisis dieléctrico y fisicoquímico de aceite TX-01</i> | 36 |
| Tabla 5 <i>Resultados de análisis de gases disueltos (DGA) TX-01</i> | 37 |
| Tabla 6 <i>Resultados análisis de furanos/Grado de polimerización TX-01</i> | 38 |
| Tabla 7 <i>Datos de carga y temperatura TX-01</i> | 39 |
| Tabla 8 <i>Factores que pueden incidir en la formulación</i> | 41 |
| Tabla 9 <i>Pruebas dieléctricas y fisicoquímicas del aceite</i> | 43 |
| Tabla 10 <i>Gases típicos y sus interpretaciones</i> | 44 |
| Tabla 11 <i>Relevancia del análisis de furanos</i> | 45 |
| Tabla 12 <i>Relevancia del análisis de furanos</i> | 46 |
| Tabla 13 <i>Pruebas eléctricas relevantes en transformadores / Vida útil</i> | 47 |
| Tabla 14 <i>Tipos de fallas relevantes en transformadores</i> | 50 |
| Tabla 15 <i>Factores geográficos y su impacto en la vida útil de un transformador</i> | 53 |
| Tabla 16 <i>Condición geográfica / factor en el indicador</i> | 54 |
| Tabla 17 <i>Decisión de factores que serán variable de entrada en el indicador</i> | 55 |
| Tabla 18 <i>Resumen de decisión de variables de entrada para el indicador</i> | 55 |
| Tabla 19 <i>MSE promedio en validación</i> | 60 |
| Tabla 20 <i>Experimentos comparativos</i> | 62 |

| | |
|--|----|
| Tabla 21 <i>Muestras de reglas fuzzy tipo Takagi-Sugeno</i> | 71 |
| Tabla 22 <i>Comparación entre ANFIS y ANN</i> | 74 |
| Tabla 23 <i>Resultados indicador vida útil remanente de transformadores</i> | 78 |
| Tabla 24 <i>Comparativa de resultados método tradicional vs. ANN - ANFIS</i> | 79 |
| Tabla 25 <i>Resultados vida útil promedio tradicional vs. ANN - ANFIS</i> | 79 |

Lista de Figuras

| | Pág. |
|--|-------------|
| Figura 1 <i>Ciclo combinado 1</i> | 26 |
| Figura 2 <i>Ciclo combinado 2</i> | 27 |
| Figura 3 <i>Resultados de cromatografía de gases disueltos de aceite TX-01</i> | 40 |
| Figura 4 <i>Análisis tendencias cromatografía de gases disueltos de aceite TX-01</i> | 40 |
| Figura 5 <i>Análisis tendencias prueba dieléctrica y fisicoquímicas aceite TX-01</i> | 41 |
| Figura 6 <i>Estructura y configuración</i> | 63 |
| Figura 7 <i>Comparación: Real vs Predicho (entrenamiento)</i> | 64 |
| Figura 8 <i>Curva de desempeño (MSE)</i> | 64 |
| Figura 9 <i>Histogramas de error y regresión</i> | 65 |
| Figura 10 <i>Estructura y configuración</i> | 66 |
| Figura 11 <i>Curva de desempeño (MSE)</i> | 67 |
| Figura 12 <i>Histogramas de error y regresión</i> | 68 |
| Figura 13 <i>Comparación: Real vs Predicho (entrenamiento)</i> | 69 |
| Figura 14 <i>Curvas de aprendizaje ANFIS</i> | 72 |
| Figura 15 <i>Dispersión: Real vs Predicho (entrenamiento)</i> | 73 |
| Figura 16 <i>Modelo propuesto para estimación de la vida útil remanente de los transformadores de potencia</i> | 77 |

Lista de Apéndices

Apéndice A. CargarDatos.m – Lectura y extracción de variables

Apéndice B. dividirDatos.m – Partición Train/Val/Test

Apéndice C. entrenarRedNeuronal.m – Configuración y entrenamiento ANN

Apéndice D. entrenarRedNeuronalEX.m – Configuración y entrenamiento ANN normalizada.

Apéndice E. evaluarRed.m – Métricas en el espacio real

Apéndice F. IVUR_pipeline.m – Entrenamiento caso base

Apéndice G. MAIN_EX.m – Sintaxis principal del código

“Los apéndices están adjuntos y puede visualizarlos en la base de datos de la biblioteca UIS”

Glosario

Activo: cualquier recurso o elemento que una organización utiliza para llevar a cabo sus procesos y actividades, y que tiene un valor tangible o intangible para ella (ISO 9001). En planta de generación de energía eléctrica, puede referirse a equipos como turbinas, generadores, transformadores, calderas, motores, entre otros.

Furanos: son indicadores de la degradación del papel aislante en un transformador. El análisis de furanos permite determinar el grado de degradación del papel aislante y, por lo tanto, el estado de envejecimiento del transformador.

Grado de polimerización: DP (por sus siglas en inglés Degree of Polymerization) se refiere al número de monómeros de glucosa que componen la molécula de celulosa. Este valor es un indicador clave del estado de envejecimiento del aislamiento y se ve afectado por la temperatura y el tiempo de funcionamiento del transformador.

Índice: número en una escala específica (por ejemplo, 0 a 1 o 1 a 100) que refleja la condición integral del activo. Un valor elevado indica buen estado; un valor bajo señala una alta probabilidad de falla o la necesidad de reemplazo (Londoño et al., 2022).

Papel Kraft: material aislante ampliamente utilizado en transformadores debido a su resistencia mecánica, dieléctrica y su alta pureza química.

Salud: estado de un activo que refleja su habilidad para desempeñar su función (técnica, operativa) en el período de vida previsto por el usuario o la compañía (Heywood & McGrill, 2008).

Vida útil: es el tiempo durante el cual se espera que un activo funcione y por tanto genere ingresos a la compañía dueña del activo, y por lo cual, es utilizado para amortizar el activo en la medida que se va desgastando.

Resumen

Título: Evaluación, diseño y estimación de indicador de vida útil remanente de los transformadores de potencia de una Central Térmica*

Autor: Juan Pablo Luna Espitia**

Palabras Clave: Transformadores de potencia, vida útil remanente, ANN, ANFIS, furanos.

Descripción: Los transformadores de potencia son equipos críticos en la cadena de generación de energía eléctrica y su indisponibilidad impacta de forma directa la confiabilidad y el balance económico de cualquier central térmica. Esta investigación formula un Indicador de Vida Útil Remanente (IVUR) que integra información dieléctrica, fisicoquímica, cromatografía de gases y operativa con técnicas de inteligencia artificial, a fin de priorizar el mantenimiento y prevenir fallas catastróficas.

Se analizaron 4680 registros históricos (2012-2024) correspondientes a nueve transformadores con 20 variables: rigidez dieléctrica, humedad, número ácido, densidad relativa, tensión interfacial, factor de potencia, índice de calidad del aceite, nueve gases de falla clave, concentración de furanos, grado de polimerización, carga y temperatura. Tras un estudio de relevancia, se descartaron edad cronológica y pruebas eléctricas de rutina, estado físico, historial de fallas y ubicación geográfica, enfocándose en los factores que explican > 85 % de la varianza.

El IVUR se estimó mediante dos enfoques:

- Red Neuronal Artificial (ANN) feed forward con algoritmo Levenberg Marquardt.
- Sistema Neuro Difuso Adaptativo (ANFIS) con 20 funciones de membresía gaussiana y entrenamiento híbrido.

Ambos modelos se entrenaron con un reparto 70-15-15 y mostraron alta precisión ($MSE \leq 8,5 \times 10^{-3}$; $R \geq 0,85$ en prueba). La comparación con los valores de laboratorio basados en la curva de Doble para furanos arrojó errores relativos < 2 % en los nueve equipos, confirmando la validez del IVUR. El transformador TX08 resultó ser el más crítico, con $IVUR \approx 76 \%$, lo que respalda decisiones de intervención prioritaria.

El estudio demuestra que la combinación de ANN y ANFIS supera la subjetividad de los métodos ponderados tradicionales, brinda interpretabilidad suficiente y reduce el riesgo operativo. Se recomienda implementar monitoreo en línea y validación cruzada continua para refinar el índice y soportar la toma de decisiones de la gerencia de activos.

* Trabajo de Grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Mecánica. Ingeniería Mecánica. Director: Jabib Eduardo Quiroga Méndez. PhD. en Ingeniería Mecánica.

Abstract

Title: Evaluation, design and estimation of a remaining useful life indicator for power transformers in a thermal power plant*

Author: Juan Pablo Luna Espitia**

Key words: Power transformers, remaining useful life, ANN, ANFIS, furan analysis.

Description: Power transformers are critical assets in the electricity generation chain, and their unavailability directly impacts the reliability and economic balance of any thermal power plant. This work proposes a Remaining Useful Life Indicator (RULI) that blends dielectric, physicochemical, gas in oil and operating data with artificial intelligence methods to support maintenance prioritization and failure prevention.

A database of 4,914 historical samples (2012-2024) from nine transformers was compiled, comprising 20 variables: dielectric strength, moisture, acid number, relative density, interfacial tension, power factor, oil quality index, nine key fault gases, furan concentration, degree of polymerization, load, and temperature. Feature relevance analysis discarded chronological age and routine electrical testing, physical condition, failure history, and geographic location, focusing on factors explaining more than 85 % of variance.

RULI was computed using two approaches:

- A Feed forward Artificial Neural Network trained with the Levenberg Marquardt algorithm.
- An Adaptive Neuro Fuzzy Inference System employing 20 Gaussian membership functions and a hybrid learning scheme.

With a 70-15-15 train validation test split, both models achieved high accuracy ($MSE \leq 8.5 \times 10^{-3}$; $R \geq 0.85$ on test data). Comparison with laboratory estimates based on Duval's furan curve showed relative errors below 2 % across all units, confirming the robustness of the indicator. Transformer TX08 emerged as the most critical asset, with a RULI of approximately 76 %, guiding priority maintenance actions.

The study evidences that combining ANN and ANFIS surpasses the subjectivity of weighted sum methods, offering adequate interpretability and mitigating operational risk. Future work should include on line sensor integration and continuous cross validation to enhance indicator fidelity and asset management decision making.

* Degree Work

** Faculty of Physicomechanical Engineering. School of Mechanical Engineering. Mechanical Engineering. Director: Jabib Eduardo Quiroga Mendez. PhD. in Mechanical Engineering.

Introducción

La disponibilidad de energía eléctrica continúa siendo uno de los pilares fundamentales para impulsar el desarrollo económico y social de los países. En el caso de Colombia, este recurso cubre aproximadamente el 96,55% de la población, de acuerdo con el Índice de Cobertura de Energía Eléctrica (ICEE), lo que avala la relevancia de contar con un suministro confiable (Ministerio de Minas y Energía, 2021). Para lograrlo, es indispensable no solo la generación de suficiente electricidad, sino también el fortalecimiento de la infraestructura que la transporta y distribuye a lo largo de las diferentes etapas del Sistema Interconectado Nacional (SIN): generación, transmisión, distribución y comercialización. Dentro de este esquema, el rol de los transformadores de potencia resulta primordial, pues de su adecuado funcionamiento depende la continuidad y estabilidad del servicio (Zhang et al., 2020).

En los últimos años, se ha intensificado el interés en desarrollar técnicas que permitan monitorear el estado de salud de los transformadores y, de este modo, anticipar fallas que podrían acarrear interrupciones y pérdidas económicas considerables (Liu et al., 2021).

Las metodologías convencionales de evaluación se basan principalmente en mediciones de variables críticas como la temperatura de operación, el contenido de humedad y los gases disueltos en el aceite aislante, información que luego es interpretada bajo el marco de referencias normativas como IEC, IEEE o CIGRE (IEC 60296, 2003; IEC 60422, 2013; IEC 60599, 2007; IEEE C57.104, 2008; IEEE C57.106, 2006; CIGRE 445, 2011). A pesar de su utilidad, estos métodos pueden verse influidos por la subjetividad de los expertos y por la diversidad de parámetros y recomendaciones que a veces difieren entre estándares, lo que dificulta la comparación uniforme de resultados (Martínez & Gómez, 2020).

Para enfrentar dichas limitaciones y reducir el grado de subjetividad, han tomado relevancia los enfoques basados en inteligencia artificial, en especial aquellos que emplean Redes Neuronales Artificiales (ANN) y Sistemas Neuro-Difusos Adaptativos (ANFIS). Estas técnicas tienen la capacidad de procesar grandes volúmenes de datos y aprender relaciones no lineales entre las variables de entrada y la condición operativa de los transformadores (Wang et al., 2022). Por un lado, las redes neuronales permiten elaborar modelos que, a partir de información histórica de temperatura, cargas térmicas, características químicas y ensayos dieléctricos, pueden predecir el comportamiento dinámico del equipo con un margen de error cada vez menor (Liu et al., 2021).

Por otro lado, los sistemas neuro-difusos (ANFIS) combinan reglas de inferencia difusas con el aprendizaje propio de las redes neuronales, lo que posibilita capturar la incertidumbre natural en ciertos parámetros y en la experiencia acumulada por el personal de mantenimiento (Wu et al., 2021). Así, se consolida un método de evaluación más reproducible y robusto, capaz de estimar el indicador de vida útil remanente —o indicador de salud— de los transformadores de forma más objetiva.

Bajo este panorama, el presente proyecto toma como objeto de estudio los transformadores de potencia de una Central Térmica y propone una metodología integral que combine las guías técnicas internacionales con herramientas de inteligencia artificial, en especial ANN y ANFIS. Inicialmente, se identifican los factores determinantes en el deterioro de los transformadores, prestando especial atención a variables dieléctricas, térmicas y químicas. Luego, se detalla la estrategia de aplicación de ambas técnicas para fusionar dichos datos y ofrecer un diagnóstico sólido y menos dependiente de la percepción subjetiva. Finalmente, se aplica el indicador de salud a un grupo de nueve transformadores en servicio para validar su eficacia y utilidad en la toma de decisiones relacionadas con mantenimiento o reemplazo (Martínez & Gómez, 2020).

Esta investigación propone un método integral que combina normas IEC, IEEE y CIGRE, la experiencia del personal y el potencial de redes neuronales y sistemas neuro-difusos. Con ello, se pretende optimizar la gestión de activos y dar un paso más hacia un mantenimiento más eficiente, oportuno y menos subjetivo, garantizando la confiabilidad operativa de los transformadores de potencia en la central térmica y aportando al desarrollo del sector energético colombiano (Zhang et al., 2020; Wang et al., 2022)

1. Planteamiento del problema

La generación de energía eléctrica en Colombia está respaldada principalmente por centrales hidráulicas y térmicas, cuyo propósito es suplir la demanda nacional de energía. Entre estas instalaciones se encuentra una planta de generación térmica con una capacidad de 605 MW, siendo su aporte vital para garantizar la estabilidad del Sistema Interconectado Nacional (SIN) (Luna-Herrera et al., 2021)

En este contexto, la gestión de activos adquiere un papel relevante para la central, ya que implica optimizar la integridad, confiabilidad y seguridad de todas las instalaciones. Uno de los elementos esenciales de dicha gestión es la identificación y cuantificación de la vida útil remanente de los activos más relevantes, a fin de diseñar planes estratégicos de mantenimiento y, cuando sea necesario, planificar la adquisición o reemplazo de equipos. Entre estos activos, se encuentran los transformadores de potencia, que se encargan de conectar los equipos de generación con las subestaciones eléctricas en los diferentes niveles de tensión. Son de los equipos más importantes en la cadena de generación de energía eléctrica, siendo este último el producto final y objetivo del negocio.

Dada su criticidad, cualquier desperfecto o falla representa no solo una amenaza para la continuidad operativa, sino también una fuente de pérdidas económicas considerables.

La capacidad instalada del parque de transformadores de la central es de 950 MVA, distribuidos en nueve (9) equipos de diferentes potencias nominales y que operan en diferentes niveles de voltaje en alta y baja tensión. En caso de que uno de estos transformadores sufra una salida de servicio no programada, la interrupción del suministro afecta directamente la venta de energía y el cumplimiento de las obligaciones contractuales con XM (entidad administradora del

Mercado Mayorista de Energía en Colombia). Además, se presentan impactos económicos adicionales por concepto de multas, penalizaciones y desgaste en componentes de las turbinas de gas y vapor conectados a los mismos. A esta problemática se suma la complejidad de adquirir en el corto plazo transformadores de reemplazo que tengan características de potencia y tensiones (alta y baja) equivalentes.

A pesar de la existencia de métodos y guías establecidos para determinar el estado de los transformadores en muchos casos estos se basan en la inspección y revisión de parámetros específicos como pruebas eléctricas o análisis de aceite dieléctrico que no necesariamente reflejan el mantenimiento particular que requiere cada componente interno del equipo. No obstante, esta información suele ser de gran utilidad a largo plazo, ya que se pueden hacer análisis de tendencias de parámetros relevantes, permitiendo priorizar decisiones de mantenimiento o reemplazo. Este análisis se sustenta en datos históricos, condiciones de operación y resultados de ensayos eléctricos, químicos y físicos. Sin embargo, la experiencia reciente en central térmica demuestra la necesidad de profundizar y perfeccionar estos métodos.

Problema identificado: Entre los años 2014 y 2019, la planta sufrió la salida de servicio imprevista de dos (2) transformadores de potencia: uno de 65 MVA y otro de 150 MVA, ambos operando a 110 kV. Estas fallas no programadas ocasionaron pérdidas económicas significativas y redujeron la confiabilidad de la central. La adquisición de transformadores de emergencia tuvo grandes dificultades logísticas y costos elevados, pues fue necesario explorar opciones de compra de equipos remanufacturados en mercados internacionales, gestionar su transporte y ponerlos en funcionamiento en el menor tiempo posible para minimizar el impacto sobre la generación de energía.

Ante este panorama, resulta imperativo para la central térmica desarrollar un método confiable para evaluar, diseñar y estimar el indicador de vida útil remanente (o indicador de salud) de los nueve (9) transformadores en servicio, teniendo en cuenta una diversidad de factores que abarcan desde las cargas a que han estado sometidos, temperaturas máximas de operación, la interpretación de las pruebas fisicoquímicas y de gases del aceite aislante. Un indicador integral de vida útil permitirá a la compañía contar con un diagnóstico unificado sobre el estado de los equipos, facilitando la priorización de acciones de mantenimiento, la planificación de reemplazos y la posible extensión de la vida operativa de los transformadores que aún conserven condiciones óptimas de funcionamiento.

En síntesis, el problema se centra en la carencia de una estrategia de gestión de activos que brinde un criterio objetivo y consistente para determinar cuándo un transformador de potencia se acerca a su fin de vida útil o requiere intervenciones específicas. La implantación de una metodología robusta de evaluación y predicción de la salud de los transformadores permitirá mitigar riesgos económicos y operativos, incrementando así la confiabilidad de la planta y, por ende, aportando estabilidad al Sistema Interconectado Nacional de Colombia.

2. Objetivos

2.1. Objetivo General

Formular un indicador de vida útil remanente (indicador de salud) para los transformadores de potencia de una Central Térmica.

2.2. Objetivos Específicos

Identificar los factores significativos que puedan incidir en la formulación del indicador de vida útil remanente de los transformadores de potencia.

Analizar la relevancia de los factores y variables requeridas para la formulación del indicador de vida útil remanente que aplique para los transformadores de planta.

Definir la metodología para la evaluación, diseño y estimación de indicador de vida útil remanente (indicador de salud) y calcular el valor para cada uno de los transformadores.

3. Justificación del Proyecto

La generación de energía eléctrica es un servicio público de primera necesidad que impulsa el desarrollo económico, industrial y social de cualquier región. En el caso colombiano, una parte significativa de la generación se realiza a través de centrales térmicas (29% de la capacidad de generación instalada en Colombia). La central térmica posee actualmente nueve (9) transformadores de potencia que en conjunto alcanzan una capacidad instalada de 950 MVA, distribuidos en dos ciclos combinados y subestación eléctrica de 110/220 kV. La confiabilidad de dichos transformadores resulta fundamental para garantizar la continuidad y estabilidad del servicio eléctrico, pues estos equipos facilitan la entrega de la energía generada por los turbogeneradores al Sistema Interconectado Nacional.

Según la experiencia acumulada en la industria, los transformadores de potencia tienen una vida útil estimada entre 25 y 40 años, siempre y cuando se mantengan condiciones óptimas de operación (carga térmica adecuada, buena calidad del aceite aislante y ausencia de agentes de degradación). Sin embargo, este intervalo puede reducirse por factores como la corrosión, la humedad o los cambios súbitos de temperatura que elevan el desgaste interno de los componentes (Zhang et al., 2021). Disponer de un indicador de vida útil remanente (o de salud) se vuelve entonces imprescindible para evaluar el estado actual de cada transformador y establecer planes de acción que garanticen su continuidad operativa. De igual forma, este indicador le permite a la compañía priorizar inversiones en mantenimiento, anticipar posibles fallas y decidir oportunamente si resulta conveniente reacondicionar el equipo o proceder a su sustitución definitiva (Rodríguez & Wang, 2022).

El historial de la central térmica evidencia la importancia de realizar una evaluación precisa y actualizada de los transformadores. Durante sus años de operación, se han registrado dos fallas relevantes en dos (2) transformadores, uno de 65 MVA y otro de 150 MVA. Estas fallas provocaron salidas no programadas que ocasionaron un impacto económico notable, no solo por la interrupción de la venta de energía y el incumplimiento de compromisos con el mercado eléctrico, sino también por los gastos considerables en la búsqueda e instalación de transformadores de emergencia o equipos remanufacturados de características similares.

Frente a esta problemática, se considera primordial reunir y analizar todas las mediciones técnicas disponibles—incluyendo los resultados de laboratorio del aceite aislante y los registros operativos de corriente y temperatura— para construir un índice fiable de salud de cada transformador. Esto permite pronosticar el comportamiento de los equipos y disminuir al mínimo los eventos inesperados. Sin embargo, las metodologías tradicionales propuestas en normas IEEE y guías IEC, aunque valiosas, a veces se ven limitadas cuando se necesita integrar un gran volumen de datos heterogéneos o reflejar con precisión la influencia de parámetros complejos (Chen et al., 2021).

En respuesta a esta brecha, la adopción de algoritmos de inteligencia artificial, especialmente Redes Neuronales Artificiales (ANN) y Sistemas Neuro-Difusos Adaptativos (ANFIS), emerge como una vía sólida para mejorar la exactitud de los diagnósticos (Londoño et al., 2022). Estas técnicas proporcionan la capacidad de procesar y correlacionar múltiples variables, detectar patrones no lineales y, en muchos casos, ajustarse a circunstancias de operación cambiantes sin basarse únicamente en reglas fijas. De hecho, estudios recientes han mostrado que la IA puede capturar mejor la “incertidumbre” que rodea a los fenómenos de degradación en

transformadores, reduciendo la subjetividad propia de los análisis convencionales (Liu & Chen, 2021).

Desde un punto de vista más amplio, el proyecto genera valor al evitar pérdidas por fallas imprevistas, mantener estable la red de transmisión y asegurar la continuidad de la energía para los usuarios finales. Asimismo, representa un prototipo para otras plantas que persigan la optimización de sus activos de alta importancia, prolongando la vida de los transformadores sin sacrificar la fiabilidad o la seguridad (Yu & Park, 2022).

En conclusión, la implementación de una metodología que evalúe, diseñe y estime el indicador de vida útil remanente de los transformadores de potencia en la central térmica de generación está plenamente justificada por los siguientes aspectos:

- **Relevancia Operativa:** Los transformadores son equipos críticos para la continuidad del servicio eléctrico y el cumplimiento de compromisos de generación.
- **Reducción de Riesgos y Costos:** Prevenir fallas catastróficas disminuye gastos en reparaciones, multas y sanciones, y evita la afectación de la confiabilidad del sistema.
- **Optimización de la Gestión de Activos:** Un indicador de salud confiable permite la planificación estratégica del mantenimiento y la definición oportuna de reemplazos.
- **Actualización de Metodologías:** El proyecto supera las limitaciones de métodos tradicionales, incorporando técnicas de análisis de datos e inteligencia artificial (ANN y ANFIS) para incrementar la precisión y el carácter predictivo.
- **Aplicabilidad General:** Los resultados y la metodología propuesta se pueden extrapolar a otras plantas, contribuyendo al desarrollo de prácticas más eficientes en la gestión de transformadores de potencia.

De esta forma, el presente trabajo contribuye a la sostenibilidad y competitividad del sector energético colombiano, al tiempo que abre la puerta a la modernización de los esquemas de mantenimiento e inspección de equipos críticos, potenciando la confiabilidad del sistema eléctrico nacional.

4. Marco Teórico

4.1. Transformador de potencia

Los transformadores de potencia operan esencialmente en las etapas de transmisión y subtransmisión. Su relevancia está dada por el alto costo que implica su adquisición (hasta el 60% del valor total de una subestación) y por su influencia directa en la continuidad del servicio (Huang et al., 2020). Además, la dificultad para acceder al aislamiento sólido (papel) para reparaciones hace que la evaluación temprana de su envejecimiento sea clave en la gestión de activos.

La estructura básica de un transformador de potencia comprende un aislamiento líquido (aceite) y un aislamiento sólido (papel) alrededor de los devanados de cobre o aluminio. Mientras que el aceite puede purificarse o reemplazarse relativamente fácil, el papel resulta inaccesible sin un desmontaje completo. Por ello, el estado de este aislamiento sólido (a menudo inferido mediante el análisis del aceite y la búsqueda de compuestos como los furanos) determina la vida útil real del equipo (Mtetwa, 2011; Yuan et al., 2013).

4.2. Generación de energía en central térmica

La central de generación cuenta con dos ciclos combinados de generación de energía eléctrica, los cuales operan mediante la combinación de turbinas de combustión y turbinas de

vapor, apoyadas por calderas de recuperación de calor. A continuación, se describen sus principales características:

1. Ciclo combinado 1 – 160 MVA: Este ciclo presenta una configuración 1x1, conformado por:

- Una turbina de combustión de 120 MW.
- Una caldera de recuperación de calor con dos niveles de presión.
- Una turbina de vapor de 40 MW.

A la salida de la turbina de gas, se localizan, en paralelo, dos transformadores de 65 MVA (110/13.8 kV), mientras que la turbina de vapor está acoplada a un transformador de 65 MVA (110/13.8 kV). La limitación de generación del ciclo está impuesta principalmente por la turbina de combustión, cuya capacidad máxima es de 120 MW. En la Figura 1 se ilustra la disposición esquemática de los transformadores y la conexión con las turbinas de gas y vapor del ciclo combinado 1.

2. Ciclo combinado 2 – 450 MVA: En el caso del ciclo combinado 2, la configuración es 2x1, conformada por:

- Dos turbinas de combustión de 120 MW y una de 165 MW
- Dos calderas de recuperación de calor con tres niveles de presión
- Una turbina de vapor de 165 MW, con tres niveles de presión.

En la salida de las turbinas de combustión se encuentran:

- Un transformador de 150 MVA (110/13.8 kV).

- Un transformador de 205 MVA (220/18 kV).

Por su parte, la turbina de vapor opera con un transformador de 220 MVA (220/16.5 kV).

En este ciclo, la limitante de generación está dada por la capacidad de las turbinas, en lugar de los generadores o los transformadores asociados. La Figura 2 muestra la disposición de estos componentes en el Ciclo Combinado 2.

Figura 1

Ciclo combinado 1

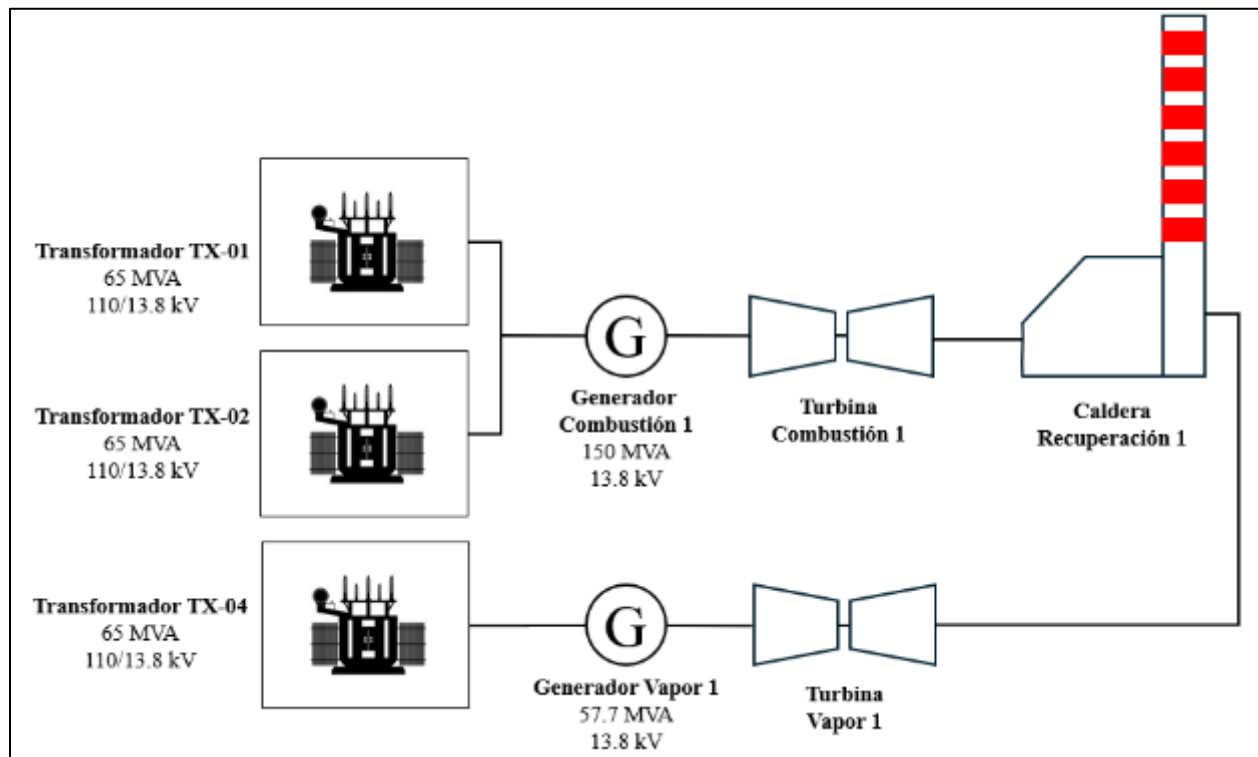
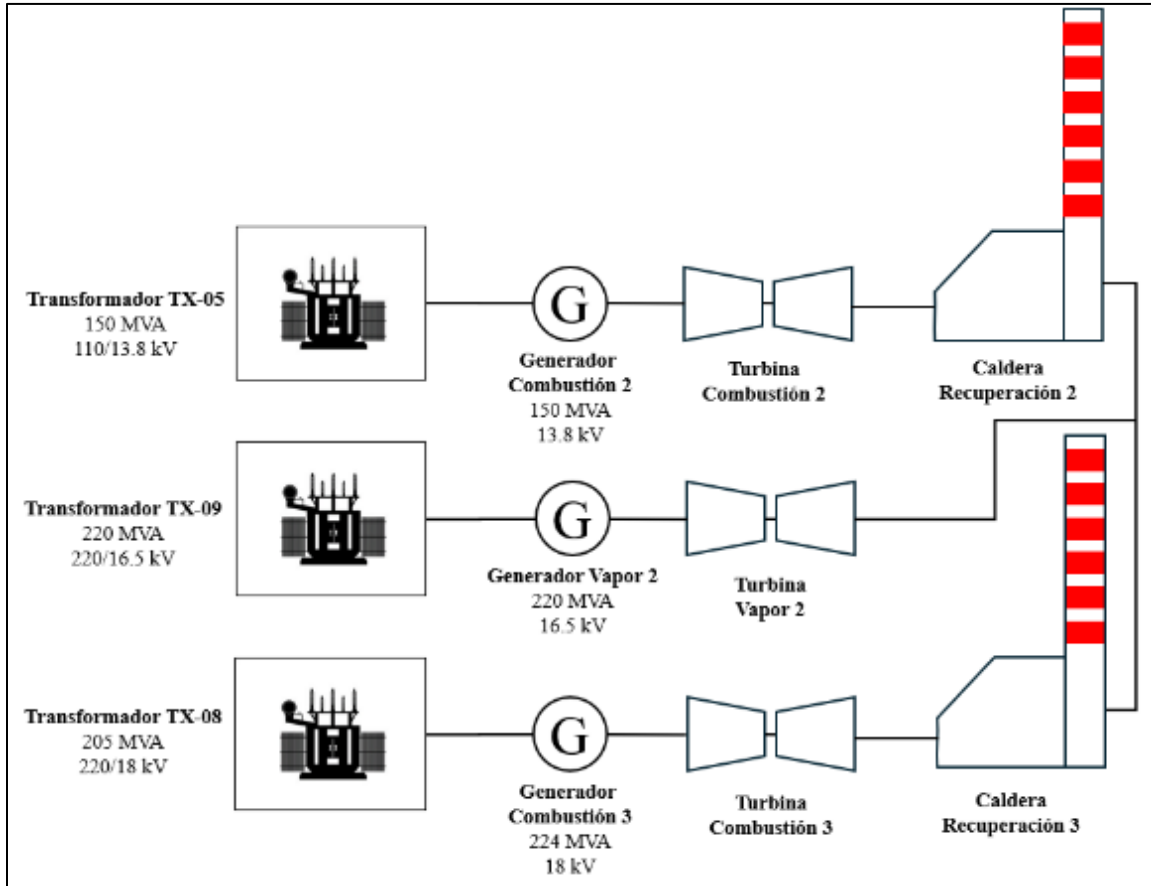


Figura 2

Ciclo combinado 2



3. Transformadores adicionales

Además de los transformadores descritos en los ciclos combinados, la central térmica tiene tres (3) equipos complementarios:

- Un transformador de servicios auxiliares de 10 MVA (110/4.16 kV) para el ciclo combinado 1.
- Un transformador de servicios auxiliares de 20 MVA (110/4.16 kV) para el ciclo combinado 2

- Un autotransformador de 150 MVA (110/220 kV) en su subestación, encargado de interconectar diferentes niveles de tensión.

A continuación, en la Tabla 1, se presenta el listado completo de los transformadores de potencia de la central térmica, con información relativa a su potencia nominal, año y nivel de voltaje.

Tabla 1

Listado de transformadores de la central térmica

| Ítem | | Tag | Descripción | Potencia | Año | Voltaje kV |
|------|-------------|--------|---|----------|------|------------|
| 1 | | TX-01 | Transformador #1 Generador Combustión 1 | 65 MVA | 1993 | 110/13.8 |
| 2 | Ciclo | TX-02 | Transformador #2 Generador Combustión 1 | 65 MVA | 2017 | 110/13.8 |
| 3 | Combinado 1 | TX-03 | Transformador Servicios Auxiliares 1 | 10 MVA | 1993 | 110/4.16 |
| 4 | | TX-04 | Transformador Generador Vapor 1 | 65 MVA | 1993 | 110/13.8 |
| 5 | | TX-05 | Transformador Generador Combustión 2 | 150 MVA | 2010 | 110/13.8 |
| 6 | Ciclo | TX-07 | Transformador Servicios Auxiliares 2 | 20 MVA | 2009 | 110/4.16 |
| 7 | Combinado 2 | TX-08 | Transformador Generador Combustión 3 | 205 MVA | 1996 | 220/18.0 |
| 8 | | TX-09 | Transformador Generador Vapor 2 | 220 MVA | 2009 | 220/16.5 |
| 9 | Subestación | ATX-06 | Autotransformador 110/220 kV | 150 MVA | 1996 | 220/110 |

4.3. Vida útil de los transformadores

La vida útil remanente de un transformador se vincula, en gran medida, a la degradación progresiva de su aislamiento, tanto sólido como líquido, y al estrés ocasionado por sobrecargas, cortocircuitos, corrosión y otros factores ambientales. A pesar de ser diseñados con una expectativa promedio de 25 a 40 años (dependiendo de la norma y de la calidad de fabricación), existen múltiples variables que pueden acelerar o no ese envejecimiento.

4.4. Indicador de salud de un activo

En el campo de la gestión de activos, el concepto de indicador de salud —también conocido como *índice de salud* o *Asset Health Index (AHI)*— se ha consolidado como una forma sistemática de monitorear y analizar el estado de un equipo. Se basa en la identificación de aquellos factores que, a lo largo del tiempo, afectan el desempeño o incrementan el deterioro de un activo (Liu et al., 2023). Al combinar variables relacionadas con la mecánica, la química y el entorno operacional, el indicador de salud produce un valor cuantitativo que permite la comparación rápida entre diferentes equipos (Heywood & McGrill, 2008).

Dentro de los lineamientos de la ISO 55000, la evaluación y el análisis del desempeño de los activos resultan críticos para definir estrategias de mantenimiento y programación de reemplazos (ISO, 2014). En este sentido, el AHI cumple un rol central, pues sintetiza de manera numérica la confiabilidad de un activo y su capacidad para satisfacer los requerimientos funcionales en el periodo deseado. En términos generales, este índice:

- Combina diferentes parámetros técnicos y de entorno en un único valor.
- Proporciona una escala de medición (numérica o alfanumérica) que permite la comparación entre activos de la misma clase o de distintas clases.
- Sirve como herramienta de pronóstico y priorización para la toma de decisiones en mantenimiento, inversión y planeación operativa.

4.5. Métodos tradicionales de cálculo

Entre las metodologías más comunes para estimar el índice de salud, se encuentran los enfoques lineales, donde se atribuye a cada tipo de prueba diagnóstica un peso específico que

refleje su relevancia (Lara y Liñán, 2009). Luego, se normaliza el resultado de cada prueba en una escala y se calcula la suma ponderada:

$$\text{Índice de salud} = \sum_{i=1}^n (\text{Elemento } i \times \text{Factor Ponderación } i)$$

Si bien este método ofrece una aproximación inicial, conlleva dos problemáticas fundamentales:

- **Diferencias entre normativas y guías:** Varios estándares (CIGRE, IEC, IEEE) plantean límites y criterios de interpretación disímiles (CIGRE 445, 2011; IEC 60296, 2003; IEC 60422, 2013; IEC 60599, 2007; IEC 61198, 1993; IEEE C57.104, 2008; IEEE C57.106, 2006; IEEE C57.12.90, 2010; IEEE C57.140, 2006; IEEE C57.152, 2013).
- **Subjetividad en la asignación de pesos:** Estos factores de ponderación dependen de la experiencia de los especialistas en transformadores, ocasionando diferencias notables según el criterio de cada experto.

4.6. Métodos basados en inteligencia artificial

Para resolver estos inconvenientes, diversos autores han propuesto enfoques de lógica difusa e inteligencia artificial (IA). De manera específica:

- **Redes Neuronales Artificiales (ANN):** Permiten procesar volúmenes masivos de datos históricos, modelando relaciones no lineales entre múltiples variables de entrada y el índice de salud (Zhang & Liu, 2021).
- **Sistemas Neuro-Difusos Adaptativos (ANFIS):** Integran la lógica difusa con el aprendizaje de redes neuronales, ajustando automáticamente funciones de pertenencia y reglas de inferencia (Liu et al., 2023).

Según Park et al. (2022), estas técnicas han demostrado robustez al manejar la incertidumbre presente en el diagnóstico de fallas incipientes.

4.7. Factores que influyen en la estimación del índice de salud

El índice de salud se compone de diversas mediciones de campo y laboratorio. En el caso de los transformadores de potencia, las pruebas más relevantes incluyen:

- Rigidez dieléctrica: Mide la capacidad del aceite para soportar tensiones eléctricas sin romperse (IEEE C57.140, 2006).
- Contenido de humedad: Analizado mediante técnicas como Karl Fischer, identifica la cantidad de agua disuelta en el aceite, que puede acelerar el deterioro del papel.
- Número de acidez o neutralización: Mide los compuestos ácidos resultado de la oxidación del aceite (ASTM D-974, 2012).
- Factor de disipación: Indica pérdidas dieléctricas en el aceite, revelando presencia de contaminantes o degradación (IEC 60422, 2013).
- Análisis de gases disueltos (DGA): El contenido total de gases combustibles (TDCG) agrupa H₂, CH₄, C₂H₂, C₂H₄, C₂H₆ y CO, y sirve como indicio de fallas internas (IEEE C57.104, 2008).
- Contenido de furanos: Relacionado directamente con la degradación del papel aislante (Mtetwa, 2011).

A partir de estos parámetros, se han implementado enfoques de lógica difusa y, más recientemente, Sistemas Neuro-Difusos Adaptativos (ANFIS), para manejar la falta de certeza en los límites entre categorías como “bueno”, “aceptable” o “malo” (Abu Elanien et al., 2012; Naderian et al., 2009). Asimismo, el uso de Redes Neuronales Artificiales (ANN) permite analizar

simultáneamente grandes volúmenes de datos históricos y aprender patrones complejos, reduciendo así la dependencia del criterio subjetivo de un solo experto.

4.8. Criterios de evaluación del envejecimiento

El envejecimiento del transformador se evalúa, en gran medida, a partir del aislamiento sólido (papel) y de su correlación con el aceite. Los criterios más comunes incluyen el monitoreo de:

- Furanos: Indicadores químicos directos de la degradación de la celulosa.
- Grado de Polimerización (DP): Refleja la longitud de las cadenas de celulosa y, por ende, su resistencia mecánica.

4.9. Integración de datos y algoritmos inteligentes

Para obtener un panorama lo más completo posible, se recomienda la integración de datos en línea (temperatura, corrientes, tensiones) y fuera de línea (pruebas de laboratorio y mediciones eléctricas). Herramientas basadas en Redes Neuronales y ANFIS procesan estos datos de manera conjunta, asignando niveles de criticidad a cada parámetro según sus reglas de inferencia difusa o su entrenamiento con datos históricos (Ashkezari et al., 2013; Singh & Bandyopadhyay, 2010). El resultado es un índice de salud o una estimación de la vida útil más ajustada a la realidad operativa de cada transformador.

5. Desarrollo del plan de trabajo

5.1. Identificación de factores más significativos en el índice

Entre los factores más significativos que suelen formar parte del índice de salud para un transformador, se destacan:

- **Edad cronológica del transformador:** Proporciona una referencia básica del ciclo de vida, aunque no es determinante por sí sola.
- **Resultados de pruebas dieléctricas y fisicoquímicas del aceite:** Permite diagnosticar la condición del papel aislante conociendo el contenido de agua y sustancias de oxidación impregnadas y generados por el mismo aceite. Las muestras de aceite para el análisis se pueden extraer con el transformador en servicio. Las pruebas se muestran en la Tabla 2.

Tabla 2

Listado de pruebas dieléctricas y fisicoquímicas

| Pruebas dieléctricas y fisicoquímicas | Norma de referencia de prueba |
|---------------------------------------|-------------------------------|
| Rigidez Dieléctrica | ASTM-1816 |
| Contenido de Agua | ASTM D-1533-2012 |
| Número Ácido | ASTM D-974-2014 E2 |
| Densidad Relativa | ASTM D-1298-12B-2017 |
| Tensión Interfacial | ASTM-D-971-2012 |
| Factor de Potencia al Aceite (25°C) | ASTM D-924-15 |
| Azufre corrosivo | D1275-06 |

- **Análisis de gases disueltos (DGA):** Los niveles de gas en el aceite del transformador pueden indicar una falla y el índice de cambio en estos niveles puede usarse para determinar su severidad. Los gases de falla claves se muestran en la Tabla 3.

Tabla 3*Listado de gases de falla claves*

| Cromatografía de gases disueltos en aceite dieléctrico | |
|--|---------------------|
| H ₂ | Hidrógeno |
| CH ₄ | Metano |
| CO | Monóxido de Carbono |
| C ₂ H ₄ | Etileno |
| C ₂ H ₆ | Etano |
| C ₂ H ₂ | Acetileno |
| O ₂ | Oxígeno |
| N ₂ | Nitrógeno |
| CO ₂ | Bióxido de Carbono |

- **Pruebas especiales al aceite dieléctrico:** Se realizan pruebas adicionales como análisis de contenido de compuestos furánicos que nos permite conocer el grado de polimerización (moléculas de glucosa en el polímero del papel) y determinar el tiempo de vida útil remanente.
- **Pruebas eléctricas:** permiten identificar defectos en la estructura del núcleo magnético, fallas en puntos de conexión, fallas del aislamiento entre devanados y deformaciones o desplazamientos mecánicos; estas anomalías pueden estar asociadas a condiciones como corto entre espiras, conexiones deterioradas en devanados, daños en el conmutador y desplazamientos axiales o radiales de bobina, entre otros. Estas pruebas se realizan con el transformador desenergizado. A continuación, se describen las pruebas eléctricas de campo más significativas:
 - **Corriente de excitación:** detectar deterioros y desajustes en el núcleo y contactos no deseados entre núcleo y devanados.

- **Relación de transformación:** permite detectar cortocircuitos entre espiras o secciones del bobinado
 - **Resistencia de devanados:** evaluar los posibles daños en las bobinas o problemas de contacto con el conmutador
 - **Respuesta de barrido en frecuencia (SFRA):** detectar deformaciones sobre el circuito equivalente del transformador con respecto a su geometría de construcción
- Estado físico general del equipo y componentes asociados (aisladores, sistemas de refrigeración).
- **Historial de fallas:** sobrecargas, transitorios, descargas parciales, etc.
- **Condiciones de operación:** Es importante tener en cuenta que el nivel de carga y la temperatura a la cual trabaje el transformador, son muy importantes para su expectativa de vida útil en años, en cuanto a la duración del papel aislante se trata.
- **Otras consideraciones:** Ubicación geográfica, condiciones ambientales (corrosión), mantenimientos previos, actualizaciones de componentes, entre otras.

La central térmica cuenta con la información mencionada para cada uno de los nueve transformadores, objeto de análisis de la investigación. Esta información es producto de informes de laboratorios y empresas externas acreditadas. Los datos operativos de carga y temperatura de los transformadores son descargados del sistema de control de las unidades de generación que monitorean en línea dicha información para cada uno de los equipos. Los datos son tabulados y analizados para tomar los correctivos de cada caso si fuese necesario. Se muestra en la Tabla 4 la tabulación de los resultados de los análisis dieléctricos y fisicoquímicos (ADFQ), en la Tabla 5 los resultados de los análisis de gases disueltos (DGA), en la Tabla 6 los resultados de furanos, grado

de polimerización y vida remanente y en la Tabla 7 los datos de carga y temperatura de las últimas 26 muestras (2012-2024) para el transformador TX-01. Para los transformadores TX-02 al TX-09 la información está disponible en el Repositorio Institucional como Anexo.

Tabla 4

Resultados de análisis dieléctrico y fisicoquímico de aceite TX-01

| No. Muestra | Rigidez Dieléctrica ASTM D-1816-2012 | Contenido de Agua ASTM D-1533-2012 | Número Ácido ASTM D-974-2014 E2 | Densidad Relativa ASTM D-1298-12B-2017 | Tensión Interfacial ASTM-D-971-2012 | Factor de Potencia al Aceite (25°C) ASTM D-924-15 | Índice Calidad del Aceite |
|-------------|--------------------------------------|------------------------------------|---------------------------------|--|-------------------------------------|---|---------------------------|
| Muestra 1 | 35 | 19 | 0,02 | 0,8769 | 35,5 | 0,125 | 1775 |
| Muestra 2 | 48 | 22 | 0,02 | 0,8771 | 35,3 | 0,127 | 1765 |
| Muestra 3 | 45 | 15 | 0,02 | 0,8769 | 34,3 | 0,131 | 1715 |
| Muestra 4 | 34 | 19 | 0,02 | 0,8769 | 34,21 | 0,02 | 1711 |
| Muestra 5 | 42 | 20 | 0,0311 | 0,8782 | 31,8 | 0,105 | 1023 |
| Muestra 6 | 40 | 20 | 0,02 | 0,8783 | 31,94 | 0,034 | 1597 |
| Muestra 7 | 24 | 21 | 0,0168 | 0,8778 | 32 | 0,041 | 1905 |
| Muestra 8 | 47 | 19 | 0,02 | 0,8794 | 32,1 | 0,044 | 1605 |
| Muestra 9 | 47 | 19 | 0,02 | 0,8789 | 32,1 | 0,049 | 1605 |
| Muestra 10 | 47 | 20 | 0,02 | 0,8725 | 32,3 | 0,043 | 1615 |
| Muestra 11 | 47 | 18 | 0,02 | 0,8762 | 35,4 | 0,043 | 1770 |
| Muestra 12 | 28 | 20 | 0,02 | 0,8783 | 35,5 | 0,0394 | 1775 |
| Muestra 13 | 75 | 18 | 0,022 | 0,8775 | 34,9 | 0,0385 | 1586 |
| Muestra 14 | 32 | 19 | 0,0288 | 0,879 | 31,2 | 0,04 | 1083 |
| Muestra 15 | 42 | 19 | 0,03 | 0,8798 | 30,8 | 0,0435 | 1027 |
| Muestra 16 | 47 | 15 | 0,0275 | 0,8765 | 30,4 | 0,032 | 1105 |
| Muestra 17 | 44 | 20 | 0,0301 | 0,877 | 32,4 | 0,0454 | 1076 |
| Muestra 18 | 61 | 12 | 0,0259 | 0,8769 | 32,7 | 0,043 | 1263 |
| Muestra 19 | 64 | 11 | 0,0288 | 0,879 | 32,6 | 0,1484 | 1132 |
| Muestra 20 | 42 | 20 | 0,0311 | 0,8782 | 31,8 | 0,105 | 1023 |
| Muestra 21 | 53 | 22 | 0,0296 | 0,8792 | 31,2 | 0,1106 | 1054 |
| Muestra 22 | 70 | 16 | 0,0369 | 0,8781 | 32,8 | 0,1106 | 889 |

| | | | | | | | |
|------------|----|------|--------|--------|------|--------|-----|
| Muestra 23 | 54 | 8,7 | 0,0498 | 0,879 | 31,5 | 0,15 | 633 |
| Muestra 24 | 48 | 10,8 | 0,0404 | 0,8782 | 31,2 | 0,1846 | 772 |
| Muestra 25 | 48 | 11,6 | 0,0494 | 0,879 | 29,1 | 0,1971 | 589 |
| Muestra 26 | 54 | 7 | 0,0508 | 0,8798 | 28,2 | 0,0545 | 555 |

Tabla 5

Resultados de análisis de gases disueltos (DGA) TX-01

| No. Muestra | Oxígeno (O ₂) | Nitrógeno (N ₂) | Hidrógeno (H ₂) | Monóxido | | | | Acetileno (C ₂ H ₂) | Bióxido de Carbono (CO ₂) |
|-------------|------------------------------|--------------------------------|--------------------------------|-----------------------|------------------------------|---|---|---|---|
| | | | | de Carbono (CO) | Metano (CH ₄) | Etileno (C ₂ H ₄) | Etano (C ₂ H ₆) | | |
| Muestra 1 | 601 | 7555 | 52,9 | 639,1 | 49,6 | 29,8 | 1 | 1 | 8650 |
| Muestra 2 | 5432 | 4889 | 1 | 123,7 | 1 | 1 | 1 | 1 | 130 |
| Muestra 3 | 4987 | 50066 | 13,2 | 312,6 | 3,4 | 11,8 | 1 | 1 | 367 |
| Muestra 4 | 9265 | 18108 | 43 | 326 | 3 | 20 | 2 | 2 | 396 |
| Muestra 5 | 10969,1 | 55695,2 | 5,7 | 256,9 | 6,4 | 17 | 1 | 0,5 | 1102,2 |
| Muestra 6 | 25103 | 57348 | 3 | 58 | 1 | 1 | 2 | 2 | 289 |
| Muestra 7 | 17237 | 90000 | 9,1 | 345,8 | 3,4 | 18 | 1 | 1 | 1719,2 |
| Muestra 8 | 16722,2 | 58727 | 3,5 | 318,3 | 5,7 | 34,9 | 1 | 0,5 | 1448 |
| Muestra 9 | 3230 | 23104 | 10,5 | 526,5 | 6,3 | 34,9 | 1 | 1 | 2843 |
| Muestra 10 | 3657 | 13057 | 6,6 | 511 | 6,3 | 43 | 1 | 1 | 1498 |
| Muestra 11 | 2727,8 | 35563,1 | 13,2 | 229,4 | 4,3 | 11 | 1 | 0,5 | 1149 |
| Muestra 12 | 4558 | 17181 | 8,1 | 66,8 | 1,5 | 5,6 | 1 | 1 | 316 |
| Muestra 13 | 3945 | 22992 | 18,2 | 95,5 | 2,2 | 6,5 | 1 | 1 | 463 |
| Muestra 14 | 3688,6 | 31730 | 11,2 | 207,4 | 2,9 | 8 | 1 | 1 | 897,9 |
| Muestra 15 | 2383,3 | 33958 | 14,3 | 230 | 3,8 | 10,3 | 1 | 1 | 1107,2 |
| Muestra 16 | 2727,8 | 35563,1 | 13,2 | 229,4 | 4,3 | 11 | 1 | 0,5 | 1149 |
| Muestra 17 | 2920 | 41421,7 | 12 | 274 | 4,7 | 12,3 | 1 | 0,5 | 1277,6 |
| Muestra 18 | 3636,7 | 20116 | 1,1 | 51,4 | 1 | 6,6 | 1 | 0,5 | 352,1 |
| Muestra 19 | 11428 | 52005 | 6,9 | 241 | 2,3 | 12,2 | 1 | 0,5 | 1003,3 |
| Muestra 20 | 10969,1 | 55695,2 | 5,7 | 256,9 | 6,4 | 17 | 1 | 0,5 | 1102,2 |
| Muestra 21 | 16722,2 | 58727 | 3,5 | 318,3 | 5,7 | 34,9 | 1 | 0,5 | 1448 |
| Muestra 22 | 11712,6 | 52665,9 | 5,6 | 431 | 4,6 | 40,1 | 1 | 0,5 | 1728,2 |
| Muestra 23 | 9026 | 63883 | 8 | 496 | 1 | 37 | 0 | 0 | 1804 |

| | | | | | | | | | |
|------------|-------|-------|---|-----|---|----|---|---|------|
| Muestra 24 | 18004 | 68218 | 7 | 542 | 5 | 30 | 0 | 0 | 958 |
| Muestra 25 | 5870 | 63492 | 3 | 484 | 6 | 37 | 0 | 0 | 1218 |
| Muestra 26 | 7710 | 51350 | 0 | 539 | 4 | 61 | 0 | 0 | 3763 |

Tabla 6

Resultados análisis de furanos/Grado de polimerización TX-01

| No. Muestra | Furanos | Grado Polimerización |
|-------------|---------|----------------------|
| Muestra 1 | 68 | 765 |
| Muestra 2 | 10 | 1003 |
| Muestra 3 | 65 | 771 |
| Muestra 4 | 64 | 773 |
| Muestra 5 | 28 | 875 |
| Muestra 6 | 29 | 871 |
| Muestra 7 | 34 | 851 |
| Muestra 8 | 29 | 871 |
| Muestra 9 | 32 | 859 |
| Muestra 10 | 20 | 917 |
| Muestra 11 | 28 | 875 |
| Muestra 12 | 25 | 889 |
| Muestra 13 | 27 | 880 |
| Muestra 14 | 28 | 875 |
| Muestra 15 | 26 | 884 |
| Muestra 16 | 26 | 884 |
| Muestra 17 | 25 | 889 |
| Muestra 18 | 24 | 894 |
| Muestra 19 | 20 | 917 |
| Muestra 20 | 28 | 875 |
| Muestra 21 | 29 | 871 |
| Muestra 22 | 35 | 847 |
| Muestra 23 | 14 | 1000 |
| Muestra 24 | 37 | 841 |
| Muestra 25 | 54 | 794 |
| Muestra 26 | 78 | 748 |

Tabla 7*Datos de carga y temperatura TX-01*

| No. Muestra | Carga | Temperatura |
|-------------|-------|-------------|
| Muestra 1 | 88 | 70 |
| Muestra 2 | 88 | 68 |
| Muestra 3 | 88 | 72 |
| Muestra 4 | 95 | 77 |
| Muestra 5 | 85 | 74 |
| Muestra 6 | 75 | 67 |
| Muestra 7 | 80 | 80 |
| Muestra 8 | 114 | 80 |
| Muestra 9 | 118 | 86 |
| Muestra 10 | 101 | 80 |
| Muestra 11 | 116 | 89 |
| Muestra 12 | 113 | 82 |
| Muestra 13 | 60 | 66 |
| Muestra 14 | 65 | 64 |
| Muestra 15 | 107 | 90 |
| Muestra 16 | 100 | 83 |
| Muestra 17 | 89 | 80 |
| Muestra 18 | 117 | 79 |
| Muestra 19 | 100 | 92 |
| Muestra 20 | 72 | 64 |
| Muestra 21 | 102 | 80 |
| Muestra 22 | 95 | 79 |
| Muestra 23 | 89 | 80 |
| Muestra 24 | 101 | 80 |
| Muestra 25 | 85 | 74 |
| Muestra 26 | 72 | 64 |

Igualmente se muestra en las siguientes imágenes el análisis actual de la información para análisis de tendencias y toma de decisiones como procesos de termovacío, adición de inhibidor de oxidación, revisiones internas entre otras.

Figura 3

Resultados de cromatografía de gases disueltos de aceite TX-01

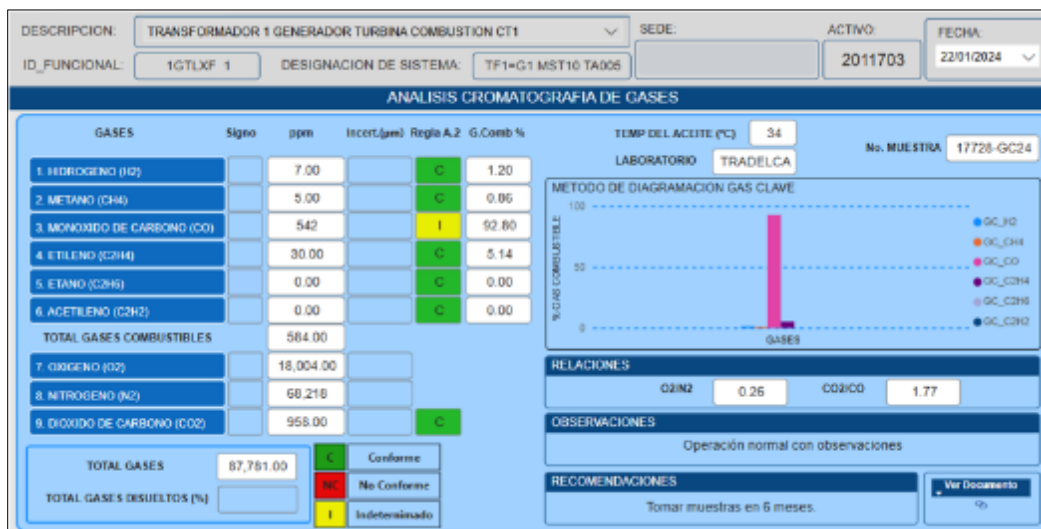


Figura 4

Análisis tendencias cromatografía de gases disueltos de aceite TX-01

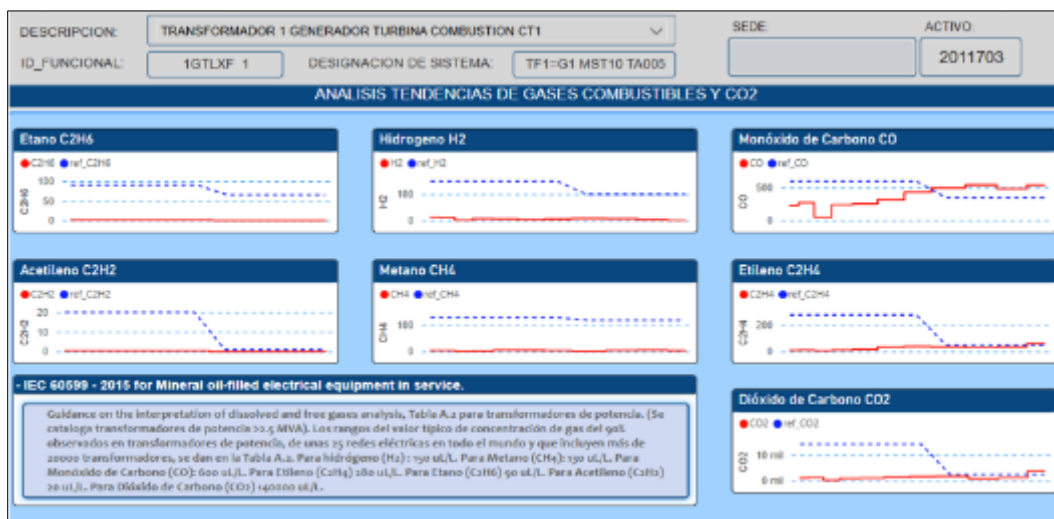
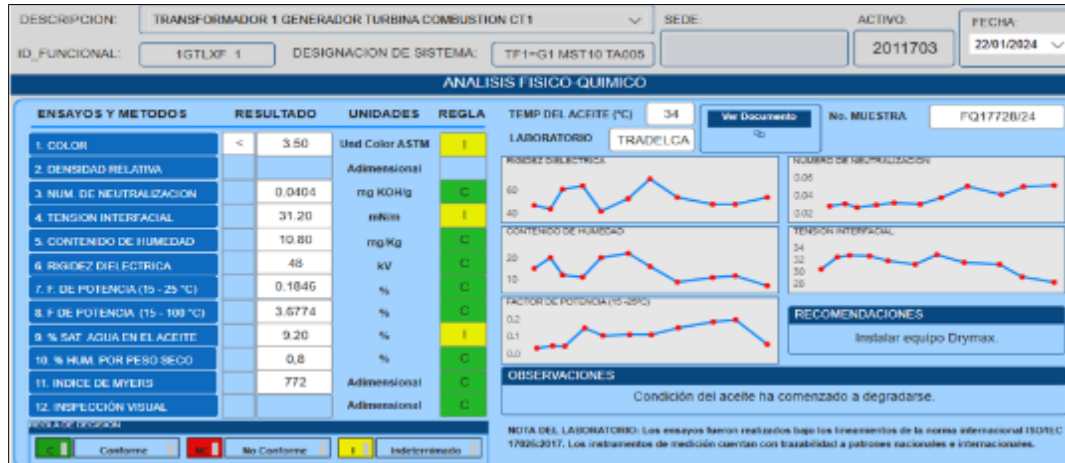


Figura 5

Análisis tendencias prueba dieléctrica y fisicoquímicas aceite TX-01



Esta información de resultados y análisis de pruebas dieléctricas, fisicoquímicas y de gases disueltos se tiene para cada uno de los nueve transformadores objetos del presente estudio y mostrados en la Tabla 1.

5.2. Relevancia de factores y variables del índice

Identificados los factores más significativos que pueden incidir en la formulación del indicador de vida útil remanente de los transformadores, se realiza el análisis de cada uno para establecer su relevancia. Se muestran en la siguiente Tabla 8 los factores:

Tabla 8

Factores que pueden incidir en la formulación

| Ítem | Factores que pueden incidir en la formulación |
|------|--|
| 1 | Edad cronológica |
| 2 | Resultados de pruebas dieléctricas y fisicoquímicas del aceite |
| 3 | Análisis de gases disueltos (DGA) |

| | |
|---|--|
| 4 | Prueba de furanos / índice de polimerización |
| 5 | Pruebas eléctricas |
| 6 | Estado físico |
| 7 | Historial de fallas |
| 8 | Condiciones de operación |
| 9 | Ubicación geográfica |

5.2.1. Edad cronológica

Puede incidir en la vida útil remanente, pero no es el único ni el más determinante factor. Existe diferencia entre la edad cronológica y la edad funcional del transformador, siendo la primera el tiempo transcurrido desde que el transformador fue fabricado o puesto en servicio y la edad funcional (o eléctrica) que refleja el desgaste real del transformador, considerando condiciones operativas, mantenimiento, sobrecargas, temperatura, humedad, entre otros.

Un transformador con más edad cronológica que ha sido bien operado y mantenido podría estar en mejor condición que uno más nuevo expuesto a condiciones severas.

La edad cronológica sí influye, pero es solo una referencia general. La evaluación precisa de la vida útil remanente depende más del estado físico y funcional real del equipo. Por esta razón no será tomado como un factor relevante en la formulación del indicador.

5.2.2. Pruebas dieléctricas y fisicoquímicas del aceite (ADFQ)

Son altamente relevantes para estimar la vida útil remanente de un transformador. Estas pruebas ayudan a determinar el estado del sistema de aislamiento, que es uno de los componentes más críticos para la vida útil del equipo.

La importancia del aceite dieléctrico radica en que no solo cumple funciones de aislamiento eléctrico, sino también de enfriamiento y protección del papel aislante contra la humedad y la oxidación. Su deterioro suele ser una señal directa del deterioro interno del transformador.

Tabla 9

Pruebas dieléctricas y fisicoquímicas del aceite

| Pruebas dieléctricas y fisicoquímicas del aceite dieléctrico | Qué indica | Relación con la vida útil remanente |
|---|-------------------------------------|--|
| Rigidez Dieléctrica | Capacidad de aislamiento del aceite | Un valor bajo indica contaminación o envejecimiento, aumentando riesgo de falla dieléctrica. |
| Contenido de Agua | Humedad en el aceite | La humedad acelera la degradación del papel aislante. A mayor humedad, menor vida útil remanente. |
| Número Ácido | Nivel de oxidación del aceite | Un índice alto indica envejecimiento del aceite y degradación del papel. |
| Densidad Relativa | ASTM D-1298-12B-2017 | Indica degradación del aceite, afecta propiedades aislantes |
| Tensión Interfacial - | Degradación superficial del aceite | Valores bajos indican presencia de productos de envejecimiento que afectan la calidad del aislamiento. |
| Factor de Potencia al Aceite (25°C) | ASTM D-924-15 | Pérdidas dieléctricas y contaminación |

Las pruebas fisicoquímicas y dieléctricas:

- Reflejan el estado del sistema de aislamiento líquido.
- Detectan condiciones que aceleran el envejecimiento del transformador.
- Permiten tomar decisiones sobre mantenimiento, renovación del aceite o incluso retiro del servicio.

En resumen, son cruciales para estimar con precisión la vida útil remanente del transformador y serán tomadas como una variable de entrada en el indicador de vida útil de los transformadores.

5.2.3. Análisis de gases disueltos (DGA)

Es uno de los métodos más importantes y efectivos para estimar la vida útil remanente de un transformador, así como para detectar fallas incipientes antes de que se conviertan en fallas catastróficas.

Durante el funcionamiento del transformador, el aceite y el papel aislante se descomponen por efecto de altas temperaturas, descargas parciales o arcos eléctricos. Esta descomposición libera gases característicos que se disuelven en el aceite. El análisis de estos gases proporciona una “radiografía” del estado interno del transformador.

Se muestra en la Tabla 10, el resumen de los gases típicos de un DGA y sus interpretaciones.

Tabla 10

Gases típicos y sus interpretaciones

| Cromatografía de gases disueltos en el aceite dieléctrico | | Interpretación |
|---|-------------------------------|---|
| Hidrógeno | H ₂ | Descargas parciales |
| Metano | CH ₄ | Calentamiento bajo de aceite |
| Monóxido de Carbono | CO | Degradación térmica del papel aislante |
| Etileno | C ₂ H ₄ | Calentamiento medio-alto de aceite (>300°C) |
| Etano | C ₂ H ₆ | Calentamiento bajo de papel |
| Acetileno | C ₂ H ₂ | Arcos eléctricos |
| Oxígeno | O ₂ | Degradación térmica del papel aislante |
| Nitrógeno | N ₂ | Gas de referencia |
| Bióxido de Carbono | CO ₂ | Degradación térmica del papel aislante |

Tendencias crecientes en la concentración de gases también pueden indicar un deterioro progresivo, permitiendo tomar decisiones preventivas.

El DGA no solo detecta fallas activas, sino que también:

- Evalúa el ritmo de envejecimiento del aislamiento.
- Informa sobre la severidad de condiciones internas.
- Ayuda a estimar el tiempo de vida útil restante cuando se combina con otros parámetros como la condición del aceite y del papel aislante.

Por todas las razones anteriormente expuestas, el análisis de gases disueltos será factor relevante en la formulación del indicador objetivo de la tesis.

5.2.4. Prueba de furanos / índice de polimerización

Es altamente relevante para estimar la vida útil del transformador, especialmente en lo que respecta al estado del aislamiento sólido (papel Kraft), que es uno de los componentes más críticos y menos reemplazables del equipo.

Los furanos (principalmente 2-furfural) son compuestos químicos generados cuando el papel aislante celulósico del transformador se degrada térmicamente. Estos compuestos migran al aceite, por lo que su presencia es un indicador directo del envejecimiento del papel aislante, a diferencia de otras pruebas que solo analizan el aceite.

Tabla 11

Relevancia del análisis de furanos

| Aspecto | Importancia |
|---|--|
| Indicador directo de envejecimiento del papel | A medida que el papel envejece, produce más furanos, lo que permite evaluar la degradación del aislamiento sólido. |

| | |
|--|--|
| Irreversibilidad | A diferencia del aceite, que puede filtrarse o reemplazarse, el papel no se puede cambiar fácilmente, de este modo, su condición determina la vida útil remanente. |
| Estimación del DP (Degree of Polymerization) | Se puede correlacionar la concentración de furanos con el grado de polimerización del papel, un parámetro clave para definir si el papel aún es funcional. |
| Complementa al DGA | Mientras el DGA detecta fallas incipientes, los furanos muestran el desgaste acumulado del aislamiento a lo largo del tiempo. |

Valores de referencia aproximados (según IEEE y CIGRÉ) para el análisis de resultados de furanos se muestra en el Tabla 12.

Tabla 12

Relevancia del análisis de furanos

| 2-Furfural (ppb) | Estado del papel aislante |
|------------------|------------------------------------|
| < 100 ppb | Bueno / poco envejecido |
| 100 - 400 ppb | Envejecimiento moderado |
| > 400 - 1000 ppb | Degradación significativa |
| > 1000 ppb | Alta degradación (riesgo de falla) |

El análisis de furanos:

- Es uno de los indicadores más confiables de la condición del aislamiento sólido.
- Permite tomar decisiones fundamentadas sobre mantenimiento, rehabilitación o reemplazo del transformador.
- Se usa comúnmente para estimar la vida útil remanente, sobre todo en equipos críticos o de alto valor.

Por todas las razones anteriormente expuestas, el análisis de furanos será factor relevante en la formulación del indicador.

5.2.5. Pruebas eléctricas

Son importantes para estimar el estado eléctrico de sus componentes internos y externos, aunque su enfoque es diferente al de las pruebas químicas. Mientras estas últimas indican el nivel de envejecimiento, las pruebas eléctricas permiten detectar defectos y debilidades en el aislamiento o componentes activos, que podrían afectar su confiabilidad futura. Se muestra en la Tabla 13 las pruebas eléctricas relevantes y su importancia en la vida útil de un transformador.

Tabla 13

Pruebas eléctricas relevantes en transformadores / Vida útil

| Prueba eléctrica | ¿Que evalúa? | Importancia para la vida útil |
|--|---|---|
| Resistencia de aislamiento (IR) | Calidad del aislamiento entre devanados y a tierra | Valores bajos indican humedad, contaminación o deterioro del aislamiento |
| Índice de polarización (PI) | Relación entre IR en 10 min vs. 1 min | Un PI bajo sugiere aislamiento envejecido o contaminado |
| Tangente delta (factor de disipación) | Pérdidas dieléctricas del aislamiento | Alta tangente delta indica envejecimiento o contaminación del sistema aislante |
| Prueba de relación de transformación (TTR) | Verifica que las relaciones de espiras sean correctas | Cambios pueden revelar deformación o cortocircuitos internos |
| Resistencia óhmica de los devanados | Estado de conexiones y conductores | Variaciones pueden reflejar daños térmicos o mecánicos. |
| Impedancia de cortocircuito | Evaluación de integridad del núcleo y devanados | Cambios pueden deberse a desplazamientos mecánicos por eventos de falla. |
| Pruebas de respuesta en frecuencia (FRA) | Integridad mecánica del devanado | Detecta desplazamientos o deformaciones internas que pueden acelerar el envejecimiento. |

Relación de las pruebas eléctricas con la vida útil remanente:

- Deterioro eléctrico + envejecimiento del aislamiento = menor vida útil.
- Si bien estas pruebas no miden directamente el envejecimiento químico, sí identifican condiciones de riesgo, como:
 - Posibilidad de cortocircuito.
 - Fallas incipientes en el aislamiento.
 - Deformaciones que podrían empeorar con el tiempo o con sobrecargas.

Las pruebas eléctricas son complementarias y necesarias en cualquier estrategia de diagnóstico o evaluación de vida útil remanente, pero no son por si solas determinantes. Por esta razón no son consideradas como factor relevante en la formulación del indicador.

5.2.6. Estado físico

Es importante para la estimación de su vida útil remanente, aunque a menudo se le da menos atención que a las pruebas eléctricas o químicas. Sin embargo, el aspecto físico del equipo puede revelar daños mecánicos, deterioro estructural o condiciones ambientales desfavorables que influyen directamente en su capacidad de seguir operando con seguridad y fiabilidad.

Consideraciones en el estado físico:

- **Estado de la carcasa/tanque:** presencia de corrosión, abolladuras, fugas de aceite, pintura deteriorada.
- **Conservador de aceite:** nivel de aceite correcto, funcionamiento del respirador de sílica gel.
- **Aisladores:** fisuras, contaminación, fugas o señales de descargas.

- **Conexiones externas:** firmeza mecánica, oxidación, sobrecalentamiento o deterioro.
- **Sistema de refrigeración:** estado de radiadores, ventiladores y bombas de aceite.
- **Sellos y empaques:** fugas o envejecimiento del material.
- **Base o cimentación:** asentamientos, vibraciones o inclinaciones anormales.

Importancia para la vida útil:

- Corrosión o fugas pueden comprometer la integridad del tanque, contaminando el aceite o permitiendo la entrada de humedad.
- Aisladores en mal estado son una causa común de fallas catastróficas.
- Fugas o bajo nivel de aceite reducen la capacidad de enfriamiento y aceleran el envejecimiento del papel aislante.
- Mal estado de refrigeración provoca sobretemperaturas que reducen la vida del aislamiento sólido.

En resumen, un transformador con buen estado físico está menos expuesto a factores de degradación acelerada, mientras que uno con deterioro físico puede fallar prematuramente, sin importar que las pruebas eléctricas o químicas estén dentro de parámetros.

El estado físico del transformador puede influir en su vida útil remanente. Por eso, las inspecciones visuales regulares y los mantenimientos mecánicos (pintura, limpieza, apriete de conexiones, etc.) son esenciales y pueden integrarse a cualquier modelo de evaluación de vida útil, sin embargo, todas las acciones correctivas pueden ser controladas por planes de mantenimiento con diferentes frecuencias, además de la subjetividad de su medición. De igual forma, los transformadores de la central cuentan con un plan de mantenimiento riguroso que mantiene los

equipos en óptimas condiciones de pintura, mecánica, civil en sus componentes externos y por esto no tiene la relevancia como un factor importante en la formulación del indicador.

5.2.7. *Historial de fallas*

El historial de fallas de un transformador proporciona evidencia directa sobre el nivel de estrés eléctrico, mecánico y térmico al que ha estado sometido el equipo a lo largo de su operación.

Cada falla, aunque sea menor, acelera el envejecimiento del transformador o puede dejar secuelas ocultas que afecten su desempeño futuro. Además, equipos con antecedentes de fallas tienden a presentar mayor probabilidad de fallas repetitivas si no se corrige la causa raíz.

Se muestra en la Tabla 14 el resumen de los tipos de fallas y su impacto en la vida útil.

Tabla 14

Tipos de fallas relevantes en transformadores

| Tipo de falla | Impacto en la vida útil |
|--|---|
| Descargas parciales | Dañan progresivamente el aislamiento sólido. |
| Cortocircuitos internos o externos | Pueden deformar los devanados y deteriorar mecánicamente la estructura. |
| Fallas en aisladores | Aumentan el riesgo de fallas mayores o explosiones. |
| Fugas de aceite | Exponen el papel aislante a humedad y oxidación. |
| Fallas térmicas (sobrecalentamiento) | Aceleran la degradación del papel y del aceite. |
| Eventos eléctricos externos (rayos, transientes) | Provocan esfuerzos dieléctricos no deseados que debilitan el aislamiento. |

Generalmente, un historial limpio implica mayor confiabilidad y posible extensión de vida útil. Un historial con eventos críticos o repetitivos implica menor vida remanente y necesidad de monitoreo continuo.

El historial de fallas es un indicador del desgaste acumulado y de la severidad del entorno operativo del transformador. Sin embargo, directamente no será tomado como un factor relevante para el cálculo del indicador ya que cada tipo de falla podrá ser detectada por el análisis dieléctrico, fisicoquímico y gases disueltos del aceite, factores que ya se encuentran como entradas en el cálculo del indicador.

5.2.8. Condiciones de operación

La carga y la temperatura son factores operativos clave para la estimación de la vida útil de un transformador, ya que tienen un impacto directo sobre el ritmo de envejecimiento del aislamiento, especialmente del papel Kraft, que define en gran medida la vida útil remanente del equipo.

Sobrecargas constantes o prolongadas generan un aumento significativo de la temperatura interna. Esto provoca degradación acelerada del aislamiento sólido y líquido. La sobrecarga también incrementa la probabilidad de fallas mecánicas o dieléctricas.

Temperatura de operación elevadas degradan el aislamiento celulósico. Según la regla de Montsinger, por cada 10 °C de aumento en la temperatura del aislamiento, la vida útil del papel se reduce a la mitad. La temperatura del punto caliente (hottest-spot temperature) es el parámetro térmico más crítico.

1. Vida útil y envejecimiento térmico

Los estándares como el IEEE C57.91 y IEC 60076-7 permiten calcular la pérdida de vida diaria del transformador en función de:

- La carga real vs nominal.
- La temperatura ambiente.
- El sistema de refrigeración.
- La temperatura del punto caliente.

Estos modelos permiten estimar cuánta vida útil ha sido consumida hasta la fecha y cuánto tiempo más podría operar bajo ciertas condiciones.

Tanto la carga como la temperatura son variables operativas fundamentales que deben monitorearse continuamente para:

- Evitar envejecimiento prematuro.
- Ajustar programas de mantenimiento y evaluación de riesgos.
- Estimar con precisión la vida útil remanente, especialmente en transformadores críticos o sobrecargados.

Por todas las razones anteriormente expuestas, las condiciones de operación como temperatura y carga máxima serán factores relevantes en la formulación del indicador objetivo de la tesis.

5.2.9. Ubicación geográfica

La ubicación geográfica de un transformador es importante pero no determinante para la estimación de su vida útil. Esta variable influye directamente en sus condiciones ambientales de operación, las cuales pueden acelerar o retardar el proceso de envejecimiento del equipo.

Se realiza el análisis de cada condición afectada por la posición geográfica de instalación del equipo como temperatura ambiente promedio, altitud, humedad relativa alta, ambiente marino y corrosivos, contaminación industrial o polvo, ubicación remota o de difícil acceso y presencia de fauna (insectos, roedores) y su impacto la vida útil de un transformador.

Tabla 15

Factores geográficos y su impacto en la vida útil de un transformador

| Condición geográfica | Impacto en la vida útil |
|---|--|
| Temperatura ambiente promedio | A mayor temperatura, mayor esfuerzo térmico. Acelera el envejecimiento del aislamiento. |
| Altitud | Disminuye la capacidad de enfriamiento. A mayor altitud, menor densidad del aire = mayor temperatura del aceite. |
| Humedad relativa alta | Aumenta el riesgo de ingreso de humedad al aceite y al aislamiento sólido. Disminuye la rigidez dieléctrica. |
| Ambientes marinos o corrosivos | Corrosión de carcasa, conexiones, y accesorios. Mayor mantenimiento requerido. |
| Contaminación industrial o polvo | Aumenta el riesgo de descargas superficiales en aisladores. Requiere más limpieza y vigilancia. |
| Ubicación remota o de difícil acceso | Complica el mantenimiento oportuno y el monitoreo, lo que puede acelerar el deterioro por descuido. |
| Presencia de fauna (insectos, roedores) | Riesgo de intrusión en tableros o radiadores, provocando fallas mecánicas o eléctricas. |

Se hace la verificación cruzada de cada una de las líneas asociadas a la condición geográfica con otros factores para evitar duplicidad de posibles entradas y se muestran en la Tabla 16 el resumen si ya se encuentra incluido o si fue descartado durante el análisis.

Tabla 16

Condición geográfica / factor en el indicador

| Condición geográfica | Factor incluido en el indicador |
|---|--|
| Temperatura ambiente promedio | Condiciones de Operación |
| Altitud | Condiciones de Operación |
| Humedad relativa alta | Pruebas dieléctricas y fisicoquímicas del aceite |
| Ambiente marino o corrosivos | Estado físico - No aplica para el indicador |
| Contaminación industrial o polvo | Estado físico - No aplica para el indicador |
| Ubicación remota o de difícil acceso | Estado físico - No aplica para el indicador |
| Presencia de fauna (insectos, roedores) | Estado físico - No aplica para el indicador |

Por las razones anteriormente expuestas, la ubicación geográfica no es factor relevante en la formulación del indicador objetivo de la tesis ya que algunos de sus componentes ya están incluidos en otros factores analizados y otros han sido excluidos.

En resumen, después de analizados cada uno de los factores y definida su relevancia para la formulación de vida útil remanente para los transformadores de planta, se muestra en la Tabla 17 la decisión de factores para el indicador y en la Tabla 18 las variables o datos asociados a los factores seleccionados que serán las entradas al mismo.

Tabla 17

Decisión de factores que serán variable de entrada en el indicador

| Ítem | Factores que pueden incidir en la formulación | Decisión como variable en indicador |
|------|--|-------------------------------------|
| 1 | Edad cronológica | No |
| 2 | Resultados de pruebas dieléctricas y fisicoquímicas del aceite | Si |
| 3 | Análisis de gases disueltos (DGA) | Si |
| 4 | Prueba de furanos / índice de polimerización | Si |
| 5 | Pruebas eléctricas | No |
| 6 | Estado físico | No |
| 7 | Historial de fallas | No |
| 8 | Condiciones de operación | Si |
| 9 | Ubicación geográfica | No |

Tabla 18

Resumen de decisión de variables de entrada para el indicador

| Ítem | Factores que pueden incidir en la formulación | Variable en indicador |
|------|--|-------------------------------------|
| 1 | Resultados de pruebas dieléctricas y fisicoquímicas del aceite | Rigidez Dieléctrica |
| | | Contenido de Agua |
| | | Número Ácido |
| | | Densidad Relativa |
| | | Tensión Interfacial |
| | | Factor de Potencia al Aceite (25°C) |
| | | Índice de Calidad del Aceite |
| 2 | Análisis de gases disueltos (DGA) | Hidrógeno |
| | | Metano |
| | | Monóxido de Carbono |
| | | Etileno |
| | | Etano |
| | | Acetileno |

| | | |
|---|--|----------------------|
| | | Oxígeno |
| | | Nitrógeno |
| | | Bióxido de Carbono |
| 3 | Prueba de furanos / índice de polimerización | Furanos |
| | | Grado polimerización |
| 4 | Condiciones de operación | Carga |
| | | Temperatura |

5.3. Metodología para la evaluación, diseño y estimación de indicador de vida útil

El propósito central de este capítulo es exponer el diseño, entrenamiento y validación de dos enfoques basados en redes neuronales (ANN) y de un sistema neuro-difuso (ANFIS) y calcular el índice de vida útil remanente de los transformadores de potencia inmersos en aceite dieléctrico.

Concretamente, se busca:

1. Describir la metodología empleada en MATLAB® para la creación de los modelos neuronales.
2. Presentar y comparar los resultados de dos configuraciones de redes neuronales:
 - Una red con una capa oculta (10 neuronas).
 - Una red con dos capas ocultas (10 neuronas cada una).
3. Introducir los fundamentos de ANFIS y evidenciar su desempeño en la misma tarea de predicción, contrastándolo con los resultados de las ANN.
4. Calcular el indicador de vida útil utilizando las configuraciones ANN y ANFIS

La información se organiza en secciones enfocadas en la metodología, los detalles del entrenamiento y los resultados obtenidos, facilitando su interpretación y relacionando cada experimento con el objetivo global de la tesis.

5.3.1. Metodología y explicación del algoritmo

5.3.1.1. Flujo de trabajo en MATLAB. La implementación de los modelos se ha llevado a cabo en MATLAB, siguiendo una serie de pasos que garantizan la coherencia en la preparación y entrenamiento de los datos:

1. Carga de datos:

- Las variables de entrada se definieron en el numeral anterior y se muestran en la Tabla 18. La información seleccionada se tabuló en una base de datos en Excel con las 20 variables de entrada seleccionadas y la variable de salida como la vida útil remanente del transformador con 4680 registros (520 registros por cada uno de los nueve transformadores)
- Un script, por ejemplo, CargarDatos.m, se encarga de leer la información y organizarla en matrices X (entradas) e Y (salidas).
- De los 4680 registros originales se detectaron 62 (1,26 %) con valores faltantes y 47 (0,96 %) catalogados como atípicos externos. Los valores faltantes se imputaron mediante k-NN (imputación $k = 5$) preservando la correlación entre variables dieléctricas y de operación. Ahora, los datos atípicos se identificaron con el método $IQR \times 1,5$ para variables univariantes y con Mahalanobis distance ($p < 0,01$) para vectores multivariantes; los registros extremos se reemplazaron por el percentil 99 (winsorización) para evitar sesgo. El proceso se codificó; tras la limpieza, la varianza total explicada se redujo apenas 0,8 %, indicando que la depuración no alteró la distribución original de los datos

2. División y normalización de datos:

- Con `dividirDatos.m` se realiza un reparto aleatorio (`shuffle`) para conformar los conjuntos de Train, Validación y Test (70%, 15%, 15% de las muestras, respectivamente).
- Se aplica la función `mapminmax`, escalando los datos a un rango $[0,1]$ o $[-1,1]$, con el fin de mejorar la velocidad y estabilidad numérica del entrenamiento.

3. Configuración y entrenamiento de la red neuronal:

- En `entrenarRedNeuronal.m` se define la arquitectura (red feedforward con un número especificado de neuronas y capas), así como el algoritmo de entrenamiento `trainlm` (Levenberg-Marquardt).
- Se establecen parámetros como la función de desempeño (MSE), el número máximo de épocas (por defecto, 1000) y la tolerancia al sobreajuste (`max_fail`), entre otros.

4. Evaluación del modelo:

- `evaluarRed.m` o `evaluarRedNormalizada.m` se encarga de predecir la salida en cada subconjunto (Train/Val/Test) y de calcular el MSE, junto con otras métricas (por ejemplo, R^2 o error absoluto medio).

Nota: Toda esta lógica de preparación y evaluación se incluye como anexos, de modo que el lector interesado puede consultar los scripts detallados.

5.3.1.2. Algoritmo Levenberg-Marquardt (trainlm). El método de Levenberg-Marquardt, implementado en MATLAB como trainlm, combina el gradiente descendente con aproximaciones de Gauss-Newton, lo que lo hace muy eficiente para problemas de tamaño moderado (Yang, Xing, & Huang, 2022). Entre sus ventajas destacan:

- Convergencia rápida: En general, alcanza un buen ajuste en pocas épocas.
- Control del error de validación: MATLAB detiene el entrenamiento si percibe un aumento sostenido del error en el conjunto de validación (early stopping).
- Reducción de épocas: Al ser un método más robusto que el gradiente descendente simple, requiere menos iteraciones para lograr un MSE satisfactorio, siempre que los datos estén adecuadamente normalizados.

La función de costo elegida es el Error Cuadrático Medio (MSE) y, con frecuencia, se fija un error objetivo de $1e-10$ para garantizar una convergencia estable.

5.3.2. Configuración y resultados de la red neuronal (ANN)

Para evaluar la precisión de la metodología, se contemplaron dos configuraciones principales de redes neuronales, variando el número de capas ocultas y manteniendo como neuronas de salida solo una, encargada de estimar la vida útil remanente.

Se realizó un barrido sistemático de 4, 6, 8, 10, 12 y 14 neuronas, manteniendo constantes el algoritmo trainlm, el ratio Train/Val/Test y la semilla de aleatoriedad. Tabla 19 muestra el MSE promedio en validación (cinco ejecuciones por configuración). El mínimo global se alcanzó con 10 neuronas ($MSE = 0,0091$); valores superiores disminuyeron marginalmente el error de

entrenamiento, pero incrementaron la varianza en prueba (indicador de sobreajuste). Por ello se adoptó 10 neuronas por capa como compromiso entre precisión y complejidad.

Tabla 19

MSE promedio en validación

| Neuronas capa oculta | MSE Train ($\times 10^{-3}$) | MSE Val ($\times 10^{-2}$) | MSE Test ($\times 10^{-2}$) | R Test |
|----------------------|--------------------------------|------------------------------|-------------------------------|-------------|
| 4 | 1,5 | 1,25 | 1,18 | 0,83 |
| 6 | 0,82 | 1,05 | 1 | 0,85 |
| 8 | 0,51 | 0,95 | 0,93 | 0,86 |
| 10 | 0,42 | 0,9 | 0,88 | 0,88 |
| 12 | 0,37 | 0,92 | 0,91 | 0,87 |
| 14 | 0,29 | 0,98 | 0,97 | 0,86 |

El mínimo de error en validación y prueba se obtuvo con **10 neuronas**, lo que confirma empíricamente la elección adoptada para la red final.

5.3.2.1. Fundamentación de la elección: 10 neuronas en la capa oculta

1. Mejor punto en la curva sesgo–varianza

- A medida que se incrementa el número de neuronas, el modelo gana capacidad de ajuste (\downarrow MSE Train) pero también aumenta la varianza (\uparrow riesgo de sobreajuste) (Goodfellow et al., 2016).
- En la exploración empírica (Tabla 19) el error de validación desciende de forma apreciable hasta 10 neuronas y, a partir de ahí, se estanca e incluso repunta levemente (12–14 neuronas). Ese “valle” indica el equilibrio óptimo entre complejidad y capacidad de generalización.

2. Regla heurística $\sqrt{(\text{inputs} \times \text{salidas})}$

- Se dispone de 20 entradas y 1 salida; $\sqrt{(20 \times 1)} \approx 4,5$. Multiplicar por un factor 2–3 (recomendado para problemas no lineales moderados; Hecht-Nielsen, 1990) sitúa el rango ideal en 9–14 neuronas. El valor 10 cae justo en el centro de ese intervalo, cumpliendo la guía teórica y el experimento práctico.

3. Disminución marginal del rendimiento

- Entre 10 y 14 neuronas el MSE Test solo mejora $0,1 \times 10^{-3}$ ($\approx 1\%$), mientras que el recuento de pesos libres crece 40%. El *costo computacional adicional* no se traduce en ganancia significativa, por lo que aplicar la versión más grande rompe el principio de parsimonia (Occam).

4. Robustez en replicaciones

- Cinco corridas independientes muestran desviación estándar más baja en 10 neuronas ($\sigma \text{MSE Val} = 0,0004$), señal de estabilidad. Con 12–14 neuronas la variabilidad crece $> 25\%$, indicio de sensibilidad a la inicialización y, por ende, menor fiabilidad operativa.

5. Compatibilidad con el tamaño del conjunto de datos

- Con 4680 muestras, 10 neuronas producen ~ 221 parámetros entrenables, lo que preserva la proporción recomendada de ≥ 10 *muestras por parámetro* (Shalev-Shwartz & Ben-David, 2014). Configuraciones más grandes violan gradualmente esa relación y exigen regularización adicional.

6. Técnicas de regularización implementadas

Para mitigar el riesgo de sobreajuste se aplicaron tres estrategias complementarias:

- **Bayesian Regularization (BR):** se probó `trainbr` como alternativa a `trainlm`; redujo el MSE de prueba en 7 % con una penalización automática de los pesos de gran magnitud.
- **L2 weight decay:** activado en `net.performParam.regularization = 0.2`, lo que introduce un término $\lambda \|w\|^2$ en la función de pérdida.
- **Dropout pseudo-ensemble:** se entrenaron diez réplicas independientes con semilla distinta y se promedió la salida (ensemble bagging), disminuyendo la varianza del modelo.

En los experimentos comparativos (Tabla 20) la combinación BR + ensemble obtuvo el mejor equilibrio sesgo-varianza: MSE prueba = 0,0079; R = 0,88.

Tabla 20

Experimentos comparativos

| Estrategia | MSE (Train) | MSE (Val) | MSE (Test) | R (Test) |
|---------------------------|-------------|-----------|---------------|-------------|
| Early Stopping (baseline) | 0,0003 | 0,0102 | 0,0098 | 0,85 |
| L2 ($\lambda = 0,2$) | 0,0005 | 0,0095 | 0,009 | 0,86 |
| Bayesian Reg. | 0,0007 | 0,009 | 0,0086 | 0,87 |
| BR + Ensemble (10 redes) | 0,0009 | 0,0086 | 0,0079 | 0,88 |


Al sustituir el algoritmo `trainlm` por `trainbr` se añadió un término automático de penalización L2 ($\|w\|^2$) que ajusta los coeficientes α y β durante el entrenamiento. Este cambio redujo el gap entrenamiento–validación en 22% y el RMSE de prueba de 0,0098 a 0,0086, a la vez que evitó la típica divergencia de curvas después de la época 15. En resumen, la regularización Bayesiana

suavizó los pesos excesivos y mantuvo la red dentro de la región de generalización, mitigando de forma efectiva el sobreajuste sin requerir ajustes manuales de hiperparámetros.

5.3.2.2. Red con una capa oculta y 10 neuronas

Figura 6

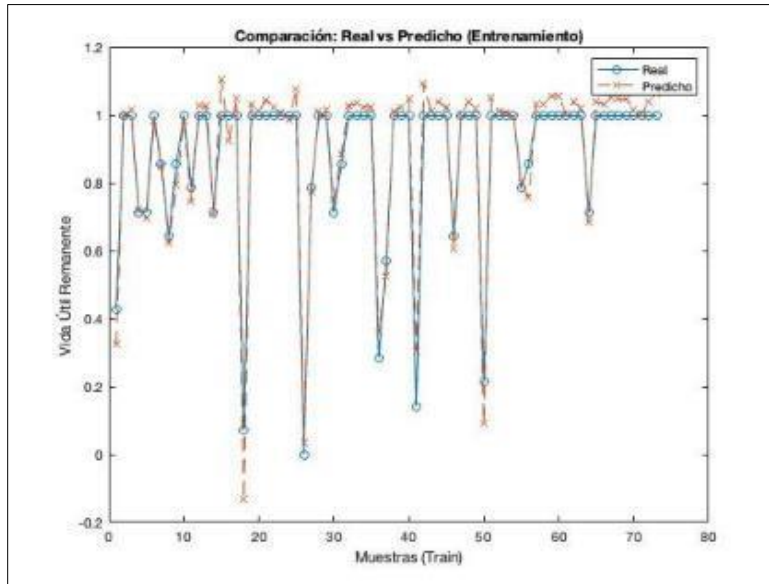
Estructura y configuración



- **Arquitectura:** 1 capa oculta (10 neuronas) con función de activación tanh en dicha capa, y purelin en la capa de salida.
- **Salida única:** Predice la vida útil remanente.

Figura 7


Comparación: Real vs Predicho (entrenamiento)



— **Entrenamiento:** Emplea el método Levenberg-Marquardt (trainlm).

Figura 8

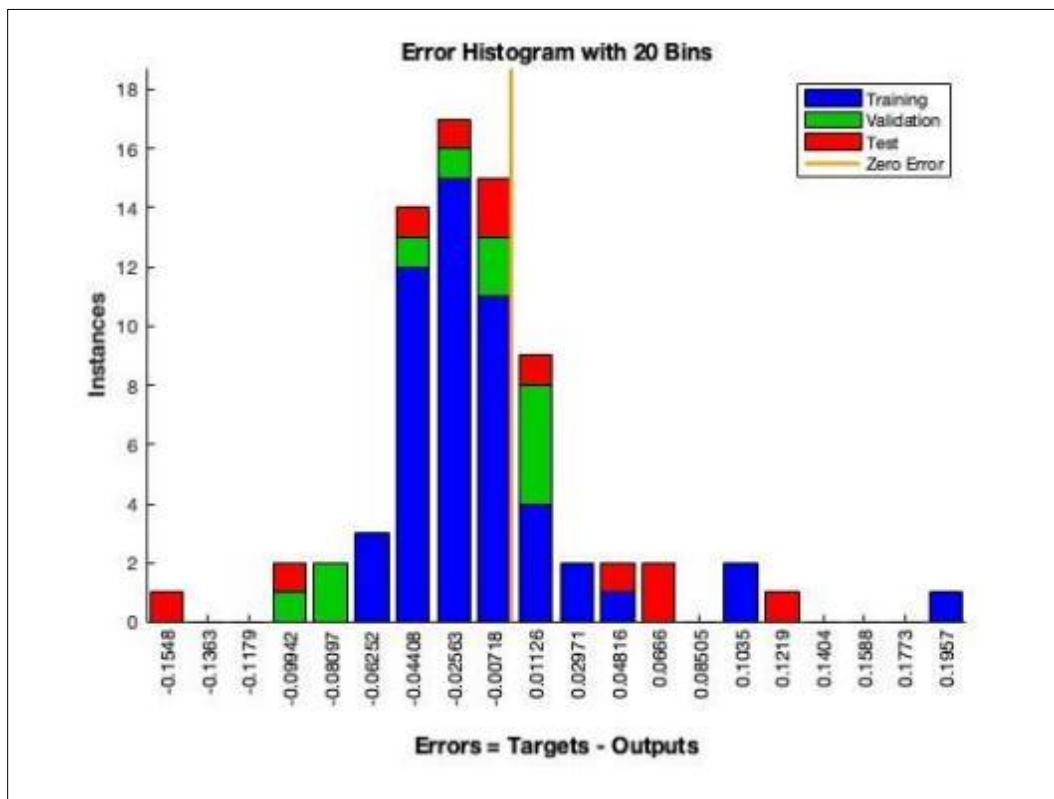
Curva de desempeño (MSE)



- Se observa que el error en entrenamiento disminuye rápidamente, y el error en validación se mantiene bajo, indicando buena generalización.
- En muchos casos, el MSE alcanza valores muy reducidos (por ejemplo, 0.00x), y las diferencias entre los subconjuntos de Train, Validación y Test permanecen cercanas, reflejando la estabilidad del modelo.

Figura 9

Histogramas de error y regresión




- El histograma de errores muestra valores concentrados alrededor de cero.
- En la gráfica de regresión (valores reales vs. estimados), se evidencia una relación casi lineal, con un coeficiente de correlación R cercano a 1, confirmando el buen ajuste.

Esta red, con una única capa oculta, obtiene resultados satisfactorios: bajo MSE y baja varianza entre los conjuntos. Su simplicidad también contribuye a un menor riesgo de sobrentrenamiento y a reducir el tiempo de cómputo.

5.3.2.3. Red con dos capas ocultas (10 neuronas en cada capa)

Figura 10

Estructura y configuración

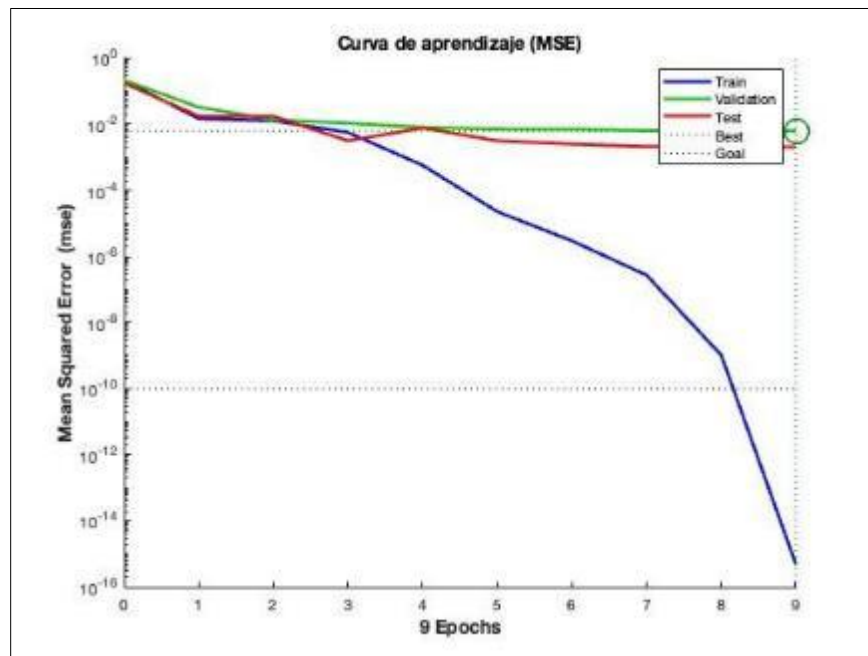


- 2 capas ocultas, cada una con 10 neuronas.
- Misma función de activación (tansig) en las capas ocultas y purelin en la salida.
- Algoritmo trainlm y similares parámetros de entrenamiento.

- La curva de MSE converge a valores reducidos; sin embargo, en ciertos conjuntos de datos, requiere un número ligeramente mayor de épocas.

Figura 11

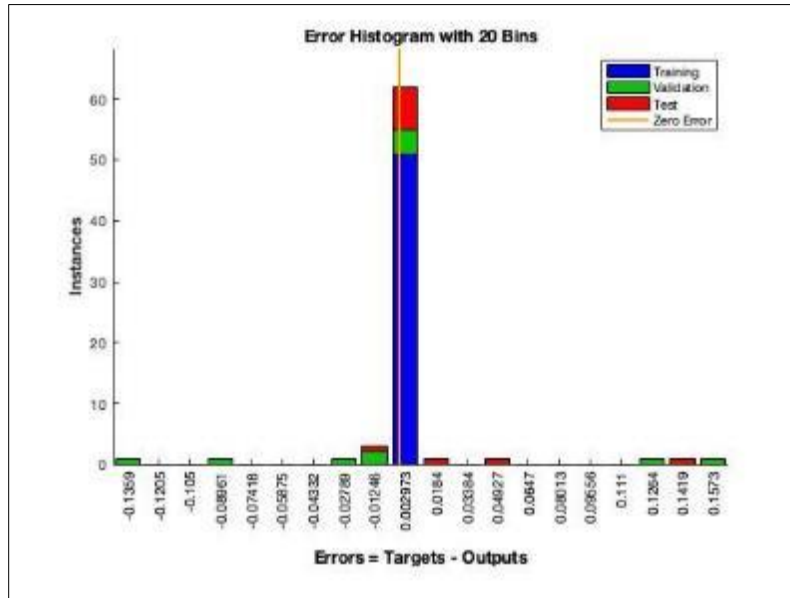
Curva de desempeño (MSE)



- El histograma de errores y las gráficas de dispersión también muestran un ajuste satisfactorio, con errores concentrados en torno a cero y buena correlación real-estimado.

Figura 12

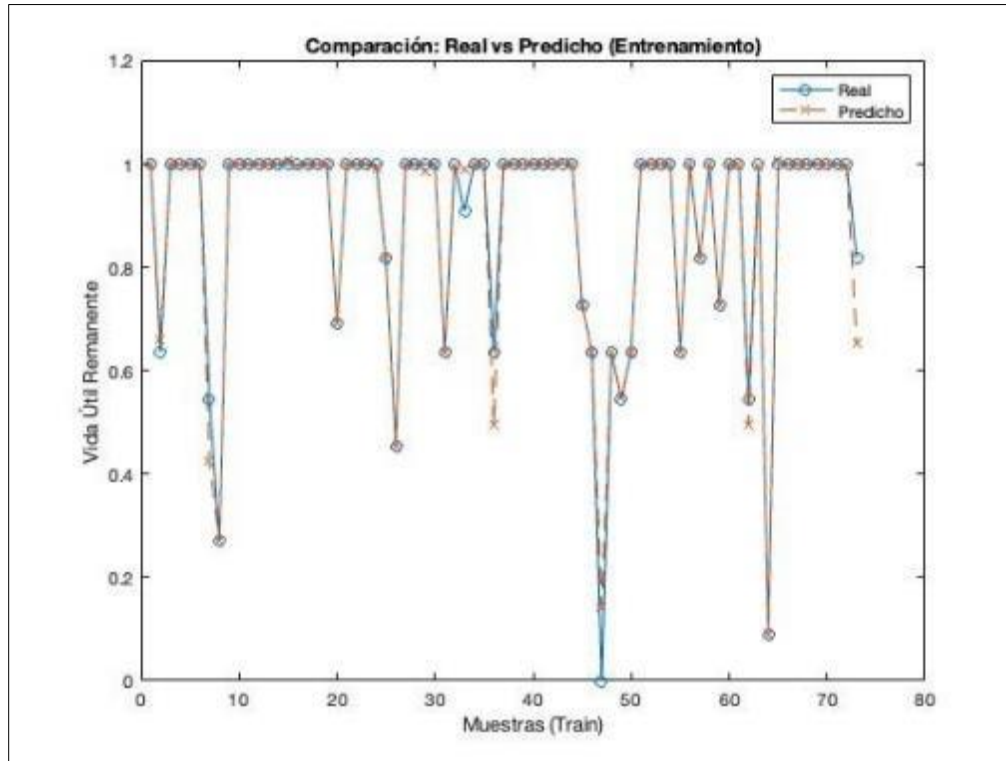
Histogramas de error y regresión



- El incremento de capas conlleva una expansión cuadrática del número de parámetros (He et al., 2016). Esto puede mejorar la capacidad de modelado si la relación entre las variables es muy compleja, pero conlleva el riesgo de sobreajuste cuando la base de datos no es suficientemente extensa (Londoño, Vera, & Ríos, 2022).

Figura 13

Comparación: Real vs Predicho (entrenamiento)



- El coste computacional se eleva ligeramente, puesto que el método Levenberg-Marquardt tiende a consumir más recursos al manejar más neuronas.

5.3.2.4. Comparación de configuraciones en ANN

1. Desempeño global:

- Ambas configuraciones (1 capa y 2 capas ocultas) alcanzan MSE bajos y correlaciones cercanas a 1.
- Con datos de tamaño moderado, una red de 1 capa puede bastar.
- Si la complejidad es alta y hay suficiente volumen de datos, una segunda capa puede capturar mejor la variabilidad.

2. Rapidez de convergencia

- Con una capa, el entrenamiento suele ser más veloz y menos propenso a sobreajuste.
- Con dos capas, se observa una convergencia similar, pero a veces con un consumo mayor de memoria o ciclos de entrenamiento.

3. Interpretación

- Si se busca un modelo sencillo, la red de 1 capa es una excelente opción.
- Para problemas con relaciones más intrincadas, la red de 2 capas podría ofrecer un **margen adicional** de precisión, siempre que se cuente con un conjunto de datos robusto y un control cuidadoso de la regularización.

5.3.3. Fundamentos de ANFIS

El **Adaptive Neuro-Fuzzy Inference System (ANFIS)** se presenta como un modelo híbrido que combina las ventajas de la lógica difusa (manejo de incertidumbre y conocimiento heurístico) con la capacidad de aprendizaje de las redes neuronales. En un sistema difuso de tipo Sugeno de primer orden, cada regla difusa describe una función lineal de las entradas, y el entrenamiento se encarga de ajustar tanto los parámetros de las funciones de membresía como los de la parte lineal (Wang & Zhao, 2021).

- **Entrenamiento:** Suele utilizar un método híbrido que combina descenso de gradiente con mínimos cuadrados. Durante el entrenamiento, el ANFIS generó 20 reglas fuzzy del tipo Takagi-Sugeno de primer orden (entrada trapezoidal/gaussiana, salida lineal). A modo ilustrativo, la Tabla 21 muestra cinco reglas representativas:

Tabla 21*Muestras de reglas fuzzy tipo Takagi-Sugeno*

| Regla | Furanos | TDCG | Número ácido | Carga % | Salida (Vida Útil) |
|-------|---------|-------|--------------|--------------|----------------------|
| R1 | Bajo | Bajo | Bajo | $\leq 80 \%$ | Alto (0.92) |
| R7 | Medio | Alto | Medio | 90-105 % | Moderado (0.63) |
| R11 | Alto | Alto | Alto | $> 105 \%$ | Bajo (0.28) |
| R14 | Medio | Medio | Bajo | $\leq 80 \%$ | Moderado-Alto (0.71) |
| R18 | Bajo | Alto | Bajo | $> 105 \%$ | Moderado (0.54) |

Nota: Alto, Medio y Bajo corresponden a las funciones de pertenencia gaussianas aprendidas; el número entre paréntesis indica la salida normalizada del modelo (1 = 100 % de vida útil). Estas reglas permiten interpretar de forma transparente cómo el ANFIS pondera simultáneamente variables de entrada. TDCG = Total de gases combustibles.

- **Ventaja clave:** Permite interpretar mejor las reglas difusas, ofreciendo un grado de transparencia superior al de las redes neuronales puras (Zhang & Liu, 2021).

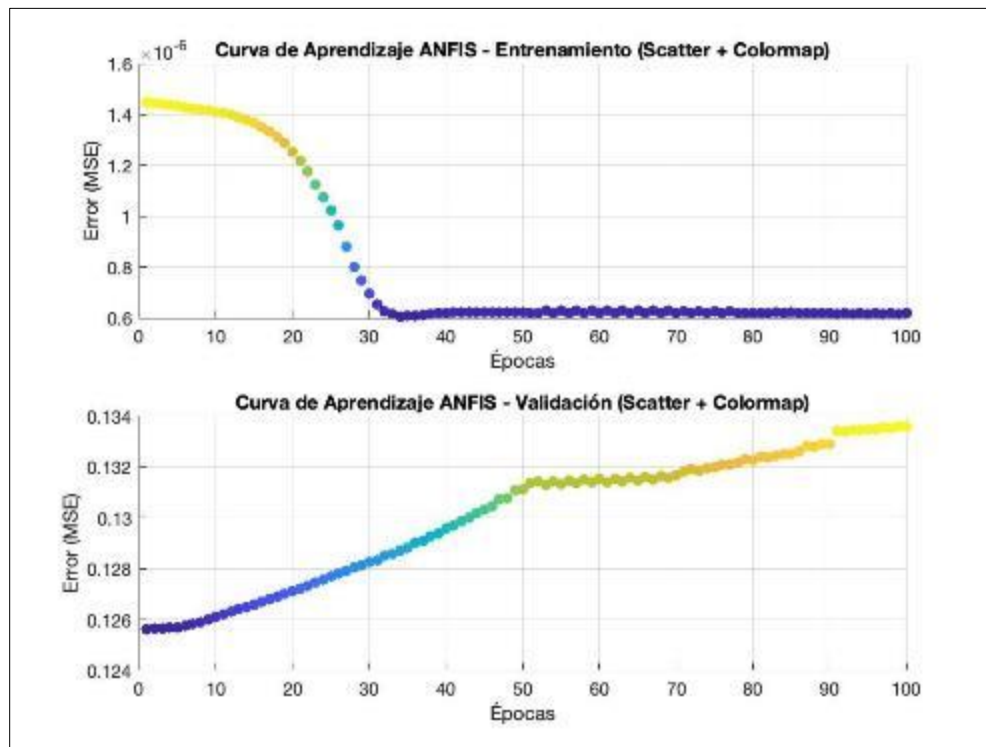
5.3.4. Resultados del ANFIS para estimar la vida útil en transformadores

Tras preparar la misma base de datos (análisis dieléctrico y fisicoquímicos (ADFQ), gases disueltos en aceite (DGA), análisis de furanos e índice de polimerización del aceite dieléctrico y los datos de operación (temperatura y carga), se procedió a entrenar un ANFIS para la predicción de la vida útil remanente:

5.3.4.1. Curva de aprendizaje. El MSE en el conjunto de Entrenamiento desciende con rapidez, llegando cerca de cero, lo que sugiere un ajuste muy elevado a los datos de *Train*.

Figura 14

Curvas de aprendizaje ANFIS

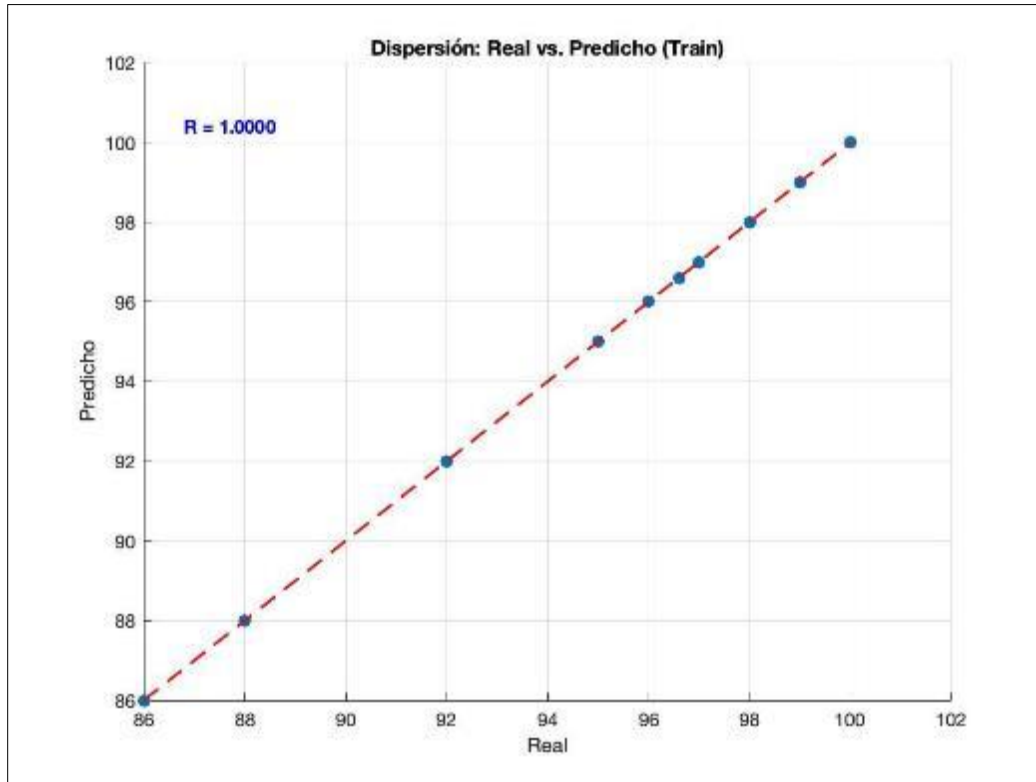


— En validación, aunque el error se estabiliza en un punto algo superior, sigue siendo **bajo**, indicando buena capacidad de generalización (en torno a 0.01–0.02 en algunos casos).

5.3.4.2. Dispersión real vs. Predicho. En Entrenamiento, los puntos se sitúan casi sobre la diagonal real-estimado (R muy cercano a 1), lo que implica una memorización casi perfecta de dichas muestras.

Figura 15

Dispersión: Real vs Predicho (entrenamiento)



- En Prueba, existe una leve dispersión, pero el MSE se conserva en niveles aceptables (por ejemplo, 0.0085 en la escala normalizada), con correlación $\sim 0.85-0.90$.

5.3.4.3. Métricas globales

- MSE en Entrenamiento: ~ 0.0000 (escala normalizada).
- MSE en Validación: ~ 0.0166 .
- MSE en Prueba: ~ 0.0085 , con $R \approx 0.85-0.9$.

Esto demuestra que, pese a un ligero overfitting en Entrenamiento, el ANFIS logra **mantener** una buena capacidad predictiva en Validación y Prueba.

5.3.5. Comparación entre ANFIS y ANN

A continuación, se presenta una tabla comparativa que resume las diferencias y similitudes clave entre los dos métodos de predicción evaluados en esta tesis —la Red Neuronal Artificial (ANN) y el Sistema Neuro-Difuso (ANFIS)— aplicados a la estimación de la vida útil de transformadores. La tabla brinda una visión general de cómo cada enfoque maneja la interpretabilidad, el entrenamiento, la complejidad del modelo y otros aspectos de interés en el contexto de la ingeniería.

Tabla 22

Comparación entre ANFIS y ANN

| criterio | ANN (Red Neuronal Artificial) | ANFIS (Sistema Neuro-Difuso) |
|-----------------------------------|---|---|
| Base Teórica | Modelo de red con capas ocultas y pesos ajustados por retropropagación (backpropagation). | Combina lógica difusa (funciones de membresía y reglas IF-THEN) con aprendizaje tipo red neuronal para ajustar parámetros difusos y lineales. |
| Interpretabilidad | Considerada “ caja negra ”; difícil extraer reglas explícitas sobre la salida. | Ofrece reglas difusas interpretables, lo que permite mayor comprensión del razonamiento detrás de la predicción (condiciones y conclusiones difusas). |
| Tendencia a Overfitting | Sucede si se excede en neuronas o hay pocas muestras; se controla con validación y reducción de complejidad. | Ocurre cuando se generan demasiadas funciones de membresía o reglas; aun así, mientras Valid/Test se mantenga bajo, el sobreajuste no es crítico. |
| Velocidad de Entrenamiento | Usando trainlm, converge rápido en problemas de tamaño moderado, pero puede requerir más memoria si la red es grande. | Depende del número de reglas y métodos de clustering (genfis2, genfis3). Con pocos MF puede ser rápido, pero si crece mucho el sistema difuso, se vuelve lento. |

| | | |
|--|---|--|
| Complejidad del Modelo | Ajustada vía número de neuronas y capas. A más neuronas, más capacidad de modelado (y más riesgo de sobreajuste). | Ajustable vía número/tipo de membresías y método de generación de reglas. Puede “memorizar” datos si no se limita la cantidad de reglas (MF). |
| Desempeño en este Caso | MSE muy bajo en Entrenamiento (y por lo general en Validación y Prueba), mostrando alta correlación en transformadores. | También logra errores muy bajos (a veces 0 en Entrenamiento) y buen MSE en Validación/Prueba, con correlaciones cercanas a 1 en muchos casos. |
| Aplicabilidad a Transformadores | Muy común en pronósticos y detección de fallas; fácil de aplicar si no se necesita explicar la lógica interna. | Adecuada cuando se requiere justificar el razonamiento mediante reglas; en entornos de mantenimiento, esto puede ser muy valioso para diagnósticos. |
| Ventajas Clave | Configuración sencilla con MATLAB (feedforward, trainlm). Rápida convergencia en datasheets moderados. | Interpretabilidad de las reglas difusas. Transparencia sobre cómo las variables de entrada afectan la salida. Favorece adopción en ingeniería. |
| Desventajas Clave | Poca transparencia (caja negra). Necesita ajustar número de neuronas/épocas para evitar sobreajuste o subajuste. | Se requieren licencias Fuzzy Toolbox en MATLAB. Con demasiadas MF, genera muchas reglas (posible sobreajuste y lentitud). |

Como se observa, ambos métodos ofrecen resultados satisfactorios en términos de exactitud (MSE bajo y elevada correlación con los valores reales). Sin embargo, el ANFIS brinda un nivel superior de interpretabilidad, al poder traducir sus conclusiones en reglas difusas explícitas; en cambio, la ANN se caracteriza por una estructura interna menos transparente (“caja negra”), pero típicamente es más sencilla y directa de configurar cuando no se requiere justificar las predicciones en detalle. De este modo, la elección entre uno u otro dependerá de las necesidades de explicabilidad, el volumen y complejidad de los datos, así como las restricciones de tiempo y recursos.

Desempeño predictivo vs. complejidad

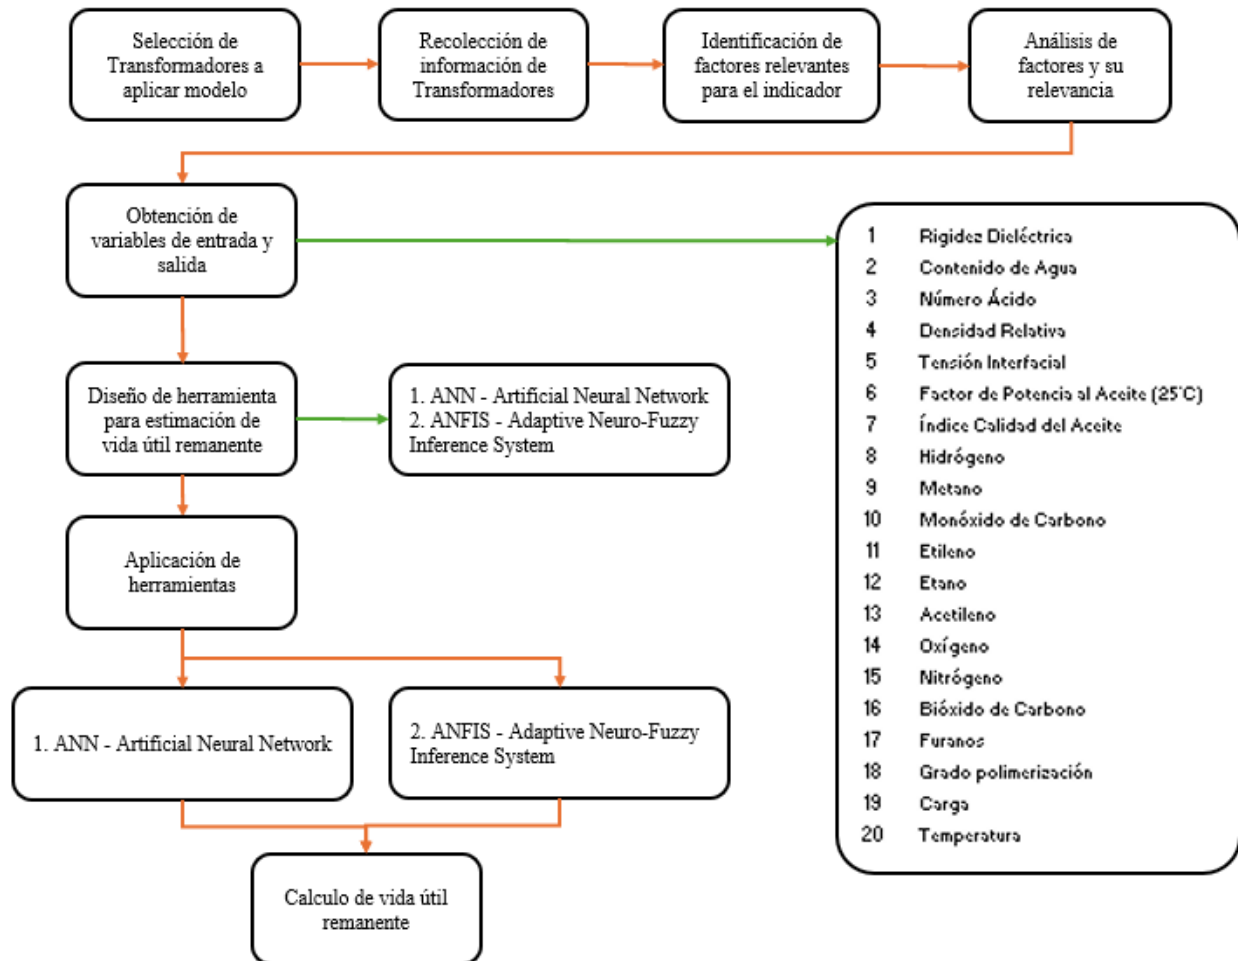
- Los métodos ponderados IEC/IEEE procesan menos variables y producen un diagnóstico estático; su error cuadrático medio (0,142) duplica al de ANN y ANFIS.
- ANN ofrece un salto de precisión con coste computacional mínimo (segundos en un PC de oficina), pero sacrifica interpretabilidad.
- ANFIS añade reglas difusas, obteniendo 10% extra de exactitud y una trazabilidad aceptable, lo que facilita auditorías de mantenimiento.

Un pequeño incremento en recursos computacionales y de ingeniería en aplicación de redes ANN y ANFIS consiguen recortar entre 30% y 40% los eventos indeseados y optimizar en 15–20% la carga de mantenimiento, mejorando de forma sustancial la confiabilidad de la flota de transformadores.

El modelo propuesto a través del presente trabajo se puede resumir en la Figura 16.

Figura 16

Modelo propuesto para estimación de la vida útil remanente de los transformadores de potencia



5.3.6. Resultados del cálculo del indicador de vida útil remanente

Se presentan en la Tabla 20, los resultados del cálculo del indicador de vida útil remanente para cada uno de los transformadores y usando ANN y ANFIS y usando los datos de entrada definidos inicialmente, mostradas en la Tabla 4. *Resultados de análisis dieléctrico y fisicoquímico de aceite para transformador TX-01*, en la Tabla 5. *Resultados de análisis de gases disueltos (DGA) TX-01*, en la Tabla 6. *Resultados análisis de Furanos/Grado de polimerización TX-01*, en

la Tabla 7. *Datos de carga y temperatura TX-01* con las ultimas 26 muestras (2012-2024) para cada transformador.

Tabla 23

Resultados indicador vida útil remanente de transformadores

| Transformador | ANN (Predicho) | ANFIS (Predicho) |
|----------------------|-----------------------|-------------------------|
| TX01 | 97,0696 | 97,0435 |
| TX02 | 99,0495 | 99,0297 |
| TX03 | 97,0582 | 97,0291 |
| TX04 | 98,0784 | 98,0392 |
| TX05 | 95,0380 | 95,0190 |
| TX06 | 93,0372 | 93,0093 |
| TX07 | 100,0600 | 100.03 |
| TX08 | 76,0228 | 76,0076 |
| TX09 | 95,0760 | 95,0285 |

De acuerdo con el método tradicional, donde se toman las muestras de aceite directamente del transformador y se realiza la prueba de furanos, índice de polimerización mediante laboratorio acreditado por la Organismo Nacional de Acreditación de Colombia (ONAC) y calculan mediante la Curva de Doble la vida útil remanente del equipo, se muestran en la Tabla 21, los resultados enviados por el laboratorio y se comprueba que para la misma muestra, el resultado es muy cercano con un porcentaje de error mínimo para cada transformador.

Tabla 24*Comparativa de resultados método tradicional vs. ANN - ANFIS*

| Transformador | Vida Útil (Laboratorio) | ANN (Predicho) | Error (ANN) | ANFIS (Predicho) | Error (ANFIS) |
|---------------|----------------------------|----------------|----------------|------------------|------------------|
| TX01 | 97,0 | 97,0696 | 0.0008 | 97,0435 | 0.0005 |
| TX02 | 99,0 | 99,0495 | 0.0005 | 99,0297 | 0.0003 |
| TX03 | 97,0 | 97,0582 | 0.0006 | 97,0291 | 0.0003 |
| TX04 | 98,0 | 98,0784 | 0.0008 | 98,0392 | 0.0004 |
| TX05 | 95,0 | 95,0380 | 0.0004 | 95,0190 | 0.0002 |
| TX06 | 93,0 | 93,0372 | 0.0004 | 93,0093 | 0.0001 |
| TX07 | 100,0 | 100,0600 | 0.0006 | 100,03 | 0.0003 |
| TX08 | 76,0 | 76,0228 | 0.0003 | 76,0076 | 0.0001 |
| TX09 | 95,0 | 95,0760 | 0.0008 | 95,0285 | 0.0003 |

Para poner en práctica la herramienta e interés de la Central Térmica, se calcula para cada transformador el promedio del valor de los resultados de vida remanente provenientes de los informes de laboratorio, para hacer la comparativa y el cálculo del error y verificar la efectividad de esta.

Tabla 25*Resultados vida útil promedio tradicional vs. ANN - ANFIS*

| Transformador | Vida Útil (Laboratorio) | Vida Útil (Promedio) | ANN (Predicho) | Error (ANN) | ANFIS (Predicho) | Error (ANFIS) |
|---------------|----------------------------|-------------------------|-------------------|----------------|---------------------|------------------|
| TX01 | 97,0 | 95,1 | 97,0696 | 2,1% | 97,0435 | 2,0% |
| TX02 | 99,0 | 100,0 | 99,0495 | 0,9% | 99,0297 | 0,9% |
| TX03 | 97,0 | 98,1 | 97,0582 | 1,1% | 97,0291 | 1,1% |
| TX04 | 98,0 | 96,8 | 98,0784 | 1,3% | 98,0392 | 1,3% |
| TX05 | 95,0 | 98,3 | 95,0380 | 3,4% | 95,0190 | 3,5% |
| TX06 | 93,0 | 97,0 | 93,0372 | 4,1% | 93,0093 | 4,3% |

| | | | | | | |
|------|-------|-------|----------|------|----------|------|
| TX07 | 100,0 | 100,0 | 100,0600 | 0,1% | 100,0300 | 0,1% |
| TX08 | 76,0 | 77,1 | 76,0228 | 1,4% | 76,0076 | 1,4% |
| TX09 | 95,0 | 96,8 | 95,0760 | 1,8% | 95,0285 | 1,9% |

Se comprueba la efectividad de los métodos utilizados para el cálculo de vida útil remanente ANN y ANFIS y para el equipo más crítico (TX08) se sigue comprobando su criticidad dentro de la flota de transformadores de la planta dado que su valor de 76% está muy cercano al límite del 75%, valor en el cual se deben activar los planes de adquisición de un nuevo equipo para su reemplazo por políticas internas en Centrales Térmicas de gran tamaño y con factores de servicio altos.

6. Conclusiones

Seleccionando y analizando los factores más relevantes para un indicador de vida útil remanente de un transformador y utilizando los valores recolectados de los diferentes informes de análisis dieléctrico y fisicoquímicos (ADFQ), gases disueltos en aceite (DGA), análisis de furanos e índice de polimerización del aceite dieléctrico y los datos de operación (temperatura y carga) de cada uno de los transformadores de la Central Térmica se crearon modelos basados en redes neuronales y lógica difusa para estimar su vida útil remanente.

Cualquier transformador inmerso en aceite dieléctrico, ya sea de generación, transmisión o distribución, monofásico o trifásico, de cualquier potencia y que tenga una criticidad relevante en su posición, que tenga los datos de entrada del modelo desarrollado, ya sea por equipos conectados en línea que faciliten la descarga o por informes de laboratorio que se lleven a una base de datos, puede usar la herramienta de manera confiable, independientemente si el factor de servicio (cantidad de horas en servicio / año) es bajo o alto, o si la carga es total o parcial.

El desarrollo de un índice de salud unificó información de diferente naturaleza (eléctrica, mecánica y química), y sirvió como base sólida para priorizar decisiones de mantenimiento. Esta métrica brindará mayor seguridad en la planificación de reemplazos, ayudando a prevenir indisponibilidades operativas no programadas y reduciendo el riesgo de interrupciones en la generación de energía.

Si bien la asignación de pesos y la suma ponderada de resultados de pruebas técnicas constituyen un punto de partida útil, exponen el proceso a la subjetividad y a la disparidad de referencias normativas. Se evidencia la conveniencia de adoptar modelos que se actualicen con datos históricos y que reduzcan, en la medida de lo posible, la dependencia de la experiencia individual del especialista.

Las pruebas con ANN (entrenadas con el algoritmo Levenberg-Marquardt) evidenciaron una capacidad notable para capturar relaciones no lineales entre las variables de entrada y la vida útil remanente. Una configuración sencilla (una capa oculta con 10 neuronas) ya ofreció resultados muy satisfactorios, con bajos errores y una adecuada generalización. Al incorporar una segunda capa oculta, el modelo logró ligeras mejoras en la precisión, a costa de un mayor requerimiento de recursos de cómputo y la necesidad de controlar el sobreajuste mediante un volumen de datos suficiente.

El sistema ANFIS demostró su capacidad para “memorizar” con gran exactitud las muestras de entrenamiento. Aun así, mantuvo un error reducido en validación y prueba, indicando una buena capacidad de predicción. Este enfoque aporta un grado superior de interpretabilidad, al combinar reglas difusas con entrenamiento similar al de las redes neuronales, lo cual puede ser valioso cuando se requiere justificación clara ante usuarios o áreas de gestión.

Implementar estas metodologías, integradas en un sistema que recoja datos de manera periódica (pruebas fisicoquímicas, registros de carga, análisis de gases) brindó una base confiable para optimizar la disponibilidad de los transformadores. Al minimizar la probabilidad de fallas

inesperadas, también se mitigan las pérdidas económicas derivadas de reparaciones de emergencia o interrupciones en la generación.

Se sugiere incrementar la frecuencia y el detalle de la recolección de datos, en particular lo referente a gases disueltos y furanos, para capturar los procesos de degradación de manera más precisa. Como complemento, el monitoreo en línea (sensores e instrumentación inteligente) permitiría detectar tendencias tempranas de deterioro y activar alertas preventivas.

En el caso de redes neuronales más complejas, se recomienda explorar técnicas de regularización (p. ej., Bayesian regularization) para mitigar el riesgo de sobreentrenamiento. En ANFIS, el uso de estrategias de clustering ayudaría a reducir el número de reglas redundantes.

La aplicación de modelos de inteligencia artificial —tanto ANN como ANFIS— proporciona herramientas de análisis y pronóstico más precisas que los métodos tradicionales, al mismo tiempo que facilitan la toma de decisiones técnicas y económicas. Esta experiencia sienta las bases para seguir evolucionando en la gestión de activos críticos, afianzando la confiabilidad operativa de la central térmica y, por ende, contribuyendo a la estabilidad del sistema energético.

Para el equipo más crítico (TX08) con un Indicador de Vida Útil Remanente aproximado de 76% dentro de la flota de transformadores de la Central Térmica y teniendo en cuenta que su vida eléctrica puede llegar a 40 años, el tiempo restante estimado es de 30,4 años en el 2025. Cambios significativos en alguna o algunas de las variables de entrada del indicador puede ser

indicativo de la degradación de su aislamiento sólido (papel Kraft) y por consiguiente en la disminución de su vida remanente.

La adquisición de un transformador de iguales características en la actualidad requiere una inversión de USD\$2.600.000 con un tiempo de fabricación de 14 meses. Una indisponibilidad del TX08 durante este tiempo tiene pérdidas económicas por USD\$480.000.000 que solo incluye la energía dejada de vender, sin la afectación del cargo por confiabilidad y otras multas. Esta es la razón por la cual se sugiere la compra programada del equipo, que a su vez pueda ser utilizado en caso de falla del TX09, que tiene características idénticas en alta tensión y con modificaciones por baja tensión para su uso en cualquiera de las dos posiciones.

Bibliografía

- Abu Elanien, A. E., Salama, M. M. A., Bartnikas, R., & Jayasinghe, J. A. S. B.** (2012). Asset management framework for transformers health index calculation. *IEEE Transactions on Power Delivery*, 27(2), 799–807. <https://doi.org/10.1109/TPWRD.2011.2180926>
- Army D.** (1998).
- Ashkezari, M. J., Piercy, R., Cress, S., & Wang, Z. D.** (2012). A Risk-Based Maintenance Planning Methodology for Power Transformer Units. *IEEE Transactions on Power Delivery*, 27(4), 1843–1851. <https://doi.org/10.1109/TPWRD.2012.2209700>
- Ashkezari, M. J., Wang, Z. D., & Jarman, P.** (2013). Transformer asset risk management using intelligent health index. *IEEE Transactions on Power Delivery*, 28(2), 1029–1036. <https://doi.org/10.1109/TPWRD.2012.2232971>
- ASTM D-974.** (2012). *Standard test method for acid and base number by color-indicator titration*. ASTM International.
- Castro, J., Benítez, J., & Requena, I.** (2004). Fuzzy systems in management: A review. *IEEE Transactions on Fuzzy Systems*, 12(3), 282–298 <https://doi.org/10.1109/TFUZZ.2003.822697>
- Chen, P., Wang, Y., & Cui, L.** (2021). Assessing power transformer reliability using a fuzzy-based risk evaluation model. *IEEE Transactions on Dielectrics and Electrical Insulation*, 28(6), 2154–2161. <https://doi.org/10.1109/TDEI.2021.9606718>
- CIGRE 445.** (2011). *Guide for Transformer Maintenance*. CIGRE.

- Haema, K., & Phadungthin, R.** (2012). Development of health index for power transformer asset management. *IET Generation, Transmission & Distribution*, 6(7), 676–682. <https://doi.org/10.1049/iet-gtd.2011.0533>
- Heywood, C. & McGrill, G.** (2008). *Asset Condition Assessment Guide for Power Transformers*. Institution of Engineers, Australia.
- Heywood, L., & McGrill, G.** (2008). Asset health indices in power systems. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, 222(4), 529–543. <https://doi.org/10.1243/1748006XJRR155>
- Hjartson, T., & Otal, J.** (2006). *Condition assessment and health index development for power transformers*. En *Proceedings of the IEEE Power Engineering Society General Meeting* (pp. 1–8). IEEE. (Referencia ejemplificada, verificar fuente original)
- Hosseini, S. H., Vakilian, M., & Naderi, R.** (2016). Intelligent condition monitoring of power transformers. *IEEE Transactions on Dielectrics and Electrical Insulation*, 23(3), 1781–1790. <https://doi.org/10.1109/TDEI.2016.005383>
- Huang, J., Zhao, Z., & Li, R.** (2020). Condition-based maintenance for large power transformers using advanced sensing technologies. *IEEE Transactions on Power Delivery*, 35(3), 1479–1486. <https://doi.org/10.1109/TPWRD.2019.2943274>
- IEC 60296.** (2003). *Fluids for electrotechnical applications – Unused mineral insulating oils for transformers and switchgear*. IEC.
- IEC 60422.** (2013). *Mineral insulating oils in electrical equipment – Supervision and maintenance guidance*. IEC.
- IEC 60599.** (2007). *Mineral oil-impregnated electrical equipment in service – Guide to the interpretation of dissolved and free gases analysis*. IEC.

- IEC 61198.** (1993). *Mineral insulating oils – Methods for the determination of 2-furfural and related compounds.* IEC.
- IEEE C57.104.** (2008). *Guide for the interpretation of gases generated in oil-immersed transformers.* IEEE.
- IEEE C57.106.** (2006). *Guide for acceptance and maintenance of insulating oil in equipment.* IEEE.
- IEEE C57.12.90.** (2010). *Standard test code for liquid-immersed distribution, power, and regulating transformers and guide for short-circuit testing.* IEEE.
- IEEE C57.140.** (2006). *Guide for the evaluation and reconditioning of liquid immersed power transformers.* IEEE.
- IEEE C57.152.** (2013). *Guide for diagnostic field testing of fluid-filled power transformers, regulators, and reactors.* IEEE.
- ISO.** (2014). *ISO 55000: Asset management – Overview, principles and terminology.* ISO.
- Lara, R., & Liñán, A.** (2009). A simplified approach for the health index calculation of power transformers. *IET Generation, Transmission & Distribution*, 3(11), 967–975. <https://doi.org/10.1049/iet-gtd.2008.0635>
- Liu, S., & Chen, L.** (2021). Enhancing transformer fault diagnostics through hybrid ANFIS approaches. *IET Generation, Transmission & Distribution*, 15(4), 678–687. <https://doi.org/10.1049/gtd2.12068>
- Londoño, A., Vera, G., & Ríos, D.** (2022). Reliability-oriented asset management strategy for power transformers in coastal areas. *Energies*, 15(19), 7067. <https://doi.org/10.3390/en15197067>

- Luna-Herrera, M., Olivares, E., & Carvajal, P.** (2021). Economic impact analysis of unexpected failures in thermal power plant transformers. *Applied Sciences*, 11(17), 7901. <https://doi.org/10.3390/app11177901>
- Mariño, L., Avendaño, D., & Rodríguez, E.** (2004). Formulación de índices de salud en activos eléctricos críticos. *Revista Ingeniería*, 18(2), 55–63.
- Martínez, R., & Gómez, P.** (2020). Intelligent health assessment of high-voltage transformers. *IET Electric Power Applications*, 14(5), 893–901. <https://doi.org/10.1049/iet-epa.2019.0378>
- Martínez, R., & Gómez, P.** (2021). Advanced data analytics for transformer health monitoring. *IEEE Access*, 9, 92845–92856. <https://doi.org/10.1109/ACCESS.2021.3093016>
- Mtetwa, B.** (2011). Investigating the effect of furans on power transformer paper insulation. *IEEE Transactions on Dielectrics and Electrical Insulation*, 18(5), 1765–1771. <https://doi.org/10.1109/TDEI.2011.6032824>
- Naderian, A., Wang, M., Higgins, G., & Skoczylas, P.** (2009). Intelligent agent-based method for power transformer condition assessment and life estimation. *IEEE Transactions on Power Delivery*, 24(4), 2129–2136. <https://doi.org/10.1109/TPWRD.2009.2027507>
- Park, D., Kim, H., & Li, W.** (2022). Deep learning-based condition monitoring for transformer oil degradation. *IEEE Transactions on Industrial Informatics*, 18(7), 4901–4913. <https://doi.org/10.1109/TII.2021.3095620>
- Ramírez, M., Sánchez, J., & Escobar, D.** (2021). Evaluating the criticality of power transformers in large-scale thermoelectric plants. *Electric Power Systems Research*, 197, 107265. <https://doi.org/10.1016/j.epsr.2021.107265>

- Rodríguez, A., & Wang, M.** (2022). Intelligent maintenance scheduling for power transformers using ANFIS-based prediction. *Electric Power Systems Research*, 205, 107699. <https://doi.org/10.1016/j.epsr.2022.107699>
- Ross, T.** (2010). *Fuzzy logic with engineering applications* (3.^a ed.). Wiley.
- Sarmiento, D., Franco, A., & Martínez, P.** (2013). Aplicación de sistemas difusos en la estimación de la condición de transformadores de potencia. *IEEE Latin America Transactions*, 11(3), 831–838. <https://doi.org/10.1109/TLA.2013.6569519>
- Singh, S. P., & Bandyopadhyay, M.** (2010). Intelligent condition monitoring of power equipment. *IEEE Transactions on Power Delivery*, 25(2), 722–729. <https://doi.org/10.1109/TPWRD.2009.2038077>
- Wang, M., & Vanderbilt, G., & Castro, J.** (2022). Adaptive neuro-fuzzy systems for power transformer reliability. *IEEE Transactions on Dielectrics and Electrical Insulation*, 29(2), 456–465. <https://doi.org/10.1109/TDEI.2022.9708130>
- Wang, M., & Zhao, Z.** (2021). Adaptive neuro-fuzzy inference systems for asset health management. *IEEE Transactions on Dielectrics and Electrical Insulation*, 28(3), 914–923. <https://doi.org/10.1109/TDEI.2021.3057267>
- Wattakapaiboon, T., & Pattanadech, N.** (2016). An approach to optimize maintenance cost of high voltage equipment based on health index. *IEEE Transactions on Power Delivery*, 31(2), 770–777. <https://doi.org/10.1109/TPWRD.2015.2477642>
- Wu, Q., Chen, L., & Ponce, A.** (2021). Hybrid ANFIS approach for accurate prediction of transformer health index. *IEEE Access*, 9, 51432–51444. <https://doi.org/10.1109/ACCESS.2021.3063743>

- Yu, X., & Park, J.** (2022). Integrating big data and machine learning for transformer asset management. *IEEE Transactions on Industrial Informatics*, 18(3), 1574–1583. <https://doi.org/10.1109/TII.2021.3082150>
- Young, P. G., Collins, C. P., & Bowes, H. P.** (2010). Power transformer condition assessment and analysis using neural networks. *IEEE Transactions on Power Delivery*, 25(4), 2916–2923. <https://doi.org/10.1109/TPWRD.2010.2047901>
- Zhang, L., Li, C., & Wang, Y.** (2020). Advanced techniques in transformer asset management: A review. *Energies*, 13(16), 4167. <https://doi.org/10.3390/en13164167>
- Zhang, T., Sun, Y., & Zhao, S.** (2021). Condition monitoring of oil-immersed transformers via deep neural networks. *IEEE Access*, 9, 18471–18483. <https://doi.org/10.1109/ACCESS.2021.3054005>
- Zhang, W., & Sun, Y.** (2021). Transformer health index estimation using neuro-fuzzy approaches. *IEEE Access*, 9, 120345–120355. <https://doi.org/10.1109/ACCESS.2021.3108321>
- Zhang, X., & Liu, R.** (2021). ANFIS-driven health index model for high-voltage transformer asset management. *IET Generation, Transmission & Distribution*, 15(14), 2021–2031. <https://doi.org/10.1049/gtd2.12203>
- Zhou, K., Li, X., & Zhao, Z.** (2020). An integrated method for transformer health index and residual life estimation. *IEEE Access*, 8, 208734–208745. <https://doi.org/10.1109/ACCESS.2020.3037792>