



UNIVERSIDAD NACIONAL DE COLOMBIA

Desarrollo de una técnica de Gestión de Activos para Transformadores de Distribución basada en sistema de monitoreo

Kevin Steven Morgado Gómez

Universidad Nacional de Colombia
Facultad de Ingeniería, Departamento de Ingeniería Eléctrica y Electrónica
Bogotá, Colombia
2022

Desarrollo de una técnica de Gestión de Activos para Transformadores de Distribución basada en sistema de monitoreo

Kevin Steven Morgado Gómez

Tesis o trabajo de grado presentada(o) como requisito parcial para optar al título de:
Magister en Automatización Industrial

Director(a):
Javier Rosero García, PhD

Línea de Investigación:
Gestión de Activos en Sistemas de Potencia
Grupo de Investigación:
Electrical Machines and Drives (EM&D)

Universidad Nacional de Colombia
Facultad de Ingeniería, Departamento de Ingeniería Eléctrica y Electrónica
Bogotá, Colombia
2022

Whether you're a writer, marketer, consultant, or lawyer: Your work is craft, and if you hone your ability and apply it with respect and care, then like the skilled wheelwright you can generate meaning in the daily efforts of your professional life.

Cal Newport

Agradecimientos

Agradezco a mi familia por el apoyo constante para el desarrollo de este documento y en especial a mis padres, a mi hermana y a mi abuela. También agradezco al profesor Javier Rosero por su apoyo durante toda esta investigación y a las personas del grupo de investigación de Electrical Machines and Drives EM&D por sus consejos y colaboración para culminar este proyecto.

Resumen

Desarrollo de una técnica de Gestión de Activos para Transformadores de Distribución basada en sistema de monitoreo

En este documento se desarrolló un sistema de diagnóstico del estado actual de una flota de cuatro transformadores de potencia del Campus Universitario de la Universidad Nacional de Colombia sede Bogotá, teniendo en cuenta el registro en tiempo real de tensión, corriente y de edad de estos dispositivos almacenado en el Laboratorio Nacional de Redes Inteligentes (LAB+i). Para este fin, se implementó un sistema de gestión de activos compuesto de un módulo de predicción basado en métodos estadísticos y de un módulo de lógica difusa, con el objetivo de la clasificación de los transformadores considerando las condiciones de consumo de energía y comparando el desempeño con métodos actuales de gestión. Se identificó que este sistema se puede utilizar tanto para el seguimiento del estado de la flota en tiempo real como para su proyección en el futuro, si bien se presentaron retos asociados a asegurar una operación continua en el tiempo.

Palabras clave: Gestión de Activos, Transformadores de Potencia, Ciclo de Vida.

Abstract

Development of an Asset Management technique for Distribution Transformers based on a monitoring system.

This paper presents the development of a diagnostic system for the current status of a fleet of four power transformers of the University Campus of the Universidad Nacional de Colombia in Bogotá, considering the real-time recording of voltage, current, and device age through the National Laboratory of Smart Grids (LAB+i). For this purpose, an asset management system was implemented, consisting of a prediction module based on statistical methods and a fuzzy logic module for the classification of transformers according to their conditions of energy consumption. It was identified that this management system could be used to monitor the status of the fleet in real-time and with future values, although there were challenges associated with its continuous operation over time.

Keywords: Asset Management, Power Transformers, Life Cycle

Lista de Figuras

2-1. Ejemplo de análisis de desempeño de Gestión de Activos [15]	6
2-2. Concepto de cálculo del Índice de Salud [17]	8
2-3. Elementos base del sistema de gestión de activos [18]	8
2-4. Ciclos de Vida propuestos del Transformador de Potencia [18]	9
2-5. Resumen de sistema de gestión de activos [21]	11
2-6. Matriz de riesgo teniendo en cuenta factores técnicos y económicos [21]	11
2-7. Matriz de cálculo de condiciones [22]	12
2-8. Cálculo final de la pérdida de vida del transformador [23]	13
2-9. Esquema metodológico para la gestión de riesgo en los activos [25]	14
2-10. Organización de transformadores analizados [25]	15
2-11. Red neuronal para cálculo de probabilidad de fallas en el transformador [30]	16
2-12. Ejemplo de un sistema de monitoreo inteligente [30]	17
2-13. Diagrama de influencia para índice de salud del transformador [33]	17
2-14. Sistema de monitoreo NSET [34]	18
2-15. Parámetros de referencia de análisis de condición de transformador [35]	19
2-16. Función de probabilidad de falla para un conjunto de transformadores [35]	20
2-17. Representación en tres dimensiones de los transformadores analizados en [37]	20
2-18. Ejemplo de modelo de regresión logística y red neuronal para HI [39]	23
2-19. Función de membresía del índice de salud para un transformador de alta tensión [40]	24
2-20. Resultados de aplicación del indicador de salud presentado en [41]	25
2-21. Estimación de probabilidad de falla basada en el índice de salud [42]	26
2-22. Modelo de ejemplo de lógica difusa para cálculo de índice de salud [43]	27
2-23. Conexiones para medición de parámetros de modelo de lógica difusa [44]	27
3-1. Diferentes tipos de arquitecturas de redes neuronales [46]	30
3-2. Parámetros de análisis de modelos de diagnóstico [47]	31
3-3. Ejemplo de cálculo de indicadores de HI con base en ponderación y redes neuronales [48]	31
3-4. Ejemplo de red neuronal aplicada para las predicciones de las propiedades del transformador [49]	32
3-5. Ejemplos de desempeño de redes neuronales en la predicción de la velocidad del viento [50]	32

3-6. Ejemplo de red neuronal para celdas refractarias [51]	33
3-7. Estructura base de la red de Elman implementada en [53]	34
3-8. Comparación del pronóstico del día después entre los modelos expuesto en [55]	35
3-9. Datos de tráfico en conjunto con la predicción de PROPHET [56]	36
3-10. Predicción de consumo de potencia durante días laborales [57]	36
3-11. Ejemplo de composición de sistema de lógica difusa [59]	37
3-12. Diagrama conceptual de lógica difusa [60]	38
3-13. Esquema de desarrollo de lógica difusa [60]	39
3-14. Estructura General de sistema de evaluación basado en lógica difusa [61] . .	39
3-15. Función de membresía Tipo 1 (a) y Tipo 2 (b) [62]	40
4-1. Subestaciones eléctricas del Campus Universitario de la Universidad Nacional de Colombia - Sede Bogotá [64]	42
4-2. Estructura base del sistema de monitoreo en el Campus Universitario [65] . .	43
4-3. Sistema de conexión de NEPLAN y de VisualStudio [65]	44
4-4. Recopilación curvas de carga de acuerdo con la clasificación de clusters [67] .	44
4-5. Plataforma para evaluación del desempeño de Estimación de Estados [11] . .	45
4-6. Componentes de un sistema de medición inteligente [68]	46
4-7. Presentación de las capas del Modelo de Gestión	48
4-8. Corriente de una fase del edificio nuevo de enfermería	50
4-9. Tensión de una fase del edificio nuevo de enfermería	50
4-10. Corriente de ejemplo para los 4 casos de estudio	52
4-11. Función de membresía para corriente	53
4-12. Función de membresía para Tensión	53
4-13. Función de membresía para la edad del transformador	54
4-14. Función de membresía de calidad del transformador de potencia	54
4-15. Esquema de análisis de indicador final y clasificación	56
4-16. Función de membresía para corriente en [44]	60
4-17. Función de membresía para corriente en [44]	60
4-18. Función de membresía para el nivel del aceite aislante en [44]	61
4-19. Función de membresía para el índice de salud en [44]	61
5-1. Datos de consumo del edificio de enfermería durante 1 semana	64
5-2. Ejemplo de predicción de consumo para un día hábil	65
5-3. Predicción de corriente en el período hábil	66
5-4. Predicción de corriente para el día viernes	67
5-5. Predicción de corriente para el día sábado	67
5-6. Predicción de corriente para el día festivo	68
5-7. Comportamiento semanal de la corriente para el caso de estudio	70
5-8. Comportamiento semanal de la tensión para el caso de estudio	70
5-9. Análisis de picos de corriente con respecto a las categorías en [42]	71

5-10.	Resultados de implementación de [73] para la subestación de medicina	72
5-11.	Resultados de implementación de sistema de lógica difusa propuesta en [44] .	73
5-12.	Valor real del índice de Salud	74
5-13.	Valor predicho del Índice de Salud	75
5-14.	Pérdida de información en medición al Auditorio León de Greiff	77
5-15.	Comportamiento de referencia de la corriente para el caso de estudio	78
5-16.	Comportamiento del indicador de desempeño ante intermitencia de información	79
5-17.	Datos de referencia para predicción	79
5-18.	Predicción de corriente con alto error en el diagnóstico	80
5-19.	Ejemplo de comportamiento de temperatura para subestación de Medicina .	81
B-1.	Esquema de desarrollo de modelo en sistema de monitoreo	93

Lista de Tablas

2-1. Niveles de desarrollo de la gestión de Activos [22]	12
2-2. Factores del índice de salud 1 analizado en [38]	21
2-3. Factores del índice de salud 2 analizado en [38]	22
4-1. Reglas de sistema de clasificación difuso	55
4-2. Parámetros utilizados por métodos de referencia	58
4-3. Clasificación de transformador de acuerdo con la edad. Adaptado de [42] . .	59
4-4. Reglas de sistema de lógica difusa mencionado en [44]	62
5-1. RSME para los diferentes métodos de predicción	68
5-2. Valores base de subestaciones de análisis	71
5-3. Indicador final de salud siguiendo la metodología de [42]	72
5-4. Valores de salida de los métodos analizados en el informe	76
5-5. Subestaciones con disponibilidad para análisis de desempeño	81

Contenido

Agradecimientos	VII
Resumen	IX
Lista de figuras	XI
Lista de tablas	XV
1. Introducción	2
1.1. Objetivos	3
1.1.1. Objetivo General	3
1.1.2. Objetivos Específicos	3
1.2. Publicaciones	3
2. Gestión de Activos y Modelado de Transformadores de potencia	4
2.1. Definición General de Gestión de Activos	4
2.2. Aplicación de la Gestión de Activos en Sistemas de Potencia	7
2.3. Aplicación para transformadores de potencia	13
3. Modelos de predicción y clasificación	29
3.1. Redes Neuronales	29
3.2. Modelos Estadísticos	34
3.3. Lógica Difusa	37
4. Modelo de Gestión para flota de transformadores	41
4.1. Laboratorio Nacional de Redes Inteligentes	41
4.2. Descripción de información disponible	46
4.3. Estructura del modelo	48
4.3.1. Extracción de Información a partir de Python	49
4.3.2. Modelo de Predicción	51
4.3.3. Clasificación por Lógica Difusa	52
4.3.4. Índice de Salud	56
4.4. Modelos de referencia para comparación de desempeño	58

5. Implementación de métodos y análisis de resultados	63
5.1. Comparación de métodos de predicción	63
5.2. Implementación del sistema de gestión con predicción	69
5.2.1. Aplicación de modelos de referencia de análisis de transformadores . .	71
5.2.2. Resultados de modelo propuesto	73
5.2.3. Comparación de resultados	76
5.2.4. Retos de implementación	77
5.2.5. Ampliación de escenarios de análisis	80
5.2.6. Puntos de trabajo con respecto a modelos tradicionales	82
6. Conclusiones y proyectos futuros	83
6.1. Conclusiones	83
6.2. Proyectos futuros	85
A. Resumen de Código Implementado	86
A.1. Funciones de Tratamiento de información proveniente del LAB+i	86
A.2. Código Final	89
B. Esquema de implementación del modelo de gestión	93
Bibliografía	94

1. Introducción

Los transformadores de potencia instalados en los sistemas de distribución de energía eléctrica están pasando por un proceso constante de degradación, aspecto que se agrava con su antigüedad y de las condiciones del sitio de operación [1, 2, 3]. Es por ello que el desarrollo de sistemas de gestión de estos dispositivos se ha vuelto importante para identificar el tiempo óptimo de mantenimiento y reemplazo, a la vez que sirve de insumo para el desarrollo de investigaciones enfocadas en la extensión del tiempo de vida sin aumentar los riesgos de falla asociados al suministro de electricidad y seguridad de la zona [4, 5, 6].

Un ejemplo de monitoreo corresponde a las Redes Inteligentes y a la disponibilidad de información en tiempo real de la operación del transformador de distribución, identificando retos asociados a los canales de comunicación y de tratamiento de la información [7, 8, 9]. Por estos motivos se presenta en el documento de tesis el desarrollo de una técnica de Gestión de Activos para un transformador de distribución, basado en la información proveniente del sistema de monitoreo y supervisión en línea del Laboratorio Nacional de Redes Inteligentes (LAB+i) [10, 11].

En el capítulo 2 se presentó la revisión del estado del arte con respecto al concepto de gestión de activos y de modelos de clasificación de transformadores actualmente implementados, identificando los parámetros a considerar para el desarrollo del modelo. Luego en el capítulo 3 se realizó un resumen de algunos modelos de predicción y clasificación tales como los basados en redes neuronales, modelos estadísticos y sistemas de Lógica Difusa con el objetivo de identificar los idóneos para el modelo de gestión propuesto.

A partir de esta información se presentó en el capítulo 4 el desarrollo del modelo de gestión, en donde se realizó una descripción del LAB+i, del sistema de potencia de referencia y de la información disponible para el desarrollo del diagnóstico. Con ello se expuso cada uno de los módulos del sistema desde la extracción de información con un código en Python el índice de salud final, describiendo paralelamente tres sistemas de referencia para identificar el desempeño de este nuevo modelo con respecto a las aplicaciones actuales.

En el capítulo 5 se presentaron los resultados de la implementación del modelo, iniciando con la comparación de desempeño entre los distintos métodos de predicción disponibles basada en la información que se obtuvo del LAB+i. Luego, se puso en práctica el sistema de

gestión con una flota de 4 transformadores, relacionando las ventajas y retos asociados con un diagnóstico continuo del dispositivo en conjunto con la comparación con otros métodos disponibles.

Por último, en el capítulo 6 se presentaron las conclusiones y los proyectos futuros del sistema en conjunto con el Anexo A, donde se presenta el código final implementado en el proyecto.

1.1. Objetivos

1.1.1. Objetivo General

Desarrollar una técnica de Gestión de Activos para un transformador de distribución, basado en un sistema de monitoreo y supervisión en línea.

1.1.2. Objetivos Específicos

- Determinar el grado de relevancia de los parámetros medidos en el sistema de monitoreo aplicado en el Campus Universitario para su uso en el sistema de Gestión de Activos.
- Formular un método de cálculo de la condición de vida del Transformador de Potencia teniendo en cuenta los datos disponibles en el sistema de monitoreo.
- Validar la efectividad del diagnóstico del estado de los Transformadores de Potencia en el LAB+i, teniendo en cuenta una desviación asociada a un diagnóstico de referencia.

1.2. Publicaciones

En el marco de desarrollo del trabajo de investigación se publicaron los siguientes artículos:

- K. S. Morgado Gomez and J. Rosero Garcia, “*Asset Management Model for the Transformer Fleet of the National Laboratory of Smart Grids (LAB+i) Based on Fuzzy Logic and Forecasting*,” 2021 Int. Conf. Smart City Green Energy, ICSCGE 2021, pp. 57–62, 2021, doi: 10.1109/ICSCGE53744.2021.9654425
- K. S. Morgado Gómez and J. Rosero García, “*Analysis of Asset Management Models for a Transformer Fleet in the National Laboratory of Smart Grids (LAB+i)*,” Trans. Energy Syst. Eng. Appl., vol. 3, no. 1, pp. 7–12, Mar. 2022, doi: 10.32397/TESEA.VOL3.N1.2

2. Gestión de Activos y Modelado de Transformadores de potencia

2.1. Definición General de Gestión de Activos

En términos generales, la gestión de activos según [12] corresponde a “El conjunto de actividades y prácticas a través de las cuales una organización maneja de forma eficiente sus activos con el propósito de alcanzar un Plan Estratégico”. Para la identificación adecuada del sistema de gestión de activos es importante la definición de algunos conceptos clave dados por la Normativas ISO 55000 [13] y PAS 55 [14], ya que en estas guías se presenta la conceptualización base de estos procesos:

- **Objetivo:** Resultado a Alcanzar.
- **Objetivo Organizacional:** Objeto que acota el contexto y la dirección de las actividades de una organización.
- **Riesgo:** Efecto de la Incertidumbre sobre los objetivos.
- **Activo:** Objeto que tiene o puede presentar un valor potencial para una organización.
- **Vida de un activo:** Período desde la creación del activo.
- **Ciclo de vida:** Etapas de gestión.
- **Portafolio de Activos:** Activos que se hallan dentro del alcance del sistema de Gestión.
- **Sistema de Activos:** Conjunto de activos que interactúan o que están interrelacionados.
- **Activo Crítico:** Activo que tiene el potencial para impactar significativamente en el logro de objetivos de una organización.
- **Gestión de Activos:** Actividad coordinada de una organización para obtener valor a partir de los activos.

- **Plan Estratégico:** Documentación de actividades, recursos y plazos de ejecución requeridos.
- **Acción Preventiva:** Acción para eliminar la causa de una no conformidad u otra situación potencial indeseable.
- **Acción Predictiva:** A partir del monitoreo de la condición de un activo se predice la necesidad de una acción preventiva o correctiva.
- **Sistema de Gestión:** Conjunto de elementos de una organización que interactúan para establecer políticas, objetivos y procesos para alcanzar sus objetivos.
- **Sistema de Gestión de Activos:** Permite establecer la política y objetivos de la gestión de activos.

Cabe aclarar que los apartados de la normativa PAS 55, la versión anterior a la ISO 55000, están claramente incluidos en la documentación reciente si bien se ha hecho un cambio estructural asociado con la terminología estandarizada. Además se conservan los elementos clave que, en complemento con la lista de conceptos presentada anteriormente, es la referencia para la actividad de Gestión de Activos [14]:

- **Línea de Visión:** Se basa en el enfoque hacia las estrategias, objetivos, planes y actividades diarias de la organización.
- Manejo del ciclo completo de la gestión de forma **interdisciplinaria**.
- Manejo de **riesgo** y toma de **decisiones** asociadas.
- Inclusión de liderazgo, consulta, comunicación, desarrollo de la competencia y de **manejo de la información**.

En complemento con los puntos de análisis, es importante identificar la medición de desempeño de estos sistemas ya que es necesario precisar los parámetros clave y de su desarrollo a partir de los objetivos de la organización o industria. Específicamente en [15] se estableció que esta área es pobremente comprendida desde estos sectores, siendo necesario el desarrollo de indicadores de desempeño basados en los objetivos o metas de la institución.

Por ello se presenta a continuación una lista de elementos para considerar en el momento de la planeación e implementación de estos sistemas [15]:

- Diseño de estrategias y políticas de gestión.
- Análisis de demanda – creación de distribución física de activos.
- Desarrollo de planes estratégicos – Integración del sistema.

- Análisis de criticalidad de acuerdo con las necesidades del sistema.
- Justificación de las decisiones de capital.
- Planeación de contingencias y de soluciones de respaldo.
- Operación de Activos – creación de valor y mantenimiento.
- Monitoreo de la condición de los activos por medio de índices de salud.
- Registro de valor de activos en el tiempo.
- Reconocimiento de problemas de raíz del sistema.
- Desarrollo de planes continuos de desarrollo.

Estos análisis se realizaron en tres ejes de trabajo, siendo uno correspondiente a la perspectiva financiera o la que se encarga de la revisión continua del costo-beneficio de cada uno de los activos. El segundo eje, correspondiente al campo del desempeño, se basa en el desarrollo de mediciones que permitan la identificación de las entregas de los activos, como lo son la generación de eficiencia y tiempo consumido. Por último, en el eje de riesgos se considera la revisión de seguridad, confiabilidad, disponibilidad y sostenibilidad [15].




Figura 2-1.: Ejemplo de análisis de desempeño de Gestión de Activos [15]

2.2. Aplicación de la Gestión de Activos en Sistemas de Potencia

En el caso del sector eléctrico el tema de gestión de activos está cobrando importancia debido a que los transformadores actualmente instalados en los sistemas de potencia se están acercando al final de su vida útil inicial o se siguen utilizando ya pasado este tiempo [16], lo que hace necesario evaluar aspectos tales como:

- Operación en sobrecarga de los Transformadores y efecto del envejecimiento.
- Planificación de gastos en mantenimiento.
- Aseguramiento de los activos del sistema.
- Reducción de los niveles de riesgo.

Esto hace necesario que un sistema de Gestión de Activos compuesto por estos dispositivos deba presentar las siguientes propiedades, teniendo en cuenta los lineamientos presentados por [12]:

- **Holístico:** Identificación de todos los puntos de vista de los activos.
- **Sistemático:** Aplicación de manera rigurosa.
- **Sistémico:** Visión de los activos desde un punto global.
- **Basado en Riesgo:** Inclusión de los efectos de un eventual riesgo en las actividades.
- **Óptimo:** Representación del mayor beneficio técnico y tecnológico.
- **Sustentable:** Cobertura del todo el ciclo de vida del dispositivo y de sus iteraciones.
- **Integrado:** Incluir los intereses de las distintas partes involucradas.

En otras palabras, se busca lograr un diagnóstico del estado del sistema eléctrico a partir de la gestión de activos, asegurando la confiabilidad hacia el usuario final. Por este motivo se han realizado un número de estudios de revisión que hacen la comparación entre los distintos métodos de cálculo del índice de Salud en un Transformador, tal como se evidencia por ejemplo en [17], donde se consideran los componentes de un sistema de gestión de activos y una generalización del cálculo del Índice de Salud de Transformador.

Por ello se evidencia que en la Figura 2-2 se tiene como punto base para la gestión de activos en los transformadores de potencia las condiciones actuales de la instalación, información financiera, datos históricos e índices de salud del dispositivo. Estos representan los insumos

necesarios para la toma de decisiones en la flota de los transformadores. A su vez, a partir de los datos de salida, se muestra la incorporación del factor calculado a los elementos de análisis económico y de operación de todo el sistema [17].

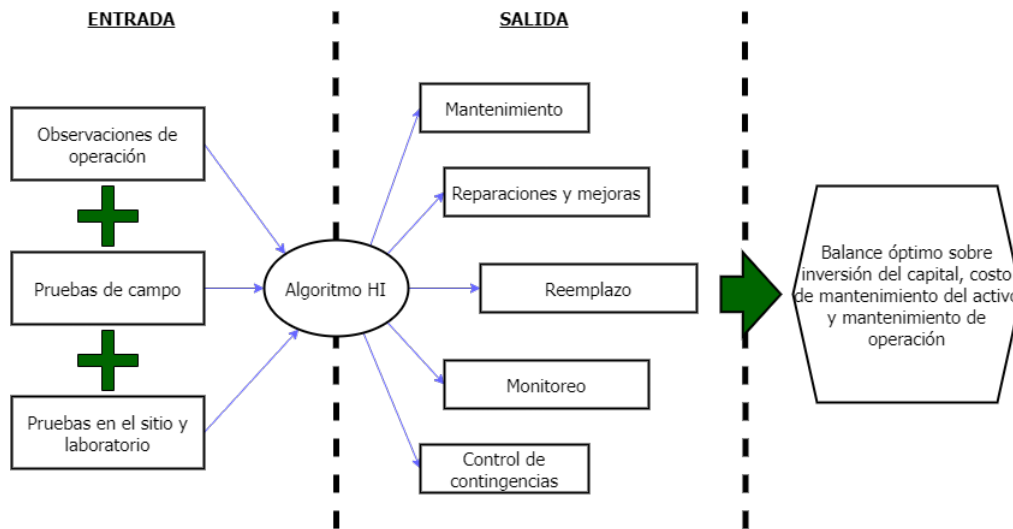


Figura 2-2.: Concepto de cálculo del Índice de Salud [17]

Específicamente en el campo de los sistemas de potencia la aplicación al pie de la letra de las normativas ISO 55000 no es posible, ya que son una referencia con la que se puede hacer un posterior traslado a un análisis técnico del sistema, siendo este último el que permite la toma de decisiones con respecto a acciones de mantenimiento, reemplazo, entre otros [18]. En la Figura 2-3 se presentan los aspectos claves propuestos en [18] para tener en cuenta en la construcción del escenario base.

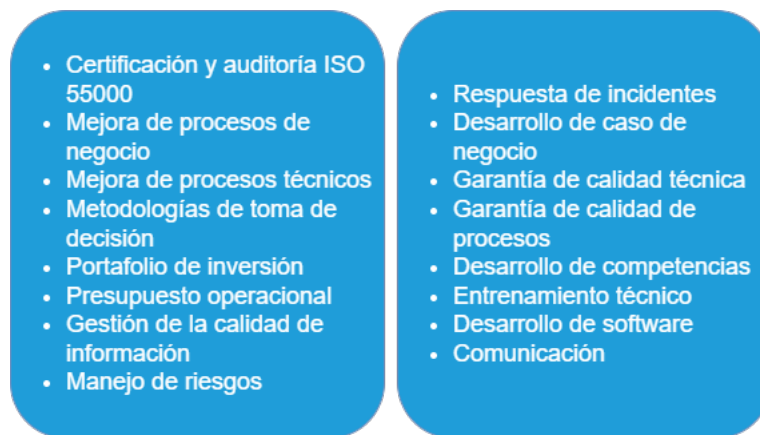


Figura 2-3.: Elementos base del sistema de gestión de activos [18]

A partir de estos elementos se propuso en [18] un resumen del ciclo de vida del transformador a partir de 7 puntos clave, resumidos en la Figura 2-4 y en la siguiente lista.

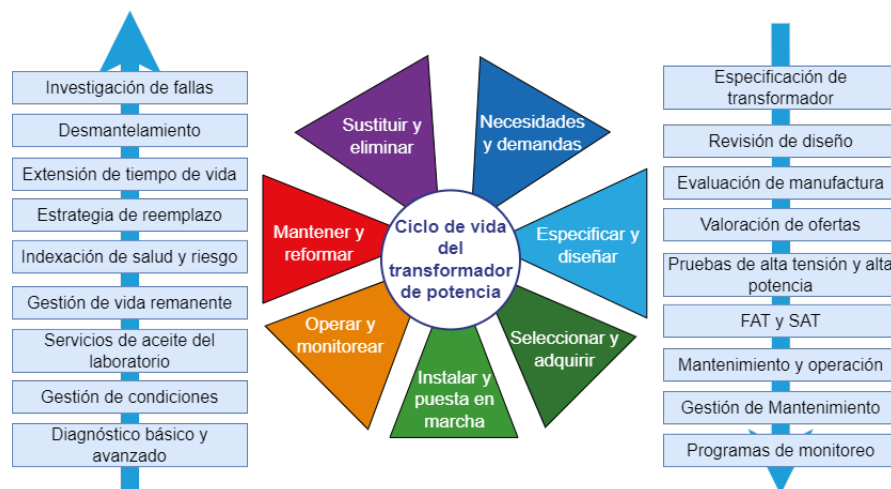


Figura 2-4.: Ciclos de Vida propuestos del Transformador de Potencia [18]

- **Necesidades y demandas:** En esta fase se evalúa el desempeño actual y futuro de la red eléctrica. El objetivo principal es la identificación de la demanda futura de energía en términos de expansión, reforzamiento o eventual reemplazo. También se definen los requerimientos del transformador basados en la evaluación del riesgo.
- **Especificación y diseño:** Se especifican los niveles de tensión y de potencia de operación en conjunto con la seguridad, ambiente y costos. Dentro de los requerimientos se puede considerar el mantenimiento, servicio óptimo, comercio, ambiente y sostenibilidad.
- **Seleccionar y conseguir:** A partir de la metodología SMART, esta componente consta de puntos de chequeo (Reportes de prueba o de aceptación de fábrica), análisis de calidad del manufacturero y posibles esquemas de instalación del transformador.
- **Instalación y comisión:** Una vez suministrados los materiales necesarios se garantizaría la instalación correcta del dispositivo involucrando al personal competente, procesos y herramientas adecuadas.
- **Operación y monitoreo:** Actividades realizadas prevenir sobrecargas, envejecimiento acelerado, mantenimiento excesivo y fallas.
- **Mantenimiento y renovación:** Basado en los niveles de riesgo estipulados, asociados con el modelo utilizado para hacer el monitoreo del dispositivo y de la información que se encuentra disponible para realizar este diagnóstico.
- **Reemplazo y disposición final:** Se toma esta decisión de acuerdo con los niveles de riesgo, acotados por las normativas IEC e IEEE si bien se puede derivar de problemas

de pérdidas de potencia en la operación, problemas en el ambiente, sobrepasar umbrales de seguridad o ausencia de una mano de obra calificada.

Como complemento en [19], el uso de la gestión de activos es clave para implementar un sistema en el cual se busque realizar un diagnóstico certero del transformador, donde se incluyen los conceptos de:

- **LCC:** Costo del ciclo de vida
- **LCM:** Gestión del ciclo de vida

Con el análisis de cada uno de estos parámetros se pueden identificar las problemáticas asociadas a la gestión de activos, en lo que se incluye el costo y la evaluación de los factores ambientales [19]. A su vez, se presenta como método de desarrollo la curva de Pareto asociada con el análisis de Montecarlo para el diagnóstico de variables que afecten el funcionamiento del sistema de potencia, en conjunto con otras metodologías como las que se presentan a continuación:

- **Teoría de Sistemas Grises:** corresponde a los sistemas con una falta información como base. Un ejemplo de ello son los mensajes estructurados, mecanismos de operación y de documentación de comportamiento [20].
- **Redes Neuronales Artificiales:** Usadas para la estimación de costos de la petición de equipos y otras aplicaciones.
- **Modelos Basados en el crecimiento de la confiabilidad:** Dado para el análisis del proceso de operación en los sistemas eléctricos.
- **Lógica difusa:** Aplicada a la estimación de LCC con el motivo de la reducción de impactos negativos asociados con una fuente limitada de información.

En esta investigación se identificaron retos y problemáticas que es necesario abarcar para el mejoramiento del desempeño de los sistemas de Gestión de Activos aplicados a los sistemas de potencia:

- Datos incompletos y opacos.
- Identificación de factores ambientales externos.
- Mejora de la precisión del cálculo de LCC.
- Estudios inadecuados en gestión de riesgos en LCM.

Asimismo en [21] se presenta un sistema de gestión construido a partir de la ponderación de importancia de los valores asociados a la calidad de vida del transformador de potencia, que se divide en los siguientes puntos:

- Análisis de estadísticas de falla
- Importancia y gestión de la condición del transformador de potencia
- Gestión de inventarios de las partes del dispositivo

Por este motivo se diseñó un sistema de Gestión de Activos basado en las normativas ISO 55000 desarrollado en la Figura 2-5, donde se analizaron los procesos asociados a la gestión de riesgos y las implicaciones técnicas y económicas de cada decisión.

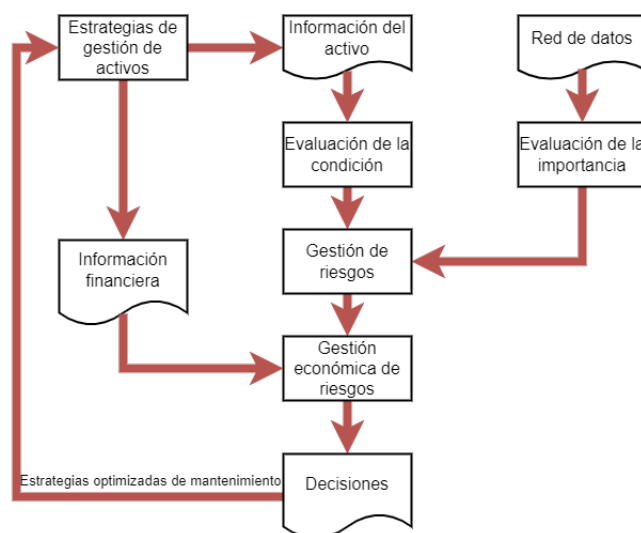


Figura 2-5.: Resumen de sistema de gestión de activos [21]

A partir de estos parámetros se desarrolló la matriz de riesgo presentada en la Figura 2-6, en la que se clasifica cada uno de los dispositivos relacionados con su condición (Actividad a realizar) y su importancia (tipos de mantenimiento implementados) [21].

	Condición			
Reemplazo	1	2	3	
Mantenimiento	4	5	6	
Inspección	7	8	9	
	CM	TBM	TBM+CBM	Importancia

Figura 2-6.: Matriz de riesgo teniendo en cuenta factores técnicos y económicos [21]

Como acercamiento de aplicación asociado con las propiedades del dispositivo se presenta en [22] la incorporación de los costos en el indicador de gestión de activos, correspondiente

al índice de salud del dispositivo, siendo conformado principalmente por las mediciones en campo y los datos históricos según se evidencia en la Tabla 2-1.

Tabla 2-1.: Niveles de desarrollo de la gestión de Activos [22]

	Datos de entrada	Nota	
Primer nivel de evaluación	Datos existentes (Información del transformador principal, historia de mantenimiento, datos de medición) / Clasificación inicial de la flota y creación de clusters para los siguientes pasos		
Segundo nivel de evaluación	Data de encuestas en campo / evaluación detalla de las condiciones de la flota para los clusters escogidos	No se requiere corte de energía	
	Inspección visual y pruebas no disruptivas		1. Análisis del aceite
			2. Análisis de Gases Disueltos
			3. Análisis de furanos
			4. Temperatura /Termografía
			5. Medición de descarga acústica parcial
			6. Vibro-acústica
7. Análisis de corriente del motor			
Tercer nivel de evaluación	Datos de las pruebas disruptivas / Condiciones más profundas de gestión de las unidades seleccionadas	Se requiere corte de energía. Unidades sospechosas o evaluación más profunda de candidatos de reemplazo	
	8. Resistencia de devanados		15. Corriente de magnetización
	9. Impedancia de corto circuito		16. SFRA
	10. Relación de vueltas		17. Medición PDC/FDS
	11. Resistencia del aislamiento		18. Medición de resistencia dinámica
	12. Factor de potencia		19. Desgaste por contacto
	13. Capacitancia		20. Medición de vibraciones
	14. Prueba Nucleo-Tierra		

Teniendo en cuenta este desarrollo se identificaron dos indicadores, donde uno corresponde al cálculo del índice de salud del transformador mientras que el otro se compone del mantenimiento [22]. A partir de ellos se construyó una matriz de riesgo como la presentada en la Figura 2-7, con el objetivo de clasificar los componentes de una flota y poder tener las herramientas necesarias para definir un mantenimiento o reemplazo futuro.

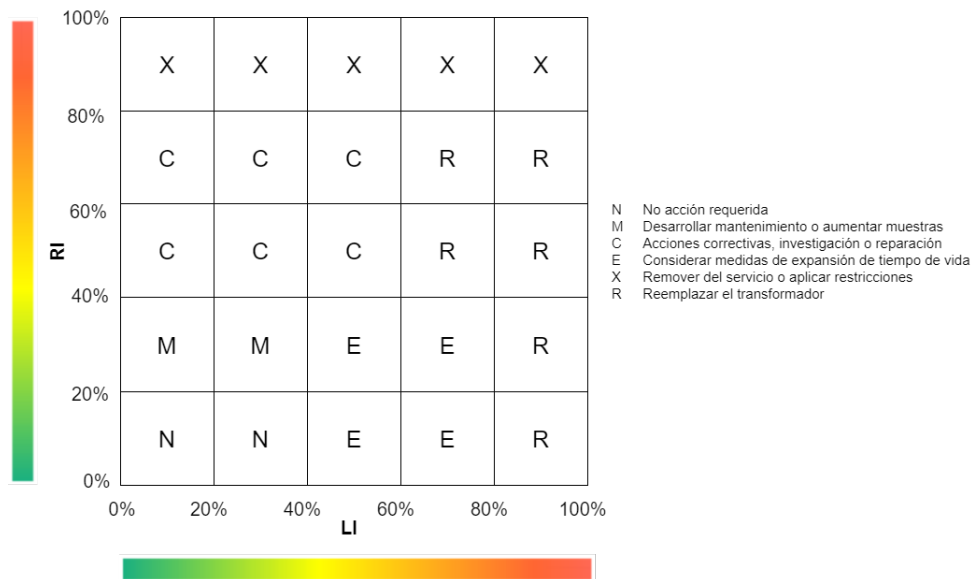


Figura 2-7.: Matriz de cálculo de condiciones [22]

2.3. Aplicación para transformadores de potencia

A partir de los modelos de gestión de activos en los sistemas de potencia se reconoció la necesidad de identificar los avances con respecto al diagnóstico de tiempo de vida del transformador, ya que de este valor depende la toma de decisiones asociadas con el mantenimiento o de reemplazo de estos activos.

En primera instancia en [23] se realizó un análisis del estado de degradación de un transformador teniendo en cuenta los procesos de oxidación, hidrólisis y pirólisis en el papel aislante del dispositivo y de la estimación de este parámetro por medio del Grado de Polimerización, que en un transformador comienza en un nivel de 1200 hasta un punto crítico de 200, donde ya no puede soportar el estrés mecánico y por ende se aumentan las probabilidades de una falla importante [23].

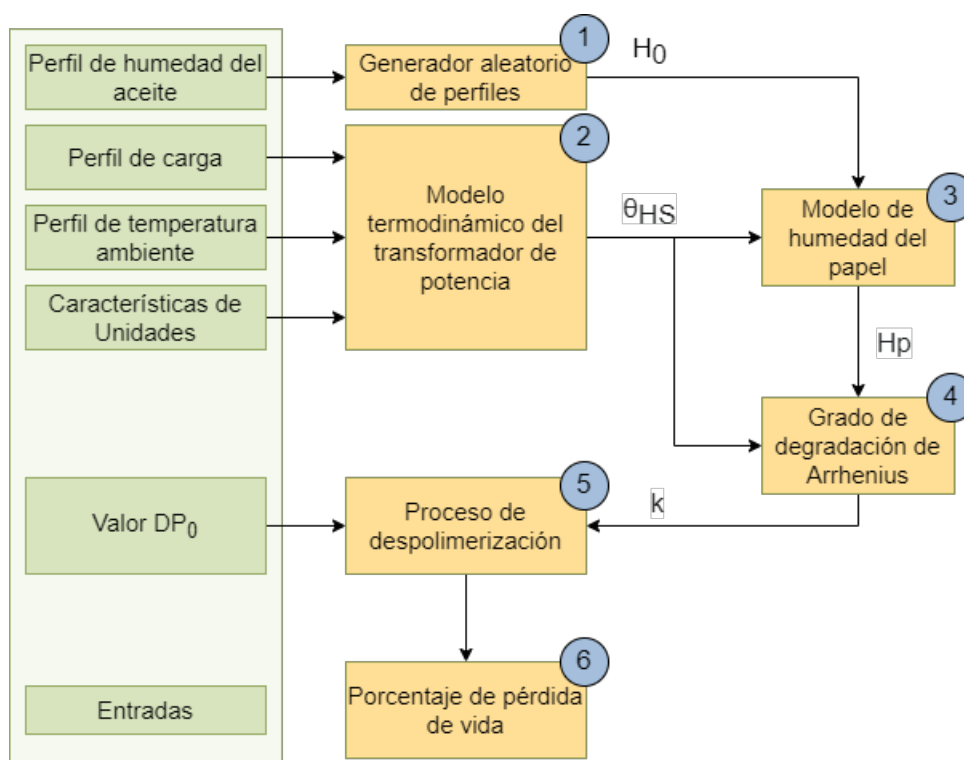


Figura 2-8.: Cálculo final de la pérdida de vida del transformador [23]

Por este motivo se desarrolló una metodología en la cual se toma en consideración la influencia de la humedad en la degradación, cambios de temperatura y sus valores máximos en el proceso de envejecimiento del transformador a partir de los siguientes puntos [23]:

- **Método de estimación de humedad en el aceite:** Dependiente de la disponibilidad de medición de la humedad en el mineral. No obstante, asumiendo que la unidad tiene

un sellado adecuado se pueden aplicar fórmulas para estimar la contaminación de partículas de agua dentro del tanque [24].

- Nuevo acercamiento de la estimación de degradación:** En primera instancia se genera un perfil de humedad aleatorio, obteniendo posteriormente el punto más caliente del transformador, humedad del papel, la tasa de degradación y la gestión del grado de polimerización que lleva al cálculo de la estimación de pérdida de vida útil.

Por otro lado, en el método práctico de la evaluación de riesgo presentado en [25] se propone una forma nueva de hacer la estimación de la Probabilidad de Falla y el factor de consecuencia del Transformador (TRI), respondiendo preguntas acerca de cuál es la mejor acción para cada activo de la flota y de cuáles serían sus costos asociados. Por este motivo se requiere la mayor cantidad de información para dar las herramientas adecuadas para la toma de decisiones según el esquema presentado en la Figura 2-9.

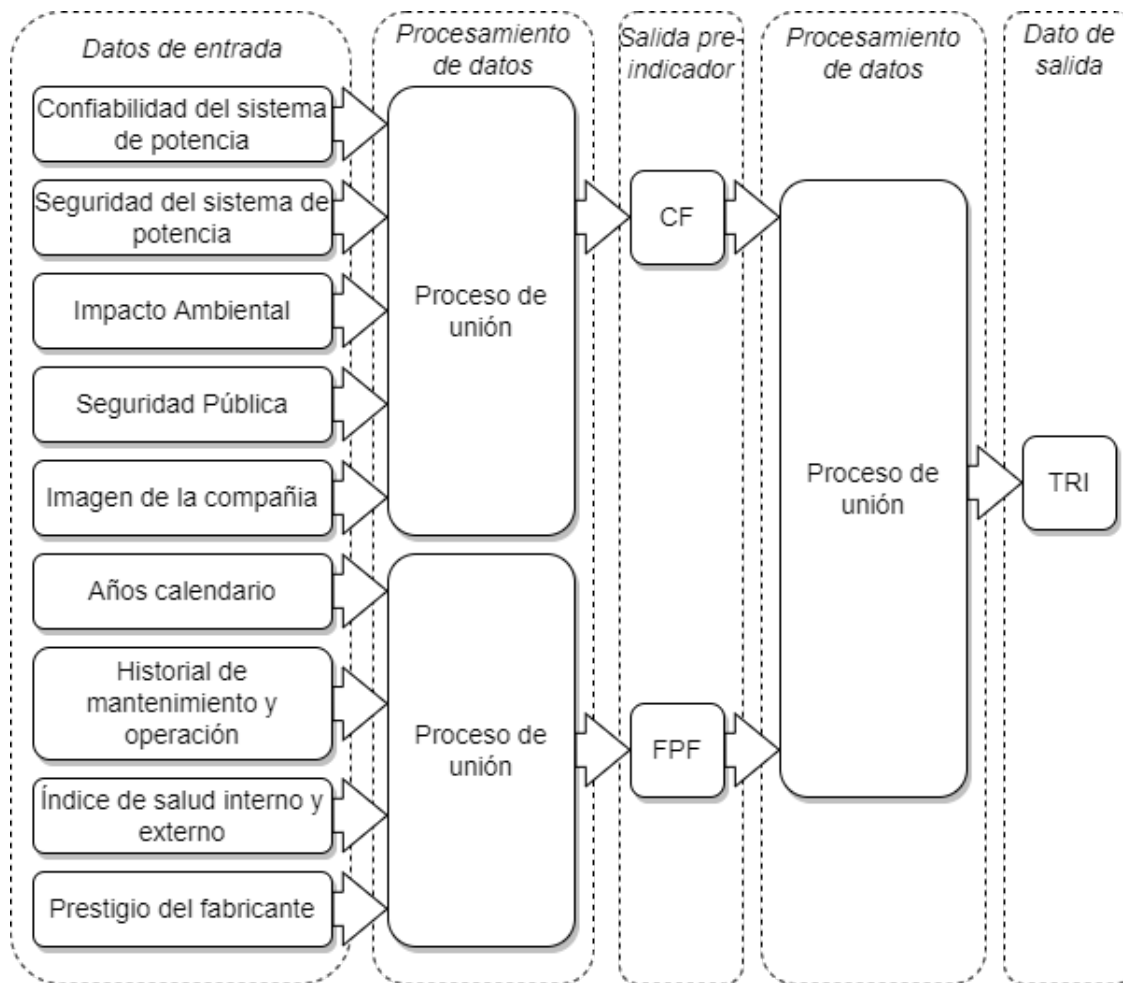


Figura 2-9.: Esquema metodológico para la gestión de riesgo en los activos [25]

Dentro de este procedimiento se consideran las variables del ambiente tales como el impacto

ambiental, la salud pública, seguridad y confiabilidad del sistema de potencia dentro del Factor de Consecuencia. A su vez, se utilizan los datos históricos de operación del transformador, índice de salud externo e interno con el prestigio asociado al fabricante para el cálculo de la Probabilidad de Falla (FPF) [25]. Para cada elemento se examinaron distintos factores a partir de los siguientes sistemas:

- Gestión de activos a partir del factor de consecuencia y el riesgo [26].
- Análisis de la gestión de los transformadores de potencia en valor económico [27].
- Gestión del ciclo de vida de los transformadores en la industria de potencia [28].
- Procedimiento práctico para el reemplazo de transformadores a partir de la condición actual y del nivel de riesgo [29].

Los resultados de cada uno de los métodos se relacionaron a partir de una matriz de riesgo, en la cual se hizo un proceso de clasificación de los transformadores analizados en esta investigación utilizando el método de clústeres resumido en la Figura 2-10:

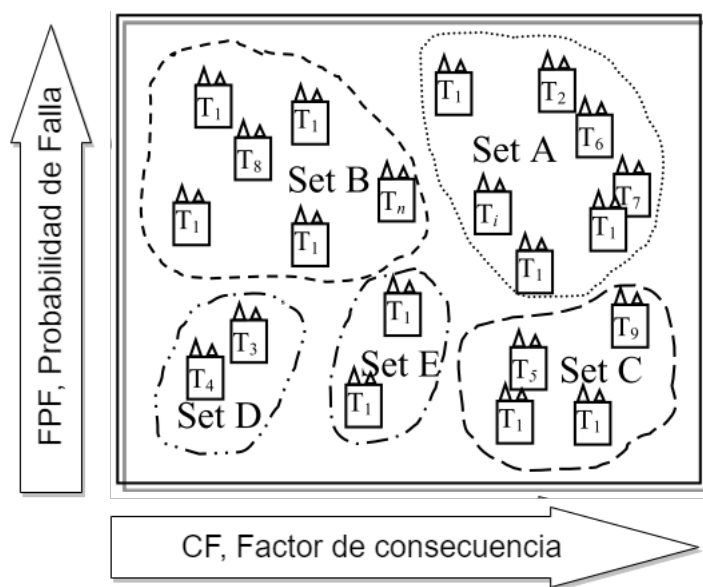


Figura 2-10.: Organización de transformadores analizados [25]

Por último, los datos que se tomaron en cuenta para los análisis fueron los siguientes:

- **Gases disueltos en el aceite:** Total de gases combustibles disueltos en el material aislante (TDCG).
- **Contenido de furanos:** Representado por el Grado de Polimerización del papel del que se compone el aislamiento del transformador de potencia.

- **Tensión de ruptura:** Valor de umbral para la identificación de descargas parciales, asociada con las condiciones del aislamiento.
- **Contenido de Agua:** Partículas de agua mezcladas con el aceite aislante del dispositivo.
- **Número de neutralización:** Medición de la acidez total del aceite.
- **Factor de Disipación:** Medición de las pérdidas dieléctricas.

Asociado con el parámetro de Gases Disueltos, en el modelo propuesto en [30] desarrolla un sistema que permite el monitoreo en tiempo real de las condiciones del transformador y predicción de fallas aplicando redes neuronales, con motivo de mejorar el reconocimiento de las condiciones de este dispositivo a partir de un número reducido de información.

La variable utilizada para el cálculo del tiempo de vida útil del transformador corresponde a la cantidad de gases disueltos en el aceite, utilizando las redes neuronales para la reducción del tiempo de procesamiento de los datos e implementar de forma rápida los respectivos procesos de mantenimiento [30]. En la Figura 2-11 se muestra la arquitectura de esta red, cuya entrada corresponden a un conjunto de estos gases y que, luego de un procesamiento por medio de capas ocultas, clasifica la condición del transformador.

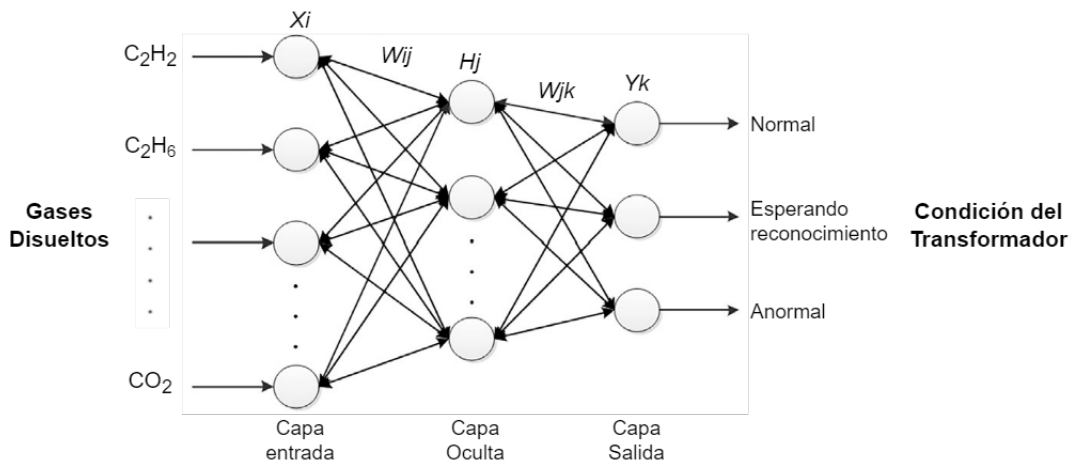


Figura 2-11.: Red neuronal para cálculo de probabilidad de fallas en el transformador [30]

Una derivación de este análisis se realizó a partir del cálculo de la correlación entre cada tipo de gas por medio del método Kaiser-Meyer-Olkin presentado en [31] y de los componentes principales de operación [30], dando como resultado el diagrama de la Figura 2-12, que muestra el esquema de predicciones de falla en el transformador en tiempo real.

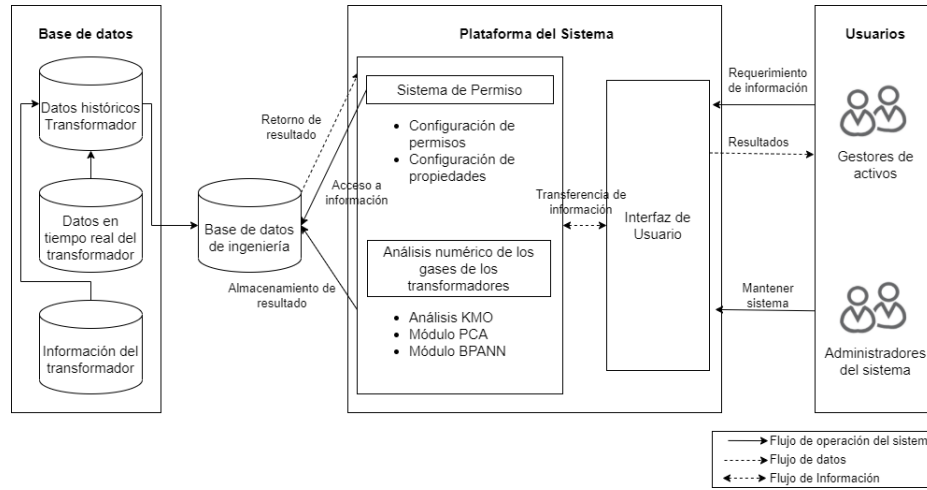


Figura 2-12.: Ejemplo de un sistema de monitoreo inteligente [30]

Por otro lado, como se evidencia en [32], en el mantenimiento de los transformadores se presenta un grado de incertidumbre asociado con la identificación del estado de vida del transformador, dificultando aspectos tales como la identificación del reemplazo de sus componentes y de costos de mantenimiento. Esta incertidumbre se identificó en las pruebas de la medición de los parámetros de calidad, por lo que en dicha investigación se complementaron los análisis tradicionales con modelos basados en la probabilidad bayesiana, con motivo del reconocimiento de una estrategia óptima para la toma de decisiones.

Dicho análisis se realizó con una cantidad limitada de información, siendo el nivel de riesgo el punto de referencia. A partir de esto se construyó el esquema de la Figura 2-13, donde se presenta un diagrama de influencia que expone la línea de acción para la gestión del transformador de potencia.

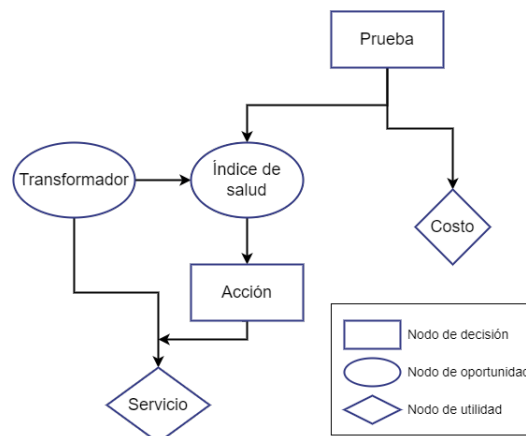


Figura 2-13.: Diagrama de influencia para índice de salud del transformador [33]

De acuerdo con la comparación con modelos de Gestión de Activos existentes se evaluó la correlación entre el contenido de partículas de agua en el aceite aislante del transformador medidas en partes por millón, acides del aceite, tensión de ruptura, gases combustibles disueltos, medición de furanos, factor de disipación, entre otros.

A su vez, en [34] se desarrolló la gestión de los transformadores de potencia a partir de distintos sensores comunicados a partir de un sistema de monitoreo para transformadores de potencia (NSET por sus siglas en inglés), que consiste en una unidad local a la cual se conectan los sensores con fibra óptica mientras que cada uno tiene su configuración exclusiva de red en el marco de un sistema de Supervisión y Adquisición de datos (SCADA) tal como se muestra en la Figura 2-14.

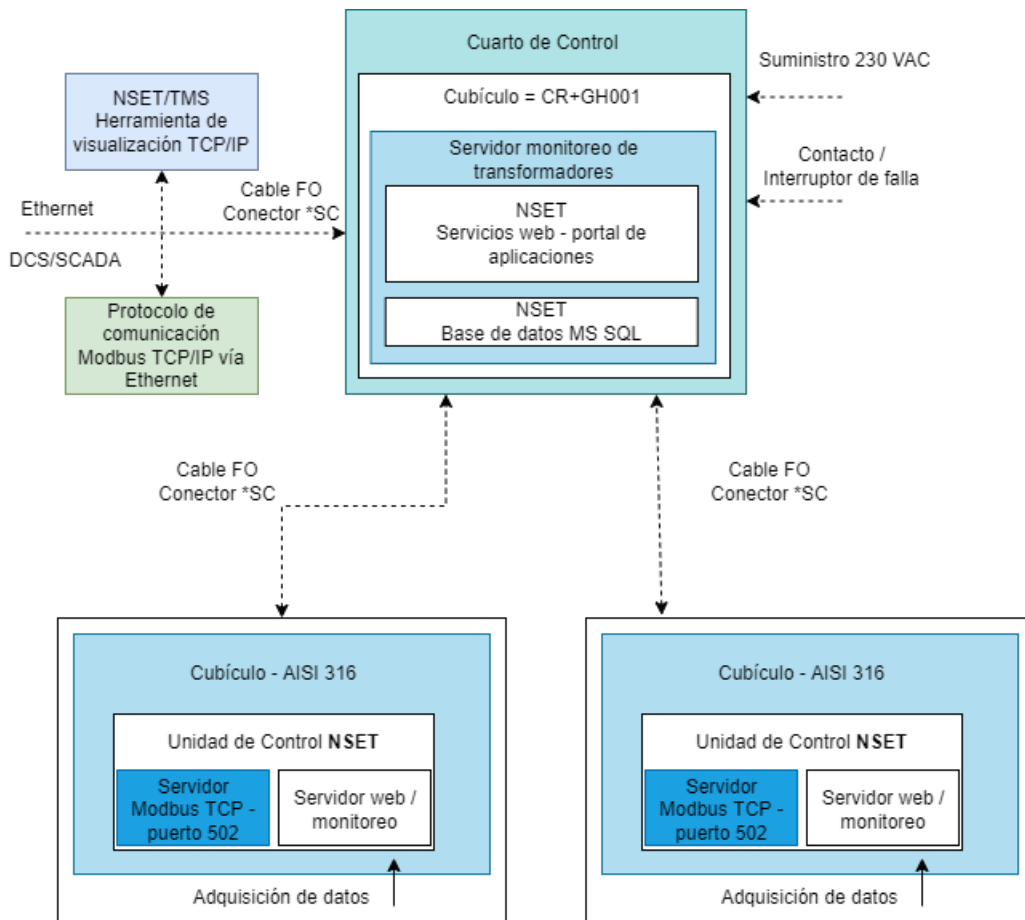


Figura 2-14.: Sistema de monitoreo NSET [34]

En este sistema se procesa la temperatura del aceite y del ambiente, concentración de gases y humedad en el aceite en conjunto con las mediciones de calidad de potencia tales como el voltaje, corriente, posición de tomas del transformador y señales de control. Con esta información se calcula la potencia aparente, factor de potencia, sobrecarga si existe, enve-

jecimiento del aislante, temperatura de punto caliente y maniobras, teniendo en cuenta la normativa IEC 60076-7 [34].

Por otro lado en [35] se presenta la importancia de la reducción de costos en la gestión del transformador, proceso que se realiza a través de un ahorro en las actividades de mantenimiento con la menor afectación en la confiabilidad. Por ello, se resalta la importancia del monitoreo del ciclo de vida utilizando las herramientas necesarias para una toma de decisiones adecuada, conllevando a la presentación en la Figura 2-15 de los distintos factores del transformador que influyen la operación.

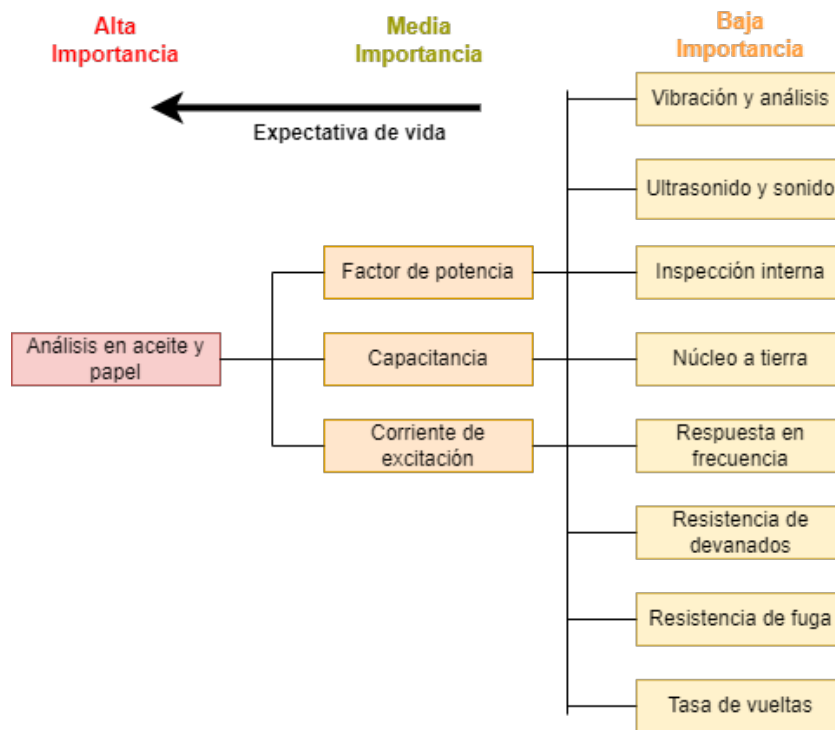


Figura 2-15.: Parámetros de referencia de análisis de condición de transformador [35]

A partir de esta información se identificaron los diferentes exámenes para el diagnóstico del transformador de potencia, entre los que se encuentran:

- Calidad del Aceite (Contenido de humedad, fuerza dieléctrica, oxígeno)
- Calidad del papel aislante - Grado de Polimerización
- Corriente de excitación, núcleo a tierra, vibración, pruebas de ultrasonido, capacitancia, entre otras.

Con esta información se propone calcular la probabilidad de falla de los estos dispositivos considerando una función construida con parámetros del estrés eléctrico, mecánico y térmico relacionados con la afectación del tiempo de vida remanente [35].




Figura 2-16.: Función de probabilidad de falla para un conjunto de transformadores [35]

Por su parte, en la investigación consignada en [36] se busca obtener un valor numérico que represente el índice de salud en un transformador con un número reducido de datos, derivados de los exámenes que buscan identificar la calidad del aceite aislante de este dispositivo. Por ello se realiza en la operación de tiempo real un monitoreo y gestión de condiciones especial para la aplicación de métodos de predicción.

El valor de referencia o índice de salud se calculó a partir del análisis de gases disueltos (DGA), calidad del aceite aislante (OQA) y de nivel de furanos (FFA) para la construcción de la clasificación de los transformadores tal como se presenta en el gráfico de la Figura 2-17.

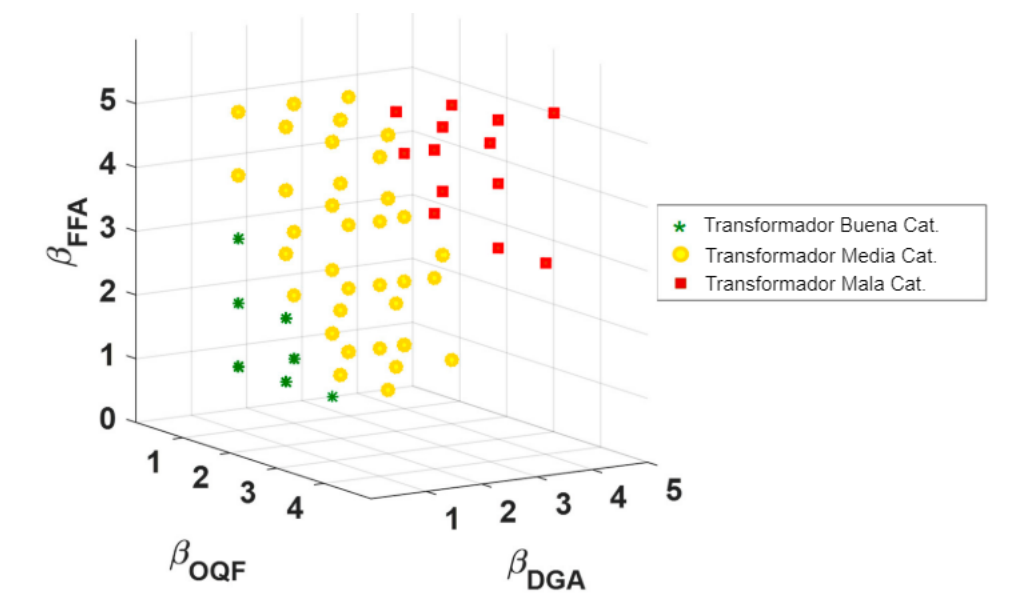


Figura 2-17.: Representación en tres dimensiones de los transformadores analizados en [37]

Posteriormente se utilizaron sistemas basados en el aprendizaje de máquina para poder hacer la determinación del índice de salud a partir de un conjunto inicial de datos reducido, como

lo son las redes neuronales artificiales, regresión logística, método Naïve-Bayes, entre otros.

Luego de las simulaciones se obtuvieron resultados con una precisión cercana al 96 % entre el análisis con los datos totales y el índice calculado a partir de información reducida, mostrando ser una alternativa para hacer el diagnóstico del estado de una flota de transformadores sin perder la confiabilidad del resultado [37].

Asociado con los requerimientos mínimos de información, en el documento desarrollado en [38] se desarrollaron dos modelos basados en la búsqueda de la estimación de parámetros con los que se obtenga un diagnóstico preciso de la calidad del transformador de potencia sin la necesidad de un número considerable de pruebas en el sistema de transmisión y distribución de Polonia, donde ya existe un método realizado por la empresa de monitoreo denominado TrafoGrade que depende de un conjunto de pruebas en donde se debe desconectar momentáneamente estos dispositivos.

El primer modelo de índice de salud considera cuatro categorías, donde cada una tiene un diagnóstico propio y un peso asignado para la obtención de un indicador global como se presenta en la Tabla 2-2:

- Propiedades fisicoquímicas del Aceite (HI_{OIL})
- Contenido de Gases Disueltos en el Aceite (HI_{DGA})
- Condición del aislamiento sólido de los devanados (HI_{ISO})
- Historia de Trabajo de la unidad (HI_{AGE})

Tabla 2-2.: Factores del índice de salud 1 analizado en [38]

Categoría (HIj)	Peso (kj)
HI_{OIL}	0,0699
HI_{DGA}	0,0946
HI_{ISO}	0,2661
HI_{AGE}	0,5695

En el segundo indicador se tienen en cuenta las mismas propiedades, pero se hace un desglosamiento de los pesos de los parámetros en que se dividen los factores, resumido en la Tabla 2-3.

En el análisis se evidenció que el segundo índice de salud fue el que más se acercó a los datos obtenidos por el algoritmo con mayor información utilizado por el operador de red pero con

un coste total menor ya que en esta última se requiere realizar maniobras de desenergización en el transformador por unas horas para poder hacer la toma de de información, lo que supone unos costos elevados y una afectación al sistema de distribución [38].

Tabla 2-3.: Factores del índice de salud 2 analizado en [38]

Categoría	Parámetro	Peso
Propiedades psicoquímicas	Acidez	0,0776
	Factor de pérdida	0,0573
	Contenido de agua	0,0241
	Tensión de ruptura	0,0258
Análisis de gases disueltos	Hidrógeno (H_2)	0,1042
	Metano (CH_4)	0,0488
	Etano (C_2H_6)	0,0163
	Etileno (C_2H_2)	0,0488
	Acetileno (C_2H_2)	0,1074
Envejecimiento de celulosa	Óxido de carbono (CO)	0,0471
	Dióxido de carbono (CO_2)	0,0471
	Furanos (2-FAL)	0,2199
Coeficiente de edad	Edad	0,1756
	Carga del transformador	
	Historia de operación	

Como método de simplificación en [39] el estado del transformador se define como sano o no sano, lo que corresponde a una clasificación binaria, y por ende se pueden utilizar otra variedad de sistemas. El análisis realizado en el artículo toma como referencia la construcción de un sistema de redes neuronales basado en la relación estadística entre cada uno de los parámetros a medir, que en el caso de un transformador de potencia corresponden a los siguientes:

- Tensión de Ruptura del Aceite
- Contenido de 2-Furfuraldehido
- Gases disueltos combustibles
- Acidez total de aceite
- Factor de Disipación
- Contenido de agua en el aceite

Posteriormente esta información se usa como entrada para un sistema de regresión logística que, luego del tratamiento a partir de una red neuronal entrenada con datos históricos, asigna alguna de las dos categorías a los transformadores analizados siguiendo un esquema similar al presentado en la Figura 2-18.

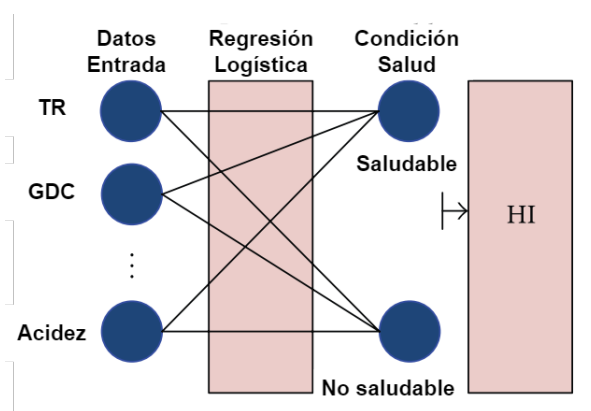


Figura 2-18.: Ejemplo de modelo de regresión logística y red neuronal para HI [39]

Con estos resultados se procedió a eliminar los factores que no afectaron de forma significativa al resultado final del índice de salud, obteniendo una reducción a solo 4 parámetros:

- Gases Disueltos Combustibles
- Tensión de Ruptura
- Acidez del Aceite
- Contenido de 2-Furfuraldehído

Por otro lado, para el caso de los transformadores que operan con tensiones entre 69kV y 230kV dados en [40] se tuvo en cuenta los parámetros de referencia sugeridos según las normativas del IEEE e IEC anteriormente citadas por medio de la creación de funciones de membresía en el marco de lógica difusa, que relacionan un concepto con un valor numérico. Este índice de salud representa la degradación del transformador de potencia, con la presencia de un alto grado de subjetividad dado por la opinión de expertos. Esto lleva a que sea difícil la comparación de los resultados finales con otros modelos [40].

En esta metodología se consideraron los siguientes parámetros, donde cada uno tiene asignada una función de membresía construida según los lineamientos de normativas internacionales en conjunto de opinión de expertos:

- Rigidez dieléctrica [kV]

- Factor de disipación [%]
- Acidez o Número de neutralización [mg KOH/g]
- Análisis del contenido de furanos [ppm]
- Análisis de Gases Disueltos [ppm]
- Contenido de Humedad [ppm]

Luego del establecimiento de las reglas difusas entre elementos se obtiene la función de membresía del índice de salud final tal como se resume en la Figura 2-19.:




Figura 2-19.: Función de membresía del índice de salud para un transformador de alta tensión [40]

A partir de este análisis se identificó la importancia del grado de polimerización en el resultado final, estipulando una necesidad de mejorar la asignación del peso de cada componente y de las reglas de la lógica difusa para la disminución de la subjetividad, mientras se recalca la necesidad de incorporar el comportamiento histórico del transformador.

Por otra parte, en el modelo presentado en [41] se implementó un sistema de diagnóstico construido a partir de la unión de pruebas periódicas y las propiedades cerámicas de las subestaciones. El índice de salud asociado es definido de acuerdo con la ubicación de la subestación, las pruebas de desempeño realizadas en laboratorio y el nivel de carga de los rayos de la zona. Las variables consideradas se presentan en la siguiente lista, teniendo en cuenta que los límites de operación están basados en la normativa del IEEE [41]:

- Análisis de gases disueltos en el aceite
- Condiciones térmicas del transformador y los efectos asociados con la degradación del aislante

- Condiciones mecánicas medidas en el sitio de operación
- Análisis de las condiciones del aislamiento

A su vez, hay otros parámetros que por su naturaleza y variabilidad son difíciles de incorporar al cálculo del indicador, como lo son las maniobras, variaciones en la demanda, temperaturas que requieren métodos invasivos para su medición y condiciones externas del ambiente. Por esto, el indicador propuesto por [41] hace la suma del resultado de cada análisis y lo divide en el número máximo que se puede obtener como un método ponderado, con un resultado obtenido entre 0 y 1 como se ilustra en la Figura 2-20 [41].




Figura 2-20.: Resultados de aplicación del indicador de salud presentado en [41]

Entre más cercano sea el valor del índice de salud a 1 representa una peor condición del transformador, siendo una herramienta que sirve como insumo para el desarrollo de actividades de mantenimiento del dispositivo.

Como complemento, en el análisis del estado del transformador con disponibilidad de una amplia gama de datos de operación tal como se estipula en [42], se construyó un modelo en el que se realiza un análisis individual del estado de los transformadores presentes en una flota basados en el factor de riesgo [42]. Los datos utilizados provienen de las siguientes pruebas a los componentes base del dispositivo:

- Factor de Disipación
- Inspección visual de los elementos mecánicos
- Pruebas de calidad del Aceite
- Análisis de Gases Disueltos

- Termografía infrarroja
- Resistencia del aislamiento

Después, a cada uno de los resultados se le asigna un peso para el cálculo de un índice de salud global, en el se tiene en cuenta tanto la ponderación de cada dato siguiendo los lineamientos de los otros métodos presentados anteriormente como la conversión de importancia relativa dividida entre el cambiador de tomas del transformador (40 %) y del resto de variables del dispositivo (60 %) tal como se evidencia en la siguiente fórmula:

$$HI = 60\% \frac{\sum_{j=1}^{21} K_j HIF_j}{\sum_{j=1}^{21} K_j} + 40\% \frac{\sum_{j=22}^{24} k_j HIF_j}{\sum_{j=22}^{24} 4K_j} \tag{2-1}$$

Finalmente se obtiene una gráfica que muestra la relación entre la probabilidad de falla y el puntaje del índice de salud. A su vez, en la investigación se propone hacer una remoción inicial de las condiciones que se mantienen constantes en el tiempo de la flota para luego estimar la probabilidad de falla actual, calcular la vida remanente de los dispositivos y por último sumar los costos de todos los que estén cerca del final de su vida útil por año [42].

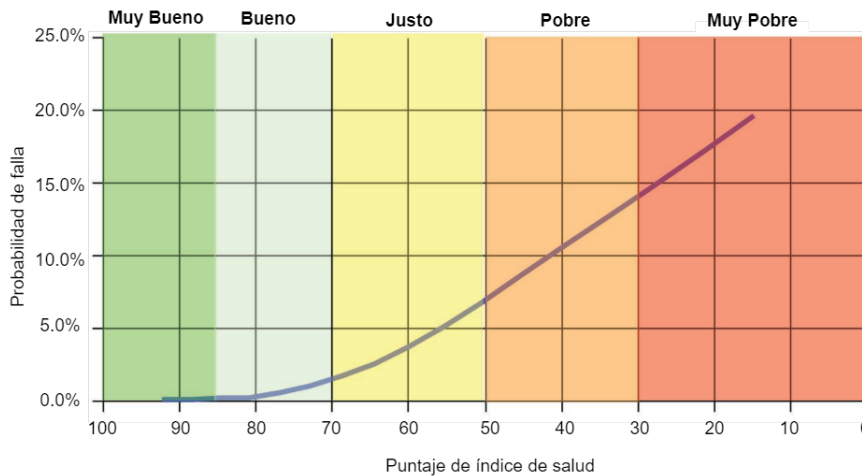


Figura 2-21.: Estimación de probabilidad de falla basada en el índice de salud [42]

Asociado a este tipo de aplicaciones, en [43] se desarrolló un modelo de lógica difusa que tiene como base un sistema de diagnóstico de parámetros tales como la historia de operación y mantenimiento, en conjunto con las consideraciones del ciclo de vida y de la medición de valores que representan la calidad de potencia.

En la Figura 2-22 se presenta un componente de este sistema, construido en la herramienta de Simulink en Matlab del análisis del estado del dispositivo considerando las concentraciones de gases disueltos. Este método de diagnóstico se desarrolla en otras capas, asociados al

cálculo del valor numérico final del indicador, teniendo como referencia los valores críticos allí expuestos [43].

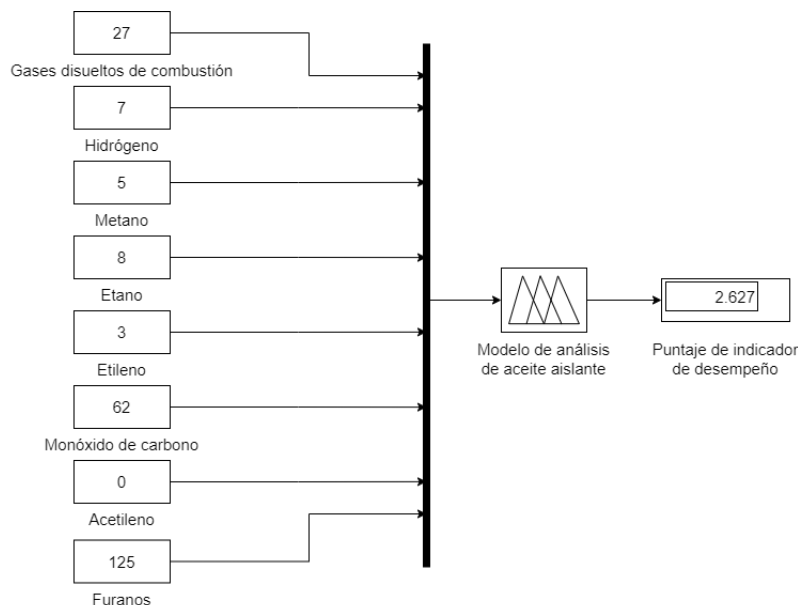


Figura 2-22.: Modelo de ejemplo de lógica difusa para cálculo de índice de salud [43]

Por último se presenta en [44] un ejemplo de cálculo del estado de un transformador de distribución, teniendo en cuenta el voltaje del lado de baja tensión, corriente y nivel del aceite aislante. Este análisis se realizó considerando un conjunto de funciones de membresía acotadas por normativas internacionales que se presentan como una alternativa para la identificación del estado de operación de estos dispositivos. En la Figura 2-23 se presenta el sistema de medición y de la ubicación del módulo de lógica difusa.

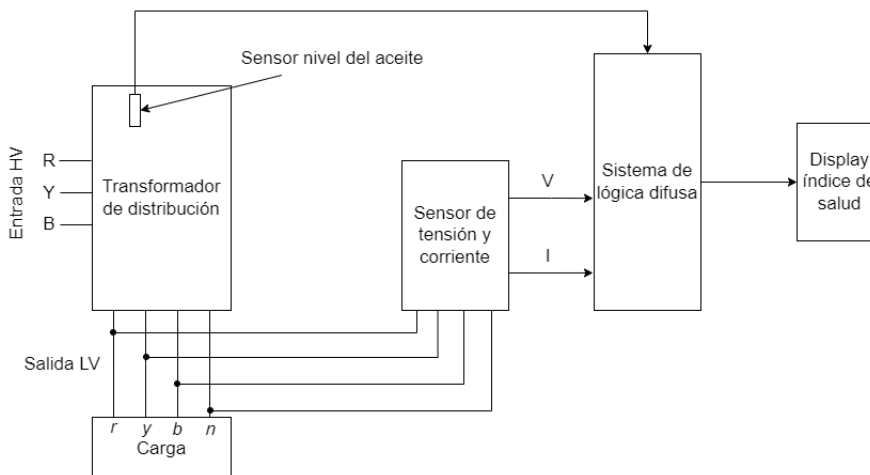


Figura 2-23.: Conexiones para medición de parámetros de modelo de lógica difusa [44]

A partir de la revisión de estos modelos se identificaron los diferentes enfoques con los cuales se abarca el problema de gestión de activos en transformadores, lo que dificulta el desarrollo de un marco de trabajo común que se pueda utilizar en sistemas en los cuales no se disponga de una amplia gama de información, en especial la recolectada con pruebas que requieren que el dispositivo esté momentáneamente fuera de operación. En la siguiente sección se presentará la definición de algunos sistemas de clasificación y predicción con el objetivo de construir un indicador global de desempeño de un transformador de distribución.

3. Modelos de predicción y clasificación

Como punto de referencia para el desarrollo del modelo basado en gestión de activos se consideró la revisión de los esquemas de predicción actualmente implementados en la literatura, asociados con la disponibilidad de información propia de las mediciones en tiempo real de la condición de los transformadores de potencia y en general de los sistemas de distribución. A su vez, se tuvieron en cuenta las metodologías de clasificación aplicadas a los sistemas de potencia en general, basados en la disponibilidad de información y de las necesidades de diagnóstico.

3.1. Redes Neuronales

Las redes neuronales son modelos matemáticos conformados a partir de algoritmos de aprendizaje, basados en la manera que el cerebro humano almacena información. Este término es utilizado en el campo científico para clasificar el grupo de métodos que permiten a los computadores aprender a partir de la información que proviene de sistemas de medición conformados por sensores y otra variedad de elementos especializados en IoT, Big data, entre otros [45].

A su vez, estos sistemas se pueden construir a partir de distintas topologías, dadas por la variación de conexiones entre neuronas y el tratamiento de la información. Entre estos tipos se encuentran las siguientes categorías [46], presentadas en la Figura 3-1:

- (a) **Conexión feedforward:** Correspondiente a la conexión de neuronas en forma lineal, normalmente organizada a partir de capas. Las neuronas de las mismas capas no se conectan entre sí.
- (b) **Red recurrente:** En ella se encuentra mínimo un lazo de retroalimentación.
- (c) **Red de celosía:** Consiste en arreglos de varias dimensiones de neuronas donde cada una tiene unas entradas asociadas.
- (d) **Conexión feedforward de varias capas:** Variación de la conexión feedforward en la cual si existen conexiones de neuronas de las mismas capas.

- (e) **Red celular:** Se desarrolla a partir de neuronas espaciadas, denominadas celdas, que se encuentran conectadas con sus vecinos inmediatos, cada una teniendo su propia señal.




Figura 3-1.: Diferentes tipos de arquitecturas de redes neuronales [46]

Estas redes neuronales gracias a su configuración, basada en las neuronas como nodo computacional, tienen la capacidad de aprender de forma adaptativa, generalizar de forma superior, desempeñarse como una caja negra natural y, en algunos casos, de organizar su propia arquitectura. Por último, tienen la capacidad de ser ejecutadas en distintos tipos de procesamiento computacional y de tratar de forma efectiva los problemas asociados a ruidos en la información y a los fallos en cualquier parte del proceso de diagnóstico [46].

En el campo de aplicaciones de redes neuronales en sistemas de potencia se identificó primeramente en el análisis realizado en [47] las necesidades encontradas de realizar un diagnóstico diario de las condiciones de los transformadores de potencia, teniendo en cuenta los efectos de volatilidad de las energías renovables no convencionales, resumido en el esquema de la Figura 3-2. A su vez, se presentaron las claves para poder implementar los sistemas de inteligencia artificial en el caso de los sistemas de potencia, especificando que la información juega un papel importante para el entrenamiento de estos sistemas.

Por ejemplo, en [48] se hace una reducción de los parámetros utilizados en el diagnóstico del transformador de potencia, tomando como referencia los datos obtenidos de la medición de gases disueltos del dispositivo y de la necesidad de reducir el costo computacional. Dicho análisis se enfocó hacia la aplicación del sistema de gestión de activos por parte de los operadores de red.

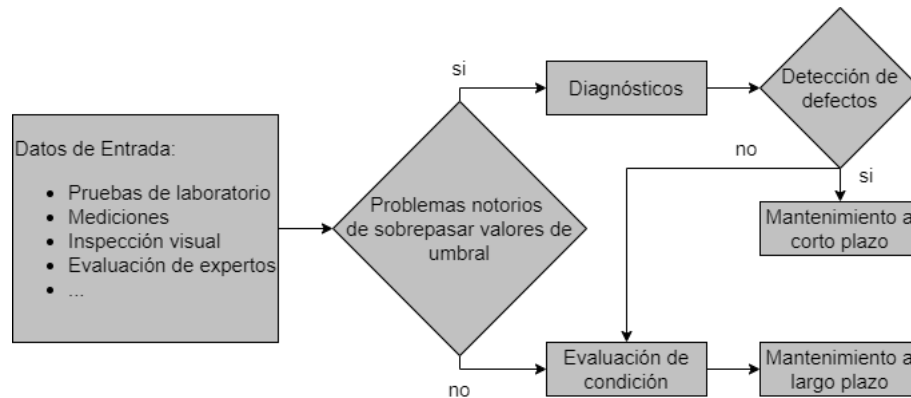


Figura 3-2.: Parámetros de análisis de modelos de diagnóstico [47]

Específicamente en la red neuronal propuesta se calculó el Error Absoluto Medio Porcentual (MAPE por sus siglas en inglés) para identificar los datos que se podrían omitir sin disminuir la precisión del indicador final. No obstante, continúa siendo una aplicación respaldada en un conjunto importante de datos iniciales, en especial de las concentraciones de gases disueltos, que se encuentran asociados a pruebas de calidad del dispositivo tal como se evidencia en el sistema de cálculo del índice de salud en la Figura 3-3 [48].

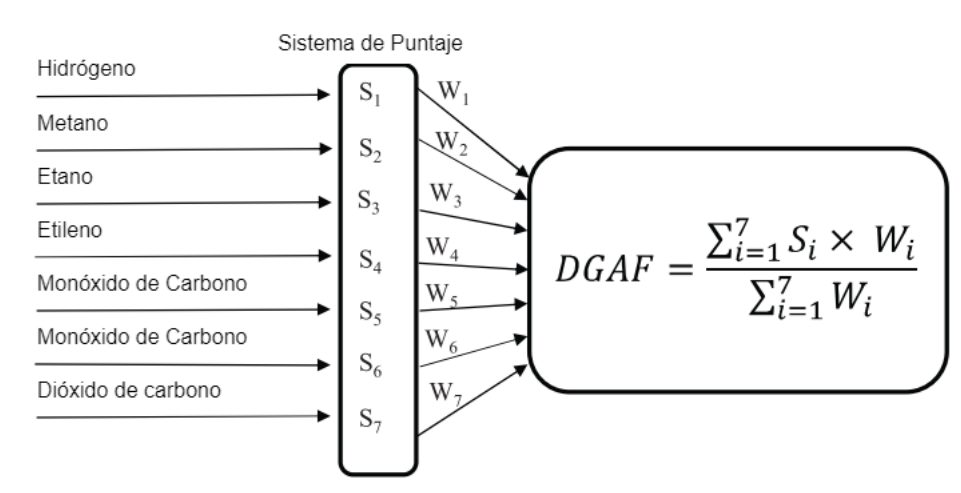


Figura 3-3.: Ejemplo de cálculo de indicadores de HI con base en ponderación y redes neuronales [48]

En [49] se muestra la aplicación de una red neuronal compuesta de 1 capa oculta, en la cual se busca realizar la predicción de 3 parámetros asociados a la degradación del papel aislante en los transformadores de potencia tal como se presenta en la Figura 3-4. La comparación del desempeño se realizó a partir del análisis de los factores MAPE y APE, llegando a una precisión de entre 80% y 90%, si bien se recomienda utilizar una red más robusta para mejorar el valor final obtenido.




Figura 3-4.: Ejemplo de red neuronal aplicada para las predicciones de las propiedades del transformador [49]

Como punto adicional al análisis de la viabilidad del uso de las redes neuronales, se tuvieron en cuenta otras aplicaciones de predicciones en el sector eléctrico, con propiedades similares a las dadas en los sistemas de medición acoplados a redes inteligentes. En primera instancia en [50] el tratamiento de la información de base para el entrenamiento de la red se hace a partir de transformaciones de señales, en los que se divide el dato de entrada (en este caso la generación eólica) en *Intrinsic Mode Functions*, que representa un tipo de información con propósito de mejorar los diagnósticos del método.

Posteriormente se realizó una prueba de desempeño de las funciones de activación de sigmoide y de la variante de tangente-sigmoide, transformando la salida a partir una función de transferencia puramente lineal. A su vez, dentro del análisis se tuvieron en cuenta los métodos de Levenberg-Marquardt para el pronóstico de los valores resultantes. En la Figura 3-5 se presenta la comparación de desempeño de la predicción de la velocidad del viento con respecto a dos tipos de redes (EMD y EEMD) de acuerdo con estas transformaciones.




Figura 3-5.: Ejemplos de desempeño de redes neuronales en la predicción de la velocidad del viento [50]

Posteriormente en [51] se presenta una red similar al caso anterior, donde la salida se transfor-

ma para cumplir con los requerimientos de la predicción de los valores de celdas refractarias tal como se presenta en la Figura 3-6, si bien se presenta una incógnita del desarrollo del problema de optimización con respecto a la comparación del desempeño contra la precisión de acuerdo con los datos predichos. No obstante, es una referencia clave para la construcción de redes neuronales.




Figura 3-6.: Ejemplo de red neuronal para celdas refractarias [51]

Por otro lado en [52] se postulan inicialmente los datos de entrada del sistema neuronal, que corresponden a las mediciones de superficie y consumo de energía asociado a la perforación de un agujero en un proyecto del campo de ingeniería. Se utilizó para este desarrollo de la red neuronal un algoritmo de *backpropagation* a partir del cálculo del gradiente y de reducción del error, complementando con el uso de una función de sigmoide y del algoritmo de Levenberg-Marquardt. Dicha implementación se realizó a partir del programa de MATLAB, siendo una opción para ejecutar los procedimientos asociados a la adecuación e implementación de los datos de entrenamiento.

Finalmente, en [53] se presenta el desarrollo de la predicción de la temperatura de punto caliente del aceite aislante de un transformador de potencia y de su condición final. En éste se desarrolló de un modelo de red de Elman, tal como se presenta en la Figura 3-7, en el cual se implementaron los siguientes puntos:

- Normalización de los valores de entrada y de salida de la red para mejorar el desempeño de la predicción y diagnóstico.
- 300 grupos de datos (270 de entrenamiento y 30 de prueba)
- Estructura de red 4-14-1 de acuerdo con la forma de presentación de los datos de entrada, neuronas en la capa oculta y de valor final de diagnóstico.
- Uso de la función tangente-sigmoide para el tratamiento de la salida
- Evaluación del desempeño de la red a partir del cálculo del error relativo.

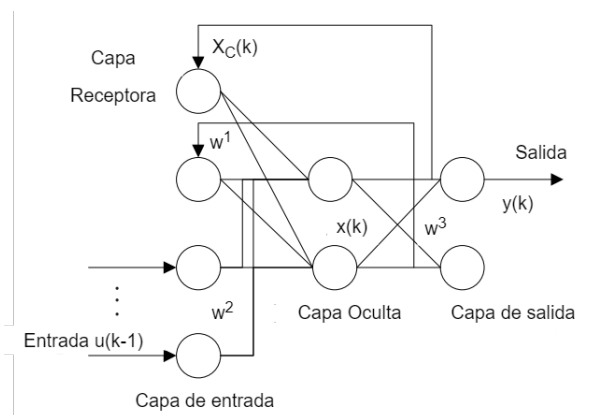


Figura 3-7.: Estructura base de la red de Elman implementada en [53]

En los siguientes apartados del presente capítulo se profundizará en los métodos basados en sistemas estadísticos y de lógica difusa.

3.2. Modelos Estadísticos

Los modelos estadísticos, en especial los que se encuentran en el marco del modelado ARIMA, se han presentado como una alternativa para el desarrollo de pronóstico de series de datos, siendo uno de los objetivos describir las correlaciones de la información, entre lo que se encuentra el análisis de tendencias que permitan identificar el comportamiento futuro de procesos [54]. A continuación, se presenta una breve descripción de los métodos citados principalmente por la literatura y de los cuales siguen surgiendo variaciones que trabajan en conjunto con Inteligencia Artificial y la disponibilidad de información:

- **ARMA (Autorregresivos y de Medias Móviles):** Combinación de procesos autorregresivos y de medias móviles, con p términos autorregresivos y q términos de medias móviles. Este modelo sólo puede ser aplicado a series que no muestren tendencia.
- **ARIMA (Modelo Autorregresivo Integrado de Media Móvil):** Corresponde a una mejora del modelo ARMA en el cual se incluye un componente de media móvil en el cual se usan los errores de un pronóstico pasado, en un modelado similar a una regresión. Se representa agregando un término q al planteamiento anterior.
- **SARIMA (Puramente estacionarios):** Variante del método ARIMA en el cual se captan el comportamiento puramente estacional de una serie a partir del número de observaciones de la información en un tiempo dado en conjunto con la definición de componentes de la parte autorregresiva, grado de diferenciación y de parte de media móvil exclusivos para dicho componente estacional.

Un ejemplo del uso de estos modelos es el identificado en [55], donde se realiza una comparación de desempeño entre distintos métodos de predicción para la generación de un sistema de celdas fotovoltaicas, entre los que se encuentra el método SARIMA, su variante a partir de la inclusión de factores exógenos SARIMAX y de un modelado basado en redes neuronales.

Específicamente, la comparación de los resultados obtenidos se basó en el cálculo de la raíz del error cuadrático medio normalizado (NRMSE por sus siglas en inglés) con respecto a la potencia real generada en las cuatro diferentes estaciones del sitio de análisis. En la Figura 3-8 se presenta una comparación del desempeño de diagnóstico del día siguiente entre los modelos mencionados.

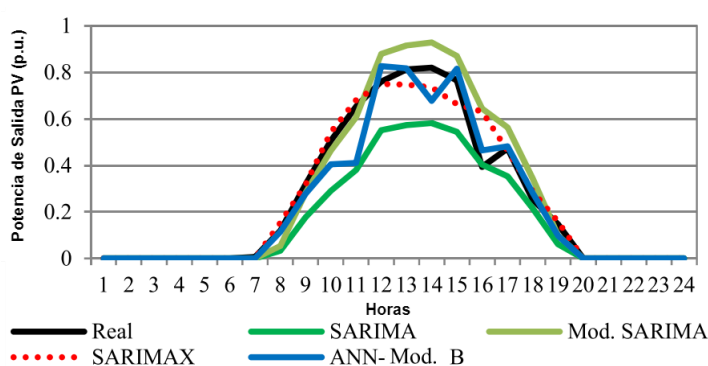


Figura 3-8.: Comparación del pronóstico del día después entre los modelos expuesto en [55]

Se identificó en este modelado que la aplicación de un método o otro depende directamente del escenario que se presente, siendo un ejemplo la homogeneidad del clima en la época de verano o la incertidumbre ligada al invierno. Por otro lado, un enfoque adicional a los sistemas de predicción estadísticos es el reconocimiento de las tendencias de los valores a analizar, siendo este el caso en la investigación plasmada en [56], donde se realiza una estimación asociada al tráfico vehicular teniendo en cuenta los datos registrados de una semana.

Dentro de esta investigación se analizó la aplicabilidad del modelo SARIMA previamente expuesto en conjunto con la aplicación del modelo PROPHET, siendo este último correspondiente a un método de predicción de series basado en un modelo aditivo, en el cual tendencias consideradas como no lineales son ajustadas de acuerdo a la estacionalidad anual, mensual y diaria en conjunto con los efectos de días festivos [56]. En la figura 3-9 se muestra el comportamiento de este último sistema.

A partir de estos análisis se identificó que el modelo SARIMA se desempeña de mejor manera con respecto al modelo PROPHET en la predicción a corto plazo mientras que este último permite la identificación de las tendencias y de la definición de intervalos de confianza en los que se presentarían los futuros valores de tráfico.




Figura 3-9.: Datos de tráfico en conjunto con la predicción de PROPHET [56]

Por último, en el campo de los sistemas de potencia se ha hecho el uso de una variante del método ARIMA denominada como ARIMA Fraccional [57]. Específicamente este método es capaz de expresar dependencias en un largo y corto rango, que a partir de la definición de sus parámetros asociados con un modelo heurístico se logra el aumento de la precisión tal como se presenta en la figura 3-10.

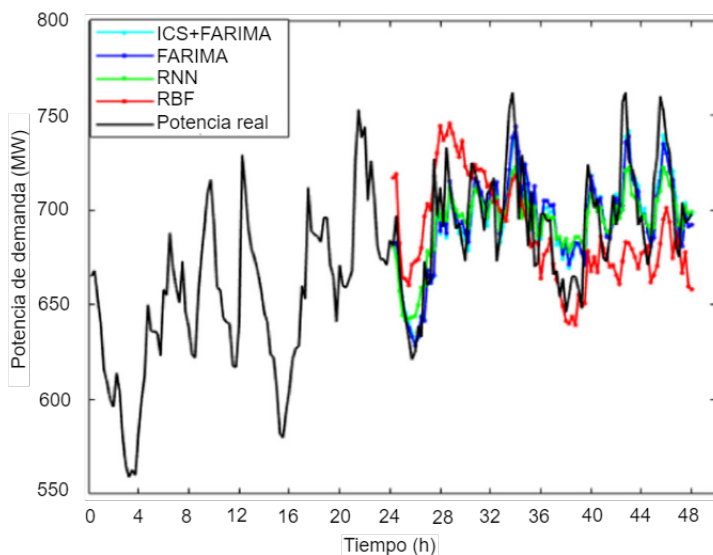


Figura 3-10.: Predicción de consumo de potencia durante días laborales [57]

En esta figura se muestra que el método asociado al FARIMA tiene un mejor desempeño con respecto al acercamiento del comportamiento del consumo de energía, si bien al agregar el módulo del algoritmo heurístico se mejora aún más este método, en especial realizando la comparación con una red neuronal recurrente RNN) y una red de base radial (RBF) [57].

3.3. Lógica Difusa

La lógica difusa o teoría de los conjuntos difusos está relacionada con el estudio de la vaguedad, que corresponde en la relación entre el conocimiento del valor de una función, denominado grado de pertenencia, y del conocimiento del valor exacto de una variable. Esto se debe a la presencia de incertidumbre, representada por información incierta e imprecisa. Por ello la lógica difusa se utiliza como una forma de lógica multivariada que busca cuantificar la incertidumbre, teniendo en cuenta el modelamiento de puntos intermedios o grises de pertenencia [58].

El procesamiento a partir de estos puntos permite una flexibilidad para el escalamiento del problema, presentado por la tolerancia a los datos imprecisos y de la posibilidad de modelar funciones no lineales en un planteamiento matemático considerado como fácil de entender [58]. Por ejemplo en [59] se muestra una aplicación de la lógica difusa para la evaluación de desempeño de un sistema de IoT, dado principalmente por las consideraciones del ambiente. Dentro de este documento se hace la presentación de una de las formas de construcción de lógica difusa más utilizada, que corresponde a la de tipo Mamdani, en la cual se evalúan valores numéricos a partir de un conjunto de funciones de membresía y de reglas lógicas para la clasificación. Un ejemplo de este procesamiento se presenta en la Figura 3-11.

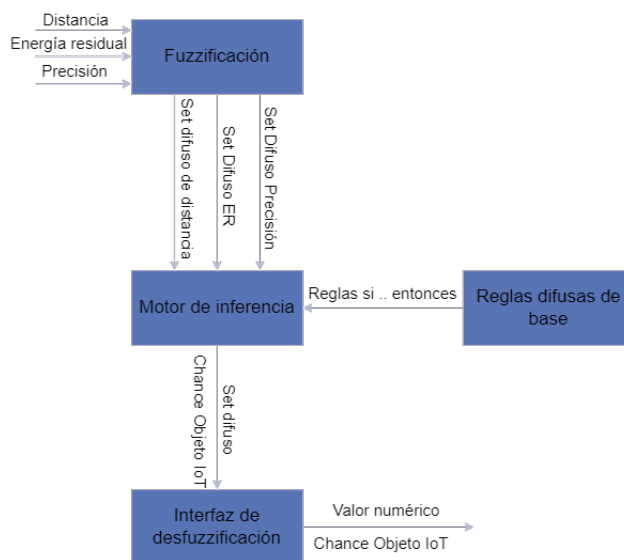


Figura 3-11.: Ejemplo de composición de sistema de lógica difusa [59]

Los principales componentes de este documento se presentan a continuación y representan los más utilizados en la actualidad:

- **Modelo de fuzzificación:** Transforma los valores de entrada en sets a partir de la representación con funciones de membresía, siendo este caso construido a partir de

funciones triangulares y trapezoidales.

- **Motor de Inferencia:** Simulación de la toma de decisiones del hombre basados en el punto anterior y en las reglas del sistema.
- **Reglas de base:** condicionales de la forma si-entonces para la escogencia de la salida del sistema. La cantidad de reglas depende del total de variables de entrada y de las categorías de cada una.
- **Módulo de defuzificación:** Uso de métodos para obtener el valor final, siendo el usado en este documento el Centroide de Área (COA por sus siglas en inglés).

Otro ejemplo de aplicación de lógica difusa se identificó en [60], donde se construye uno de estos sistemas para brindar sugerencias al consumidor para que utilice la energía eléctrica en los momentos de fuera de pico. Esto se realizó a partir de la categorización de reglas divididas en los siguientes aspectos:

- Intervalos de tiempo.
- Costo del servicio.
- Potencia nominal.
- Duración de funcionamiento de las cargas.
- Salida del sistema postulada como el estado de encendido de cada uno de los electrodomésticos.

Tal como en la aplicación anterior se procede a fuzificar los parámetros de entrada con respecto a las funciones de membresía establecidas, asignando un valor de 0 a 1 para cada punto en el dominio para luego evaluar, teniendo en cuenta el conjunto de normas del sistema, cada uno de los parámetros en pro de obtener los estatus de la salida tal como se presenta en la Figura 3-12 y la Figura 3-13.

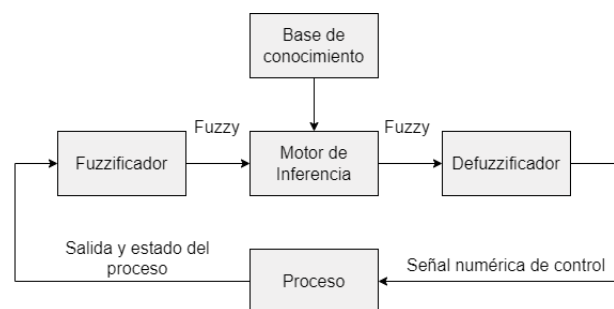


Figura 3-12.: Diagrama conceptual de lógica difusa [60]

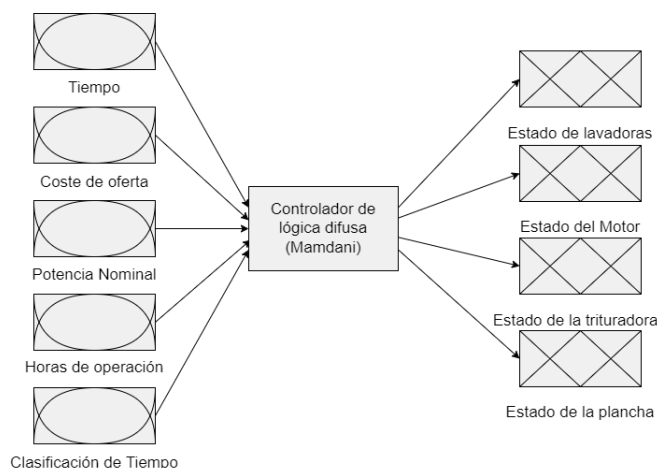


Figura 3-13.: Esquema de desarrollo de lógica difusa [60]

A su vez, este tipo de sistemas es utilizado como complemento a implementaciones basadas en la toma de decisiones como se evidencia en [61], donde a partir de la información obtenida por expertos en la temática de mantenimiento de líneas de transmisión eléctrica se desarrollaron las respectivas operaciones difusas para la clasificación, agregación y tratamiento de la información proveniente de las distintas fuentes de información, resumido en la Figura 3-14.

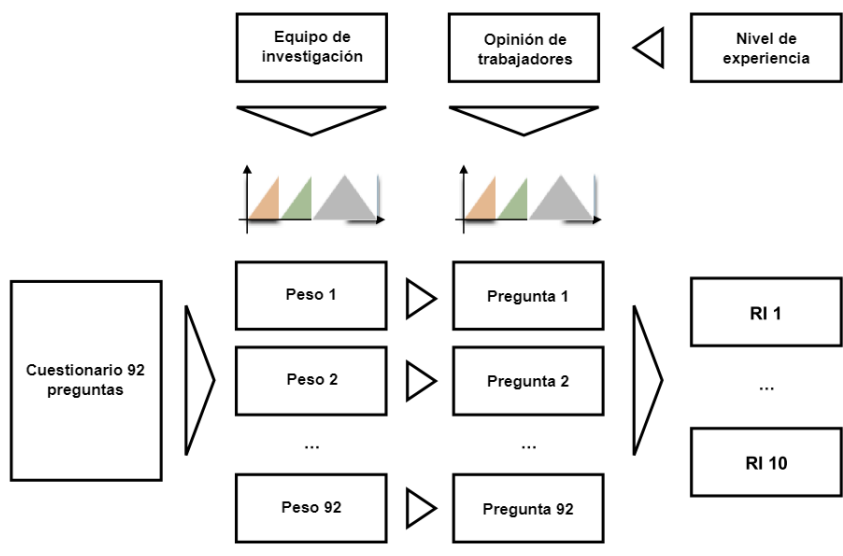


Figura 3-14.: Estructura General de sistema de evaluación basado en lógica difusa [61]

Por último en [62] se presentan algunas clasificaciones con respecto a este tipo de sistemas, considerando las limitantes de información (tales como la inclusión de ruido en las mediciones) y de las salidas a tener en cuenta tal como se presenta en la siguiente lista y en la Figura 3-15.

- **Tipo 1:** Modelado tradicional en el que las funciones de membresía representan una total certidud.
- **Tipo 2:** En este segundo caso las funciones de membresía también son difusas y se utilizan cuando no hay certidud con respecto al establecimiento de dichas funciones.

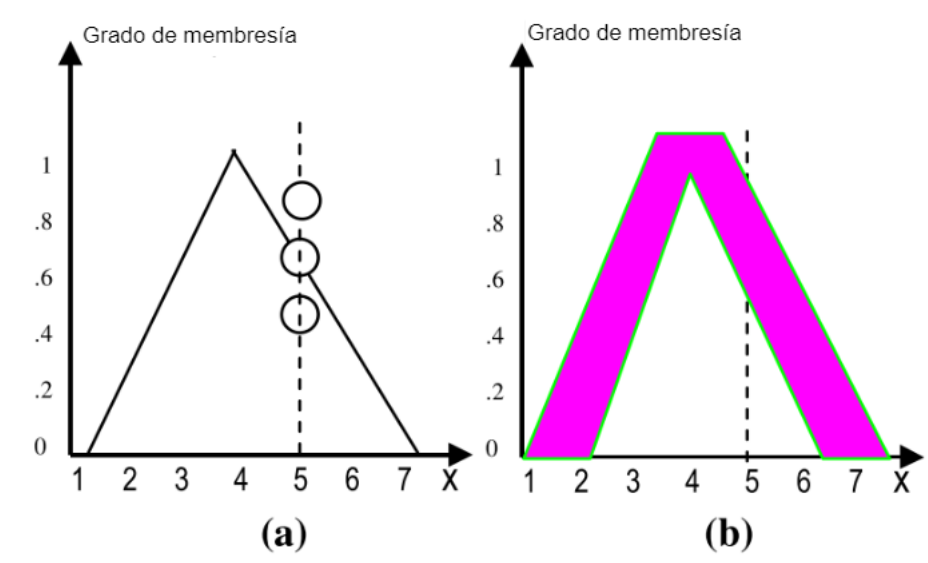


Figura 3-15.: Función de membresía Tipo 1 (a) y Tipo 2 (b) [62]

Como consideración final, el uso de métodos predictivos en conjunto con las herramientas de clasificación de lógica difusa presentan la oportunidad de modelar un grupo de reglas para el diagnóstico del estado de los transformadores de potencia, permitiendo el desarrollo de una planeación a futuro en estos sistemas, a la vez que permite realizar la comparación de resultados en la misma flota. En la siguiente sección se desarrollará este último punto con el modelo de gestión basado en las condiciones de operación del LAB+i.

4. Modelo de Gestión para flota de transformadores

En esta sección se presenta el desarrollo de los principales componentes del modelo de gestión de activos. Para ello primero se presenta una definición del estado actual del Laboratorio Nacional de Redes Inteligentes (LAB+I), del cual se va a tomar la información de referencia para la implementación del sistema de gestión. Luego se presentarán las capas del método de clasificación desde el tratamiento de información hasta el valor numérico final.

4.1. Laboratorio Nacional de Redes Inteligentes

Actualmente en el campus universitario de la Universidad Nacional sede Bogotá se tiene implementado un sistema de medición inteligente de las subestaciones eléctricas que permiten suplir la demanda de los edificios, que presentan comportamientos diferenciados de consumo de energía dado por las actividades que se realizan en el ámbito académico, laboral y de extensión [63]. Dicho sistema es denominado *Laboratorio Nacional de Redes Inteligentes (LAB+i)* y se encuentra estructurado a partir de las siguientes capas [10]:

- **Física:** Incluye todos los elementos físicos del sistema eléctrico y otros que usan variables análogas para su funcionamiento. En este caso corresponde a las subestaciones del Campus Universitario y a los elementos del sistema de distribución eléctrico analizado.
- **Interfaz:** Permite la transferencia de información entre capas, en especial de la transición de análogo a digital y viceversa. Se encuentran en esta capa los medidores inteligentes de energía, los cuales realizan el censado de tiempo real de las principales variables eléctricas de la zona. A su vez, estos tienen la disponibilidad de conectarse a internet para el envío de esta información a un servidor externo, ya que en su mayoría no disponen de un almacenamiento interno de información.
- **Comunicación:** Corresponde al sistema que permite la comunicación entre los diferentes elementos del laboratorio a partir de protocolos y otros dispositivos. Se compone de elementos tales como routers, sistemas cableados de conexión a internet y, desde el punto de vista de software, de los respectivos protocolos de comunicación entre medidores y los servidores principales.

- **Sistema:** Se asocia con el grupo de objetos y aplicaciones que hacen la recolección y manejo de información. En el Campus Universitario el conjunto de programas de PI System cumple esta función, haciendo posible su uso para aplicaciones de las capas superiores.
- **Modelo:** Corresponde a la representación del sistema de potencia y es necesario para la toma de decisiones, es decir, es un modelo de la red eléctrica que permite realizar simulaciones de desempeño, desarrollo y prueba de herramientas inteligentes.
- **Inteligencia:** Incluye procesos avanzados de procesamiento para la generación de elementos adicionales para la toma de decisiones. Dentro estos se encuentran procesamientos avanzados de la información, como lo es el uso de métodos predictivos y de aprendizaje de máquina. A su vez se presentan en esta capa herramientas de análisis tales como visualizaciones de datos.

La red eléctrica del campus, mostrada en la Figura 4-1, se conecta con el Sistema Eléctrico Nacional a partir de dos circuitos externos hacia la subestación principal de éste, la cual cuenta con una celda de transferencia y que permite modificar la conexión para asegurar el suministro continuo de energía [64].

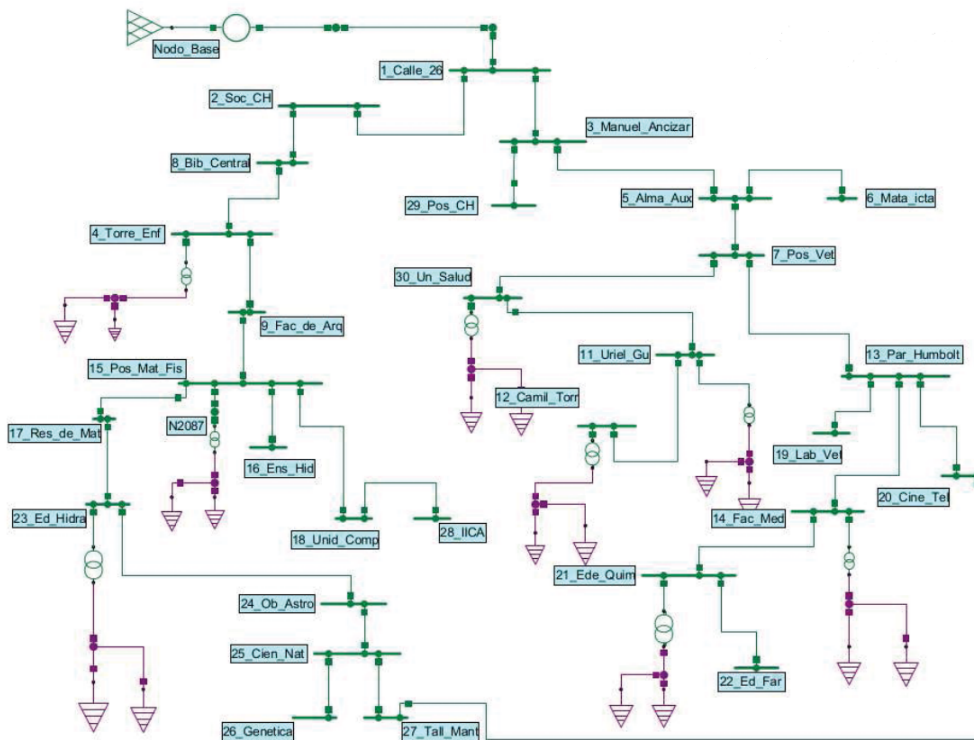


Figura 4-1.: Subestaciones eléctricas del Campus Universitario de la Universidad Nacional de Colombia - Sede Bogotá [64]

Internamente la red eléctrica consta de una topología de anillo con una longitud aproximada de 3km distribuidos en un sistema de ductos subterráneos. Dicha red está conformada por más de 33 subestaciones eléctricas que se conectan a partir de 53 buses, siendo en su mayoría de tipo local y con cada uno de sus respectivos elementos de protección y medida. Su nivel de tensión es de 11.4kV/214 o 440 V con una conexión de Dyn5, siendo su capacidad nominal medida en kVA [64].

A partir de esta información se realizó una revisión de los proyectos realizados en años anteriores que utilizaron este sistema de medición inteligente como referencia, ya que a partir de ellos se pueden identificar los puntos fuertes y a aspectos a mejorar, como lo es el uso de algoritmos de Inteligencia Artificial. En primera instancia, en el artículo [65] se identificó el efecto de la generación solar en los parámetros de calidad de potencia del sistema eléctrico de la Universidad Nacional de Colombia sede Bogotá y de una eventual instalación de capacidad que permita que el campus sea autosuficiente.

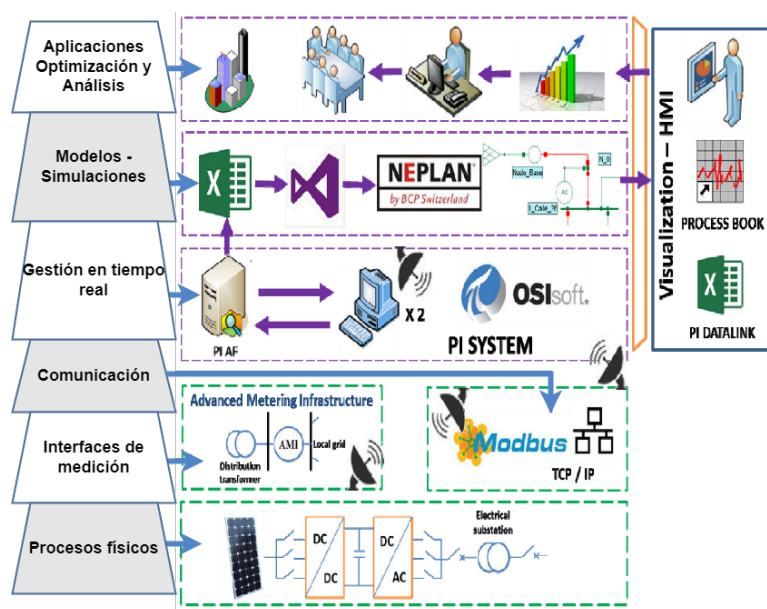


Figura 4-2.: Estructura base del sistema de monitoreo en el Campus Universitario [65]

El objetivo de la recopilación de esta información es identificar de qué forma está estructurado el sistema inteligente de medición, que es referencia clave para reconocer las oportunidades de aplicación de un modelo de gestión de activos, siendo el sistema dividido en varias capas de acuerdo con los datos y el procesamiento pertinente, siguiendo el modelado realizado en la Figura 4-2 dado en [66] y del cual se pueden extraer los elementos de diagnóstico inicial del sistema de información.

A su vez, dentro del modelado se tiene en cuenta la implementación del sistema en el software

de NEPLAN, donde se importan los valores correspondientes a la generación solar y se ejecuta la simulación de diagnóstico, especialmente con el objetivo de identificar el comportamiento de la tensión y de las posibles fallas asociadas. Se utilizaron para el tratamiento de datos los programas de Osisoft PI y VisualStudio 2015 IDE tal como se muestra en la Figura 4-3 [65].

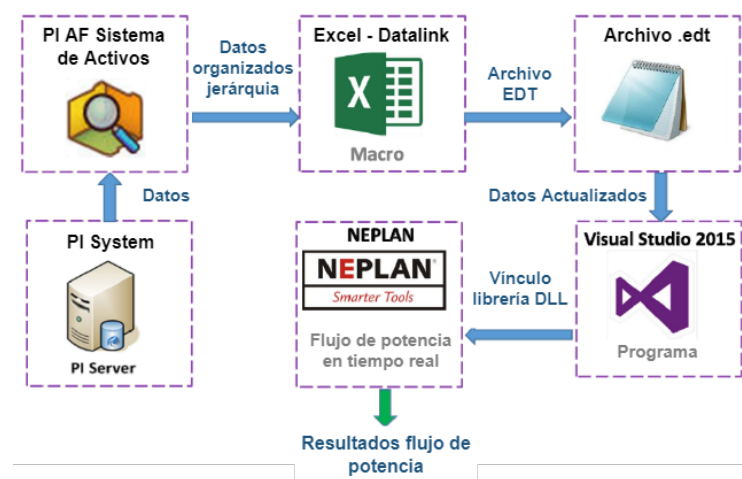


Figura 4-3.: Sistema de conexión de NEPLAN y de VisualStudio [65]

Por otro lado en [67] se evidenció una forma de aplicación de Inteligencia Artificial con los datos del campus universitario, pero con enfoque en parámetros de clasificación y procesos de la gestión de demanda, siendo los principales algoritmos dados a partir de modelos probabilísticos de clasificación, que a su vez fueron entrenados con datos históricos de un conjunto de medidores instalados en el campus universitario. Los resultados se muestran en la Figura 4-4.




Figura 4-4.: Recopilación curvas de carga de acuerdo con la clasificación de clusters [67]

En complemento con lo anterior, en el documento [11] se presenta el desarrollo de un modelo en el cual se busca mejorar el desempeño del sistema de monitoreo de la Universidad Nacional de Colombia con un estimador de estados, en el cual se permite mejorar la observabilidad y por ende su utilización para el desarrollo de análisis predictivos asociados a los sistemas de potencia. El esquema de referencia se presenta en la Figura 4-5.

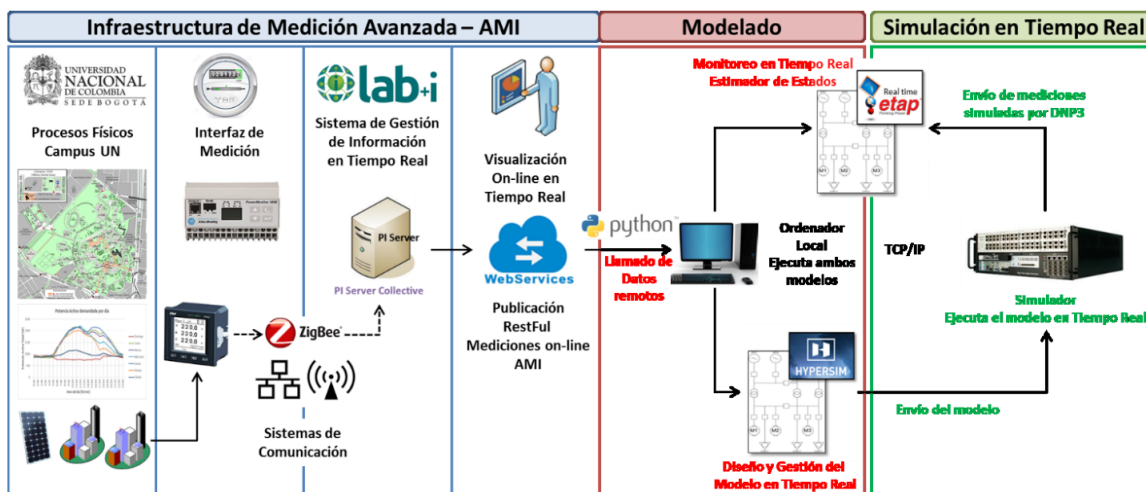


Figura 4-5.: Plataforma para evaluación del desempeño de Estimación de Estados [11]

En esta implementación se consideraron los siguientes programas, que permiten el aprovechamiento de la información censada por los medidores de energía actualmente instalados [11]:

- Servicio WEB RESTful - HTTP por medio de un código en Python
- Emulación de la red eléctrica - Hypersim
- Emulación e integración del Estimador de estados - ETAP - RT

Finalmente en [68] se presenta una implementación a gran escala de la medición inteligente en el territorio colombiano, teniendo en cuenta las necesidades de cada uno de los actores de la red eléctrica según los parámetros de la Figura 4-6.

En conclusión los datos de consumo de energía y desempeño del sistema de potencia han sido utilizados para el análisis de la demanda de energía en el predio de la Universidad Nacional y se han desarrollado modelos asociados a la gestión de la demanda, pero de acuerdo a las investigaciones presentadas en [23, 25, 31, 38, 42] estos valores se pueden utilizar para hacer un diseño de indicadores de desempeño, en los que se incluya el índice de salud para poder hacer una estimación en tiempo real de la calidad de los transformadores para la toma de decisiones [69].



Figura 4-6.: Componentes de un sistema de medición inteligente [68]

4.2. Descripción de información disponible

Teniendo presente las investigaciones previas se identificó que, para cada una de las sub-estaciones y dependiendo de la referencia de medidor inteligente, se censa en tiempo real un conjunto de variables que permiten delimitar el comportamiento asociado al consumo de energía y de operación asociada a los transformadores, como lo son:

- **Frecuencia:** Parámetro clave para el establecimiento de la calidad de energía, si bien dentro de la gestión de activos que se planteará en las siguientes secciones no se tuvo en cuenta para el diagnóstico de los transformadores de potencia ya que es relativamente constante.
- **Corriente y tensión:** Mediciones correspondientes a los valores del lado de baja tensión, que sirven como parámetros de referencia para análisis relacionados con el desempeño a partir de la potencia aparente a la cual está sometido cada transformador, siendo un parámetro clave para el diagnóstico de este elemento.
- **Factor de potencia:** Dado por la relación entre potencia activa y reactiva, la cual permite identificar los patrones de comportamiento que pueden llevar a una degradación más lenta o rápida del transformador de potencia.
- **Potencia Activa y Aparente:** Elementos utilizados para el diagnóstico de la instalación eléctrica, entre lo que se encuentra degradación del material aislante como lo es del aceite refrigerante, entre otros.
- **Temperaturas:** Actualmente la medición de la temperatura del transformador de potencia se realiza a partir de un conjunto de termocuplas, que miden directamente el valor del aceite aislante. A partir de este valor y teniendo en cuenta normativas

internacionales se puede estimar la temperatura para el resto de los componentes y tener un diagnóstico más desarrollado.

- **THD de Tensión y Corriente:** Distorsión Total Armónica vista desde la afectación de las ondas de tensión y corriente por fase. Causados principalmente por los armónicos provenientes de equipos electrónicos, como lo puede ser los asociados a sistemas de generación solar y electrónica de potencia.
- **Medición Fasorial:** dada principalmente para comparar el estado de la red eléctrica en distintos puntos al mismo tiempo y utilizado como un factor clave para identificar la calidad de potencia.

Con esta información se puede realizar un análisis con respecto al estado de vida de los transformadores de potencia debido a que estas variables, en especial las mediciones de temperatura son ampliamente utilizadas en este tipo de desarrollos. No obstante, no se utiliza con frecuencia la curva de demanda diaria para diagnosticar el estado de estos dispositivos, en especial relacionado con modelos de inteligencia computacional [37, 39].

A su vez, se tienen en cuenta los problemas de envío de información con respecto a la estabilidad de la red de internet ya que esto hace que se pierda información durante estas contingencias, lo que hace necesario un análisis previo de la información para poder desarrollar un modelo confiable y estable. Por ello, debido a estos problemas algunos medidores requieren un trabajo de campo para restablecer su comunicación, asociado a problemas de identidad o de reinicio del medidor.

Adicionalmente, para el desarrollo de un sistema de gestión de activos adecuado a las condiciones de medición es necesario identificar un sistema en que se pueda utilizar la información enunciada en la sección anterior, es decir, de los datos de tiempo real si bien se tiene en cuenta que para el uso de modelos más detallados de gestión (enfocados en la optimización de los procesos asociados al mantenimiento de los mismos) se requiere un conjunto de información actualmente no disponible en el servidor del Campus Universitario [15, 70, 71].

Actualmente se encuentra disponible la fecha de instalación de cada transformador, la cual se puede incluir en los procesos de análisis y que permitiría mejorar la predicción obtenida del modelo de vida por parte de los modelos propuestos en las secciones anteriores. No obstante, el LAB+i no cuenta con un sistema de gestión para los transformadores en los cuales se permita la identificación en tiempo real del estado del dispositivo. A su vez, a diferencia de los modelos con condiciones similares tales como [34, 37, 38, 39, 42], no se tiene un monitoreo o pruebas periódicas de la calidad del aislamiento a partir de los Análisis de Gases Disueltos y del Grado de Polimerización, que representan los parámetros con mayor peso dentro de estos modelos.

Este sistema por otra parte dispone de un monitoreo continuo del consumo de energía de la mayor parte de las subestaciones del Campus Universitario [72] y de la temperatura del aceite de un conjunto de transformadores, datos que son transmitidos hasta el servidor principal del LAB+i a la vez que éste tiene herramientas para hacer el cálculo en tiempo real de los indicadores por medio de los programas mencionados en las secciones anteriores.

4.3. Estructura del modelo

En la Figura 4-7 se presenta la estructura base del modelo de Gestión de Activos implementado, que se divide en dos fases. La primera corresponde al manejo de la información proveniente de los medidores de parámetros de energía, teniendo en cuenta al LAB+i como habilitador del tratamiento de la información. A su vez, se presenta en el **Anexo B** el esquema del modelo con respecto a sus interacciones con los demás bloques del sistema de monitoreo.

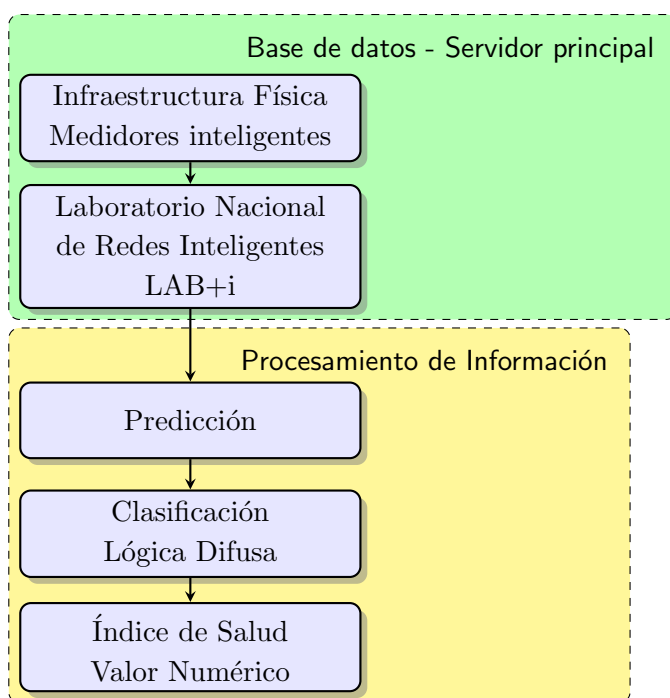


Figura 4-7.: Presentación de las capas del Modelo de Gestión

En la siguiente fase se presenta el desarrollo del sistema de gestión, que se compone de un desarrollo preliminar de predicción con respecto a los datos históricos registrados en el servidor principal y los patrones de consumo del Campus Universitario de la sede Bogotá. Posteriormente se realiza el proceso de clasificación a partir del sistema de lógica difusa y se obtiene un valor final que corresponde al estado del dispositivo. A continuación, se presentará en detalle el desarrollo de cada uno de estos componentes.

4.3.1. Extracción de Información a partir de Python

En primera instancia para la extracción de la información registrada a partir del software de Osisoft PI se implementó un módulo de Python que permite utilizar las funciones diseñadas en C# (Lenguaje de programación de base) para este proceso y del análisis de información resultante. Esto se debe a la facilidad de utilización de Python para el desarrollo de cada uno de los módulos, acoplando las siguientes funcionalidades en miras del tratamiento de la información antes de su uso en procesos posteriores:

- **Graficación de datos:** herramienta diseñada a partir de la librería matplotlib, en la cual se visualizan los datos importados del servidor principal antes de continuar con la ejecución del programa, permitiendo identificar intervalos de tiempo con fallas de registro y de la disponibilidad en tiempo real de la información. A su vez se desarrolló un código a partir del cual se hace el almacenamiento de la información en un archivo CSV para el uso de otro tipo de programas de graficación y de la facilitación de la muestra de tendencias o posibles comportamientos asociados a problemas de registro o de cálculo.
- **Interpolación de información:** funcionalidad basada en el hecho de que en varios de los medidores de energía instalados el envío y registro de información es inestable en ciertos momentos del día. Por ello se incluyó una herramienta de interpolación lineal para los casos en los que esta falta de información sea mínima y permitir el funcionamiento de los siguientes módulos. Este sistema va de la mano con la graficación de información ya que a partir de ella se identifican los escenarios en los cuales es posible hacer estas aproximaciones sin perder la calidad de diagnóstico. Un ejemplo de restricción es la cantidad total de horas sin información.
- **Almacenamiento local en Python:** Desarrollado con el objetivo de utilizar la información con las funciones disponibles de Python, dentro de lo que se incluye su posterior conversión a otro tipo de datos como lo es el tipo DataFrame y en general de las listas. Este lenguaje de programación permite el uso de una amplia gama de librerías libres, a partir de las cuales se pueden realizar diagnósticos con alta precisión y a su vez presenta facilidades que le permiten hacer el tratamiento de la información proveniente de otros programas.

Para el desarrollo del modelo de gestión de activos se tuvo en cuenta la disponibilidad de mediciones en el LAB+i por parte del monitoreo del estado de los transformadores, siendo los valores escogidos los que se presentan en la siguiente lista:

- **Corriente por fase:** Representación del consumo de energía eléctrica y punto base de clasificación del estado de los transformadores de potencia con respecto a su valor nominal. En la Figura 4-8 se presenta el perfil del edificio del programa de Enfermería

para un día correspondiente al horario hábil, el cual permite analizar el parámetro del uso de la electricidad.




Figura 4-8.: Corriente de una fase del edificio nuevo de enfermería

- **Tensión por fase:** Parámetro de calidad del servicio y acotado de acuerdo con los límites inferiores y superiores sugeridos por la normativa colombiana. En la Figura 4-9 se muestra el comportamiento de esta variable a lo largo del tiempo, asociado tanto a la demanda de energía como los procesos de operación propios de la red de distribución de la Universidad Nacional de Colombia Sede Bogotá.




Figura 4-9.: Tensión de una fase del edificio nuevo de enfermería

- **Edad del transformador:** Dato tomado en cuenta de acuerdo con investigaciones previas, que evidencian que a medida del aumento la edad de los transformadores se presentará un mayor riesgo de falla de alguno de sus componentes tal como se ha expuesto a lo largo del estado del arte del presente documento. Particularmente con este dato para el desarrollo del sistema se asumió con un valor fijo, asociado a que prácticamente no varía en el período de 1 semana, que es del que se basa el análisis. Esta variable también representa una simplificación asociada al mantenimiento de estos dispositivos.

4.3.2. Modelo de Predicción

El sistema de predicción implementado consiste en un modelo estadístico basado en la estacionalidad en conjunto con el modelado AMIRA, en el cual a partir de los datos definidos en lapsos de tiempo claros se puede hacer un pronóstico del comportamiento de la información. A su vez en la escogencia de este modelo se tuvo en cuenta la disponibilidad de módulos en Python asociados a la construcción de modelos estadísticos, en el que se incluyó el correspondiente al de *statsmodels*, que entre los sistemas disponibles dispone de un modelo SARIMA.

con el propósito de usar de este modelo es clave identificar previamente si la información a tratar es estacionaria, es decir, que se presente un valor medio constante en conjunto con la varianza y la estructura de autorregulación en conjunto con la no presencia de un componente periódico. Si es el caso, se pueden realizar las respectivas transformaciones para eliminar este último componente. Para la escogencia de estos parámetros se recurrió a los métodos de búsqueda ACF y PACF en conjunto con el método de criterio de información de Akai (AIC por sus siglas en inglés) [54].

A su vez, para el análisis del caso específico del LABI y asociado a los patrones de consumo de la Universidad Nacional de Colombia fue necesario realizar una clasificación de los datos de entrenamiento para la predicción, ya que se presenta un componente periódico acotado por los casos presentados en la siguiente lista y por la Figura 4-10, donde se muestran estas demandas.

- **Días hábiles menos los viernes:** Fechas en las cuales se presenta un mayor consumo de energía, asociado al uso de las instalaciones en el período académico de clases y de las respectivas actividades administrativas asociadas. No obstante, en los períodos donde no hay clase se disminuye considerablemente este consumo si bien se sigue presentando una leve diferencia con el resto de los períodos a analizar. Este fue el punto de referencia con respecto a la asignación de los valores asociados al proceso de clasificación que se describirá en las siguientes secciones.
- **Viernes:** Asociado con la terminación del período de actividades tanto académicas

como administrativas a las 4 de la tarde, lo que representa un alto consumo por las mañanas pero que va disminuyendo en el resto del día y es similar al consumo en fines de semana y festivos, salvo algunas excepciones de uso de laboratorios para investigación.

- **Sábados:** Corresponde al desarrollo de actividades académicas por la mañana, lo que conlleva a un pico de consumo por la mañana menor que el presentado en las otras categorías y que representa el uso de las instalaciones de clase y laboratorios.
- **Domingos y festivos:** Período en el cual se disminuye el consumo de energía ya que no hay programadas actividades ni académicas ni administrativas. Corresponde al gasto del recurso eléctrico correspondiente a los sistemas de seguridad, iluminación de las zonas comunes y cargas críticas en los laboratorios.




Figura 4-10.: Corriente de ejemplo para los 4 casos de estudio

4.3.3. Clasificación por Lógica Difusa

Para el desarrollo del sistema de lógica difusa, se utilizó la corriente como parámetro principal de clasificación, donde se asignaron 4 categorías de acuerdo con el porcentaje de corriente nominal por fase con respecto a la potencia nominal del transformador, dado por la siguiente fórmula:

$$I_f = \frac{S}{3V_l} \quad (4-1)$$

donde I_f representa la corriente por fase balanceada y V_l la tensión de línea del sistema trifásico. A continuación en la Figura 4-11 se muestra la función de membresía para un transformador de 300 kVA y 11.4kV/128V.




Figura 4-11.: Función de membresía para corriente

Posteriormente se adaptó la función de tensión dada en [44], donde se modificaron los rangos de definición de cada categoría de acuerdo con el valor nominal dado en la placa del transformador de potencia. En la Figura 4-12 se muestra el caso para 128V:




Figura 4-12.: Función de membresía para Tensión

A su vez, se implementó la misma función de edad dada por [43], en la cual se estima que desde los 30 años de vida del dispositivo se presentarán problemas asociados al desempeño general y de seguridad tal como se evidencia en la Figura 4-13.

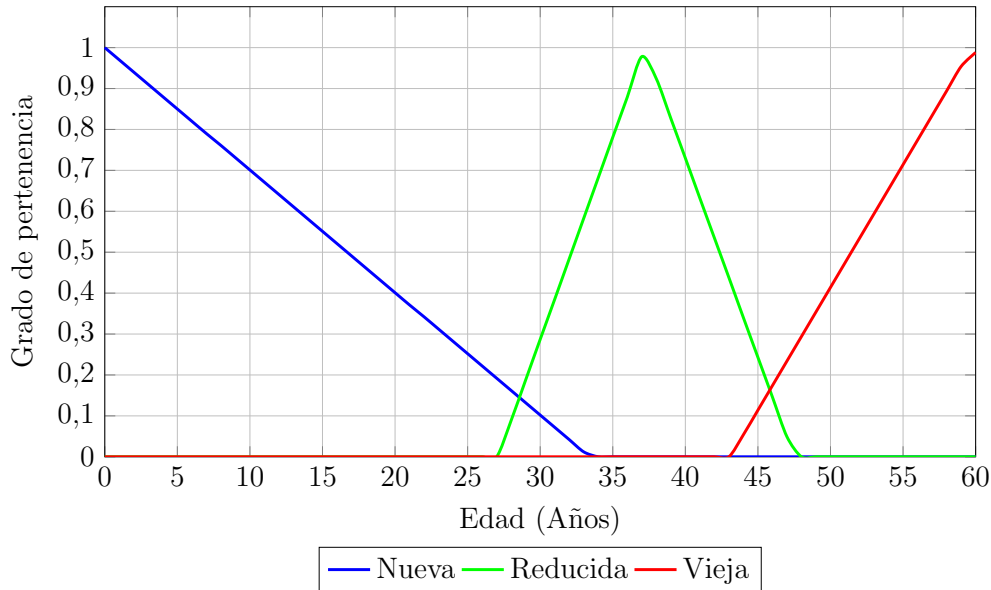


Figura 4-13.: Función de membresía para la edad del transformador

Por último, la función de membresía de salida (Índice de Calidad del Transformador) está dada por 4 categorías similares a las definidas de corriente tal como se evidencia en la Figura 4-14.

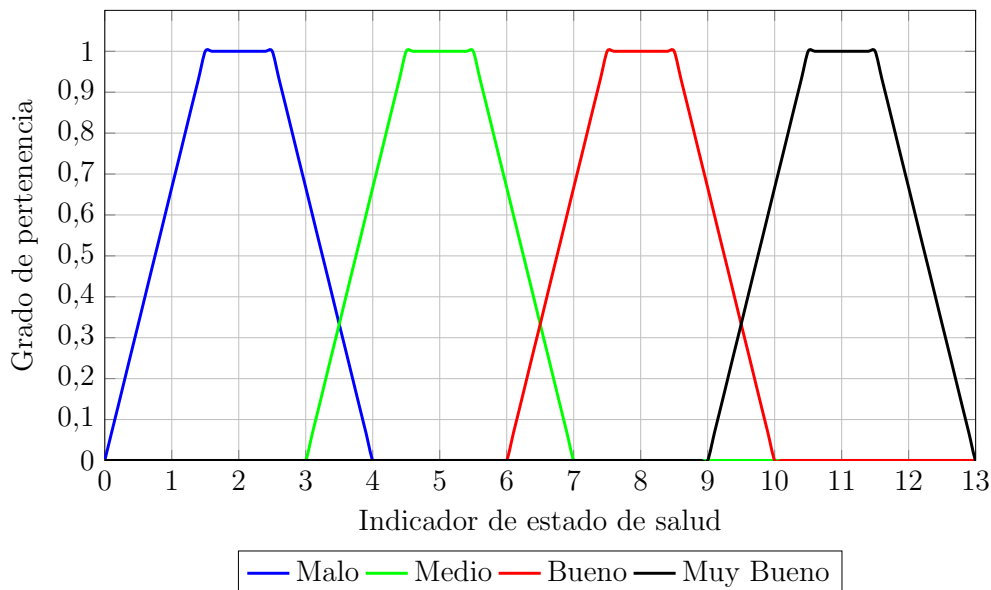


Figura 4-14.: Función de membresía de calidad del transformador de potencia

Las reglas utilizadas en el sistema de lógica difusa corresponden a la adaptación de las dadas en los sistemas [43, 44]. No obstante, con el propósito de su aplicación en el marco del Laboratorio de Redes Inteligentes se realizó un proceso de categorización basado en los niveles de corriente, tal como se evidencia en la función de membresía de la Figura 4-11.

Al mismo tiempo, como parámetro de medición de calidad de suministro se utilizó la tensión para identificar posibles comportamientos que aumenten la degradación del transformador, siendo esto representado por la reducción en la categorización si la tensión es baja de acuerdo con la Figura 4-12. De la misma manera el tiempo de vida actual del dispositivo afecta al valor final, llegando a una reducción de dos categorías si se considera el transformador como viejo a partir de la función de membresía mostrada en la Figura 4-14. En la Tabla 4-1 se presentan las reglas implementadas en el modelo.

Tabla 4-1.: Reglas de sistema de clasificación difuso

1. Si corriente es Buena , tensión Media o Alta y edad Nueva , entonces el estado es Muy Bueno
2. Si corriente es Buena , tensión Media o Alta y edad Reducida , entonces el estado es Bueno
3. Si corriente es Buena , tensión Media o Alta y edad Vieja , entonces el estado es Regular
4. Si corriente es Buena , tensión Baja y edad Nueva , entonces el estado es Bueno
5. Si corriente es Buena , tensión Baja y edad Reducida , entonces el estado es Regular
6. Si corriente es Buena , tensión Baja y edad Vieja , entonces el estado es Malo
7. Si corriente es Media , tensión Media o Alta y edad Nueva , entonces el estado es Bueno
8. Si corriente es Media , tensión Media o Alta y edad Reducida , entonces el estado es Regular
9. Si corriente es Media , tensión Media o Alta y edad Vieja , entonces el estado es Malo
10. Si corriente es Media , tensión Baja y edad Nueva , entonces el estado es Regular
11. Si corriente es Media , tensión Baja y edad Reducida , entonces el estado es Malo
12. Si corriente es Media , tensión Baja y edad Vieja , entonces el estado es Malo
13. Si corriente es Regular , tensión Media o Alta y edad Nueva , entonces el estado es Regular
14. Si corriente es Regular , tensión Media o Alta y edad Reducida , entonces el estado es Malo
15. Si corriente es Regular , tensión Media o Alta y edad Vieja , entonces el estado es Malo
16. Si corriente es Regular , tensión Baja y edad Nueva , entonces el estado es Malo
17. Si corriente es Regular , tensión Baja y edad Reducida , entonces el estado es Malo
18. Si corriente es Regular , tensión Baja y edad Vieja , entonces el estado es Malo
19. Si corriente es Crítica , tensión Media o Alta y edad Nueva , entonces el estado es Malo
20. Si corriente es Crítica , tensión Media o Alta y edad Reducida , entonces el estado es Malo
21. Si corriente es Crítica , tensión Media o Alta y edad Vieja , entonces el estado es Malo
22. Si corriente es Crítica , tensión Baja y edad Nueva , entonces el estado es Malo
23. Si corriente es Crítica , tensión Baja y edad Reducida , entonces el estado es Malo
24. Si corriente es Crítica , tensión Baja y edad Vieja , entonces el estado es Malo

No obstante, a este modelo se le puede incorporar parámetros adicionales tales como la temperatura de punto caliente del dispositivo para mejorar la calidad del diagnóstico, si bien para este caso sólo se encuentra disponible para una subestación y por ende no permitiría puntos de comparación con respecto a las demás subestaciones del Campus Universitario.

Para la implementación de este sistema se utilizó la librería de *skfuzzy* perteneciente al paquete de herramientas de SciKit y que realiza el proceso de tratamiento de información teniendo en cuenta las utilidades del software matemático SciPy.

4.3.4. Índice de Salud

A partir de la interacción entre los distintos módulos se obtiene un valor final que indica el estado del transformador de potencia a lo largo del tiempo, siendo posible aplicar el diagnóstico tanto a datos históricos como a los derivados del proceso de predicción, siendo un insumo que permite hacer una comparación entre elementos de una misma flota asociado con el caso de demanda de energía del Campus Universitario.

Para este proceso se realizó el desarrollo de un sistema de agrupación de dispositivos de acuerdo con el valor numérico obtenido en la clasificación difusa, siendo necesaria la aplicación en un mínimo de 2 transformadores de la misma flota para empezar a ver cambios y comportamientos que permitan la identificación de los activos críticos y permitir el entendimiento del estado del sistema de potencia. En la Figura 4-15 se muestra un resumen de esta clasificación.

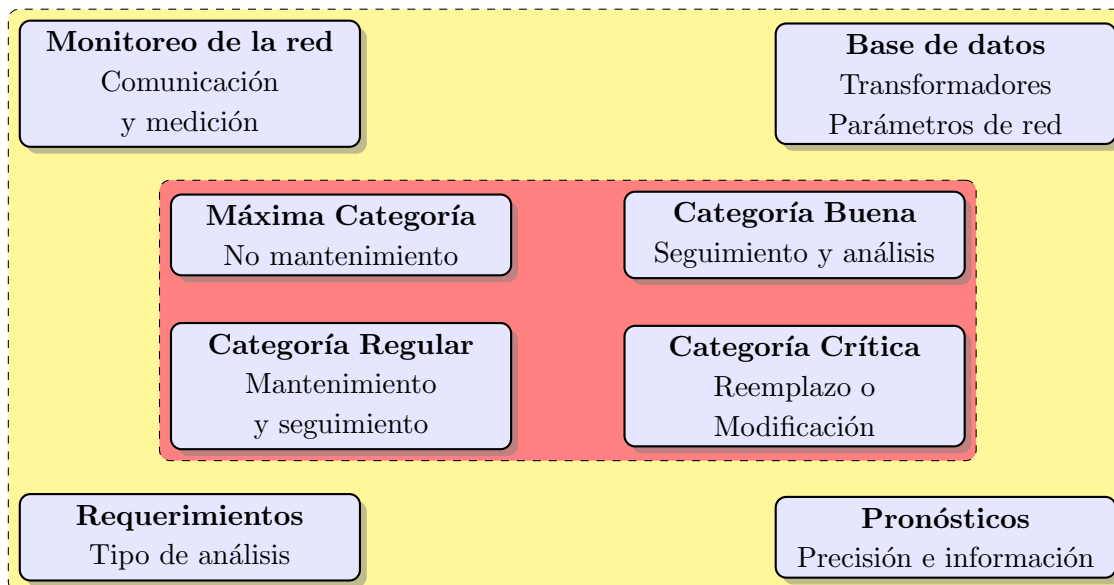


Figura 4-15.: Esquema de análisis de indicador final y clasificación

Como parámetro adicional a esta clasificación basada en los resultados del sistema de lógica difusa es importante resaltar que el análisis final se puede modificar en concordancia con los siguientes elementos:

- **Monitoreo de la red:** Asociado con la disponibilidad de medición en tiempo real,

siendo esta última la habilitadora de un análisis cada cierto número de minutos con el fin de identificar el comportamiento de la flota a lo largo de un período determinado.

- **Base de datos:** Acotación del análisis de acuerdo con la información almacenada en el LAB+i, teniendo en cuenta los intervalos de disponibilidad y de la calidad de la información. Dentro de este campo también se considera el uso de otro tipo de indicadores de calidad eléctrica, asociado con el enfoque del diagnóstico.
- **Requerimientos:** Objetivo de análisis y de datos esperados de salida. Un ejemplo de esto corresponde a la identificación en la etapa de gestión del transformador que se esté analizando.
- **Pronósticos:** Necesidad de análisis de tendencias de la información y formas de predecir el comportamiento de la flota a corto, mediano o largo plazo.

Con este campo de referencia se propone un marco general de serie de actividades de acuerdo con las categorías expuestas en la Figura 4-15:

- **Máxima Categoría:** Correspondiente a los transformadores más nuevos de la flota analizada, los cuales presentan una operación caracterizada por una baja demanda con respecto a la potencia máxima del dispositivo, por lo que no sería necesario un mantenimiento de estos si bien no se descartarían pruebas asociadas a la calidad de potencia del sistema.
- **Categoría Buena:** Son los transformadores con un tiempo de operación mayor pero que continúan con un uso reducido por la poca demanda de electricidad con respecto a su valor nominal.
- **Categoría Regular:** En esta categoría se encuentran los dispositivos que atienden una mayor demanda que las otras categorías en conjunto con un tiempo mayor de operación. En algunos casos se presentan errores asociados a la calidad del servicio y de registro de información durante el intervalo analizado.
- **Categoría Crítica:** La demanda empieza a ser cercana al 100% y se presentan fallas en la prestación del servicio, lo que hace necesario un cambio urgente dado por el reemplazo total o de maniobras invasivas para realizar la reparación del dispositivo.

En la siguiente sección se presentarán los resultados de implementación desde la escogencia del método de predicción hasta el análisis de un caso base del Campus Universitario con un sistema de cuatro transformadores.

4.4. Modelos de referencia para comparación de desempeño

Como punto de comparación entre el modelo de gestión propuesto y de las aplicaciones actuales se escogieron 3 sistemas expuestos en el estado del arte de la sección anterior, siendo acotados por su capacidad de implementación con la información actualmente disponible como se resume en la siguiente lista:

- Modelo propuesto por [42], en el cual se utiliza la ponderación de mediciones de variables críticas del transformador de potencia tales como concentración de gases disueltos, historial de demanda, factor de potencia, entre otros para establecer el Índice de Salud y de la probabilidad de falla.
- Guía IEEE para transformadores con aislamiento en aceite mineral [73] y la norma GTC 50 [74], que a partir de la temperatura del aceite aislante y de sus parámetros nominales se realiza el cálculo de la vida remanente en años del dispositivo, asociado a la temperatura del punto más caliente (Hotspot).
- Implementación de modelo de lógica difusa en el cual se tiene en cuenta la tensión, corriente y nivel del aceite aislante del transformador de potencia con respecto a su valor nominal [44]. De este modelo se adaptaron las funciones de membresía de tensión y corriente para adecuarse a las condiciones de consumo en el Campus Universitario.

A su vez, se muestra en la Tabla 4-2 las variables utilizadas por modelo. En el caso del modelo de ponderación y de lógica difusa no fue posible utilizar todos los parámetros estipulados, asociado con la disponibilidad de información en el LAB+i.

Tabla 4-2.: Parámetros utilizados por métodos de referencia

Modelo de ponderación [42]	Modelo de lógica difusa [44]	Cálculo estandar IEEE C57.91 [73]
Historial de Demanda	Tensión por fase	Temperatura del aislante
Años del dispositivo	Corriente por fase	Valores nominales
Valores nominales	Nivel de aceite aislante	
	Valores nominales	

Con objeto del modelo de ponderación se consideró el cálculo de la cantidad de picos de consumo relativo a la potencia nominal del dispositivo durante un período de análisis, siguiendo la Ecuación 4-2 y las siguientes categorías, con la potencia nominal del transformador S_B y el valor de los picos mensuales S_i :

$$LF = \frac{\sum_{i=0}^4 (4-i)N_i}{\sum_{i=0}^4 N_i} \quad (4-2)$$

- N_0 = Número de picos S_i/S_B menores a 0.6.
- N_1 = Número de picos S_i/S_B entre 0.6 y 1.
- N_2 = Número de picos S_i/S_B entre 1 y 1.3.
- N_3 = Número de picos S_i/S_B entre 1.3 y 1.5.
- N_4 = Número de picos S_i/S_B mayores a 1.5.

En conjunto con este factor se tiene en cuenta el tiempo de vida actual del transformador de potencia medido en años, acotado por las categorías presentadas en la tabla **4-3**.

Tabla 4-3.: Clasificación de transformador de acuerdo con la edad. Adaptado de [42]

Código de clasificación	Edad en Años
A	Menos de 20
B	20 - 40
C	40 - 60
D	Más de 60
E	-

Este cálculo se propone realizarlo en una ventana mayor a 1 mes, lo que permite analizar el comportamiento del dispositivo a largo plazo a partir de un único indicador. Para la comparación con el método de gestión propuesto en el documento se asignó un valor máximo de 10 al valor del denominado factor de carga, que en el artículo original llega a ser de 4, para luego disminuir linealmente hasta llegar a un valor de 0. De la misma manera se asignó un rango de 0 a 5 para el indicador de edad, con la categoría A con un valor asignado de 5 mientras que en el de la categoría D es 0, a partir de una interpolación lineal.

Por otro lado, en el modelo de lógica difusa postulado por [44] se consideraron 4 funciones de membresía, siendo 3 asociadas a los parámetros de entrada y una al índice de salud final. Para el método de comparación se adaptaron las funciones de acuerdo con la potencia nominal de los transformadores de las subestaciones analizadas. En la Figura **4-16** se muestra la función para la corriente total del dispositivo, siendo clasificada con nivel medio o nivel alto de acuerdo con el aporte a la degradación del dispositivo para un transformador de **300 kVA** con una tensión de **128V** en el lado de baja tensión.

De la misma manera en la Figura **4-17** se presenta la función de membresía de la tensión, que es la misma que la implementada en el modelo de gestión propuesto, donde clasifica el parámetro en 3 categorías asociadas a la operación del sistema y degradación de los elementos críticos del transformador.




Figura 4-16.: Función de membresía para corriente en [44]

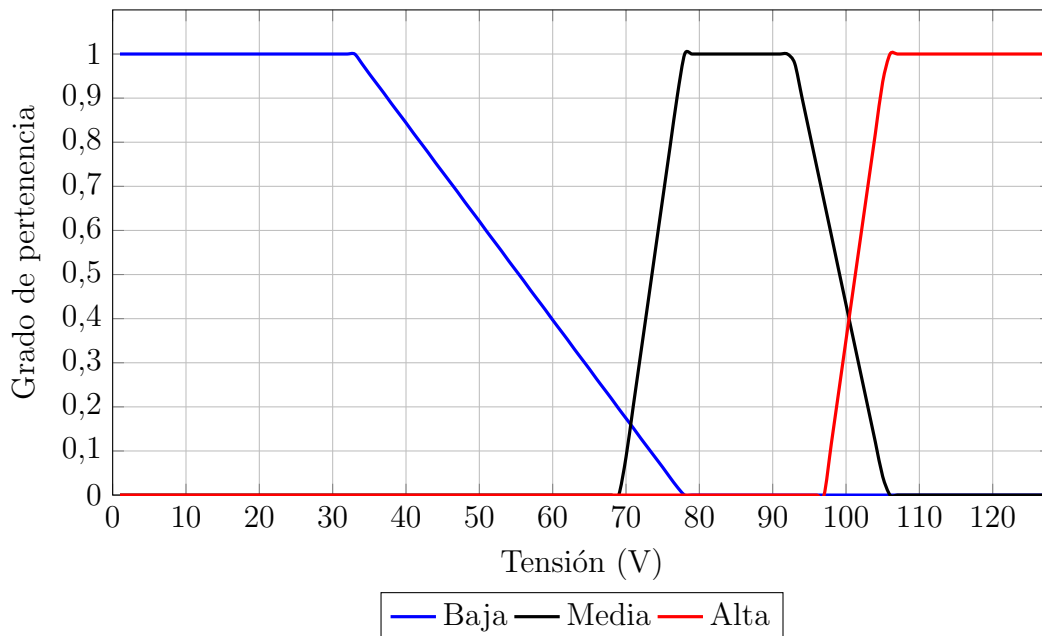


Figura 4-17.: Función de membresía para corriente en [44]

Como complemento a estas funciones se presenta en la Figura 4-18 la función de membresía del nivel del aceite aislante del dispositivo, medido en porcentaje y dividido en dos categorías, correspondiente a una operación baja y a un estado normal o alto [44].




Figura 4-18.: Función de membresía para el nivel del aceite aislante en [44]

Las 3 funciones de entrada sirven como base para el establecimiento de la función de membresía presentada en la Figura 4-19, donde se hace la clasificación final del estado del transformador a partir de un índice de salud medido en porcentaje.




Figura 4-19.: Función de membresía para el índice de salud en [44]

Por último para este modelo se desarrollaron las reglas difusas expuestas en la Tabla 4-4,

donde se relacionan los valores que puede tomar cada variable de entrada en la clasificación del estado de operación del dispositivo de análisis.

Tabla 4-4.: Reglas de sistema de lógica difusa mencionado en [44]

1. Si la tensión es baja , la corriente es media y el nivel de aceite es bajo , entonces la salud es pobre
2. Si la tensión es baja , la corriente es alta y el nivel de aceite es bajo , entonces la salud es pobre
3. Si la tensión es baja , la corriente es media y el nivel de aceite es alto , entonces la salud es buena
4. Si la tensión es baja , la corriente es alta y el nivel de aceite es alto , entonces la salud es media
5. Si la tensión es media , la corriente es media y el nivel de aceite es bajo , entonces la salud es pobre
6. Si la tensión es media , la corriente es alta y el nivel de aceite es bajo , entonces la salud es pobre
7. Si la tensión es media , la corriente es alta y el nivel de aceite es alto , entonces la salud es media
8. Si la tensión es alta , la corriente es media y el nivel de aceite es bajo , entonces la salud es pobre
9. Si la tensión es alta , la corriente es alta y el nivel de aceite es bajo , entonces la salud es pobre
10. Si la tensión es alta , la corriente es alta y el nivel de aceite es alto , entonces la salud es media
11. Si la tensión es alta , la corriente es media y el nivel de aceite es alto , entonces la salud es buena
12. Si la tensión es baja , la corriente es media y el nivel de aceite es bajo , entonces la salud es pobre

Por otro lado, con respecto al análisis de la vida remanente del aislamiento del transformador de potencia, utilizando la guía C57.91 del IEEE, se tuvo en cuenta la siguiente ecuación:

$$Life_y = e^{\frac{15000}{\Theta+273} - 27,064} \quad (4-3)$$

Donde Θ representa la temperatura de punto caliente y $Life_y$ el total de horas remanentes de vida del aislamiento. El valor de la temperatura máxima del transformador puede ser obtenida a partir de una medición directa en el dispositivo o utilizando la temperatura del aceite aislante y el conocimiento los parámetros físicos del transformador de potencia resumidos en la siguiente lista, con el uso de la guía GTC 50, en la cual se hace el estudio de la cargabilidad de los transformadores con aislamiento basado en aceite mineral [74]:

- Duración de carga pico
- Potencia nominal del transformador
- Temperatura ambiente
- Relación de pérdida
- Pico estimado de sobrecarga
- Carga anterior al pico de carga

A partir de estos modelos se puede realizar una comparación del desempeño y de la clasificación de los transformadores de potencia que son parte de la flota a analizar, considerando las diferentes variables de las cuales se basa cada uno para obtener un valor final. Por ello, en la siguiente sección se presentaran los resultados de implementación con valores provenientes del consumo de energía en el Campus Universitario de la Universidad Nacional.

5. Implementación de métodos y análisis de resultados

Para la construcción del modelo de Gestión de Transformadores presentado en la sección anterior se realizaron en primer medida pruebas con respecto a los métodos de predicción, para la identificación del mejor en cuanto un menor error (medido en RSME) en conjunto con el menor tiempo de cálculo en miras de su implementación en tiempo real. En el siguiente apartado se muestran estos resultados, considerando los diferentes tipos de demanda evidenciados en el Campus Universitario y en general del LAB+i.

5.1. Comparación de métodos de predicción

Para el análisis de la aplicabilidad de la predicción en la gestión de activos se tuvieron en cuenta los siguientes modelos:

- **Librería de Python Skforecast:** En esta librería se disponen de modelos de predicción basados en herramientas de regresión lineal, brindadas por la librería de Scikit Learn, donde el retraso de información es utilizado para la predicción de los siguientes valores, siendo un ejemplo el uso de datos registrados 24 horas antes para el diagnóstico de las siguientes 24 horas, denominados predictores. Dicha librería permite la simulación del método de predicción de demanda mostrado en [75], en el cual a partir de los datos históricos de consumo de 2 años se realizó la predicción de los valores futuros utilizando como base un sistema de Bosque Aleatorio (Random Forest), si bien se pueden utilizar los otros modelos disponibles en la librería de sklearn.
- **Librería de Python FbProphet:** Esta librería de software libre utilizada para manejo de información temporal desarrollada por Facebook permite realizar proceso de predicción de datos dependientes del tiempo, teniendo en cuenta los diferentes eventos históricos que puedan afectar a la información tales como el efecto de las estaciones y de los días festivos [76]. Esto se logra a partir de la incorporación de los modelos de predicción tradicionales como los expuestos a lo largo del presente informe y de un proceso de revisión en bucle.
- **Toolbox de Redes Neuronales de Matlab:** Gracias a las herramientas de esta caja de herramientas desarrollada por Mathworks se utilizó una Red Neuronal Recurrente

Basada en el módulo de LSTM y se ajustaron los respectivos hiperparámetros asociados de acuerdo con las tendencias a analizar. Específicamente se utilizó este tipo de red con motivo de identificar los patrones en intervalos de tiempo definidos, que permitan realizar un proceso de predicción con un error entre resultado y valor real pequeño [77].

- **Librería de python Statsmodels:** Librería que permite la utilización de un conjunto importante de modelos estadísticos para pruebas asociadas a análisis de datos. Para este proyecto se escogió un modelo estadístico basado en la estacionalidad en conjunto con el modelado AMIRA (SARIMA), en el cual a partir de los datos definidos en lapsos de tiempo personalizados se puede hacer un pronóstico del comportamiento de la información [78].

Con estos modelos en consideración se escogió como referencia la información de consumo de energía, medida en corriente por fase, proveniente del edificio nuevo de Enfermería del Campus Universitario durante 2 semanas desde el 24 de septiembre del 2018. En la Figura 5-1 se muestra el consumo durante esta semana, dado por un pico de 175A en el día miércoles y un consumo mayor a los 100A en los períodos correspondientes a actividades académicas y administrativas. Por este último aspecto, la corriente registrada en el día 30 de septiembre tiene un valor de entre 65 y 80A por corresponder a un día no hábil.




Figura 5-1.: Datos de consumo del edificio de enfermería durante 1 semana

A partir de los datos de esta edificación se realizó el siguiente procedimiento para obtener la predicción del día siguiente:

1. Revisión de la disponibilidad de información durante las dos semanas previas del día que se quiere predecir, entre lo que se incluyen posibles errores de registro por fallas en la comunicación y de medición.

2. Clasificación del día a predecir teniendo en cuenta las 4 categorías de referencia enunciadas en la sección previa.
3. Creación de archivos csv por medio de python para cada tipo de día, en los cuales se almacena de forma ordenada por fecha y hora la información registrada en el laboratorio que pertenece a cada una de las categorías. Estos elementos serán utilizados por cada uno de los métodos para facilitar el reconocimiento de patrones por parte de cada uno, asociado a los efectos de la estacionalidad de la información.
4. Aplicación de cada uno de los métodos de predicción para el mismo día de la semana, calculando a su vez el error RSME como punto de comparación con respecto al valor real.

A partir de este procedimiento se predijo el comportamiento en un día hábil que no sea viernes, resultados que se presentan en la Figura 5-2 para cada uno de los métodos mencionados. En esta se muestra un seguimiento de la tendencia por la mayor parte de los métodos, siendo la diferencia marcada por el error con respecto al diagnóstico original. Específicamente, se identifica que para los 4 modelos no se sigue el comportamiento variable de la corriente de la subestación de referencia ya que lo que se busca es acercarse a los valores medios de éste. Por ello, la predicción estimada por el método Prophet no cumple con los parámetros de precisión para ser considerado mientras que en los métodos de skforecast y de LSTM se obtiene una misma meseta.




Figura 5-2.: Ejemplo de predicción de consumo para un día hábil

No obstante, para disponer de la información suficiente para el desarrollo del diagnóstico es necesario contar con la información de consumo de la subestación de las dos semanas anteriores, teniendo en cuenta que la información de las categorías, aparte del horario hábil, se registran un día cada semana. Por ello, para identificar el desempeño de cada uno de los métodos de predicción, se consideró la información de consumo de los días entre el 7 de mayo del 2018 hasta el 27 de mayo del 2018 del mismo edificio.

En la Figura 5-3 se presentan los resultados para el caso de la predicción de un día hábil, donde los métodos de LSTM y SKforecast obtienen el mismo comportamiento de meseta mientras que el método SARIMA presenta un pico de corriente de 170A, si bien la mayor diferencia entre ellos consiste en el tiempo de ejecución y del formato de la información.

A su vez, al comparar el desempeño en las Figuras 5-2 y 5-3 se identificó que para el desempeño de los modelos no sólo se debe considerar el tipo de día a analizar sino también la calidad de información y del comportamiento de los métodos iterativos, en los que se obtiene un resultado diferente con cada simulación.




Figura 5-3.: Predicción de corriente en el período hábil

Gracias al acceso de información de varios días con la misma categoría se puede apreciar en la Figura 5-3 la cercanía de pronóstico con respecto al valor real por parte de todos los métodos. Sin embargo, el fenómeno no sucede en la Figura 5-4, donde el método de SARIMA presenta una diferencia de pronóstico con respecto a los otros métodos.




Figura 5-4.: Predicción de corriente para el día viernes

Dentro de ello al comparar el desempeño de predicción del día viernes en la Figura 5-4 con el dado en los días hábiles en la Figura 5-3 se muestra que, a excepción del método SARIMA, los métodos de predicción aproximan el comportamiento del sistema a un tipo de meseta, clave para el posterior uso de ellos con el indicador de estado de los transformadores.




Figura 5-5.: Predicción de corriente para el día sábado

Al mismo tiempo, dicho comportamiento se presenta para los casos de las predicciones en los días sábado y festivos tal como se evidencia en las Figuras 5-5 y 5-6 respectivamente, siendo los valores cercanos a los registrados por el medidor. En este caso se considera que, debido a la naturaleza de consumo durante este período de análisis, no se reconoce una tendencia clara de consumo y por ende los modelos de comportan de forma diferenciada.




Figura 5-6.: Predicción de corriente para el día festivo

Las diferencias en pronóstico se deben principalmente por el uso de información limitada en el caso de las categorías diferentes a los días hábiles. En el intervalo de análisis se presenta la información de 7 días para realizar el diagnóstico del consumo si el día que sigue corresponde a un día hábil mientras que esta cantidad se reduce para las otras 3 categorías, teniendo un valor máximo de 3 días disponibles para realizar esta predicción. Asociado a estos resultados se presenta en la Tabla 5-1 los valores de diferencia entre pronóstico y valor real medidos en RSME.

Tabla 5-1.: RSME para los diferentes métodos de predicción

Pronóstico	Días Hábiles	Viernes	Sábados	Festivos
SARIMA	17.680746	28.3213636	8.52923476	6.84180254
Skforecast	14.4174501	11.0013961	8.52923476	2.02676727
LSTM	12.0948504	14.4216867	11.4017423	1.98750599

Tal como se puede evidenciar en la Tabla precedente, el valor final del error disminuye para los casos de viernes, sábados y festivos a excepción del caso especial del método SARIMA enunciado en la Figura 5-4. Esto resultados permiten identificar que estos diagnósticos se

pueden utilizar para el desarrollo del sistema de gestión de activos ya que los valores de corriente, variable clave para definir la categoría de los transformadores, difieren en un valor RSME de 18 Amperios. A su vez, como se va a presentar en el siguiente desarrollo, son un aspecto clave para analizar del desempeño del sistema si hay un problema de comunicación o registro de información.

5.2. Implementación del sistema de gestión con predicción

Para la prueba de desempeño se tomaron en cuenta cuatro subestaciones, que representan diferentes tipos de demanda descritas en la siguiente lista, si bien este mismo sistema se puede aplicar a cualquier transformador mientras se tenga disponibilidad de información de mínimo 2 semanas precedentes a su uso con respecto al módulo de predicción. En el **Anexo A** se presenta el desarrollo detallado del código escrito en el lenguaje de python.

- **Facultad de Odontología:** Edificio donde se realizan clases teóricas y prácticas con laboratorios propios, con una mayor demanda en los días hábiles y sábados.
- **Auditorio León de Greiff:** Se realiza un conjunto reducido de clases y eventos de gran envergadura, por lo que la demanda sigue un patrón de consumo diferente al resto de escenarios.
- **Facultad de Medicina:** Dedicado a clases y laboratorios con un uso de energía importante en los días hábiles. También dispone de un sistema de generación solar de 70kWp.
- **Edificio Nuevo de Enfermería:** Dedicado a clases y, debido a su reciente construcción, presenta una demanda relativamente menor con respecto a los otras subestaciones.

En las Figuras 5-7 y 5-8 se muestra el perfil de la corriente y tensión por fase de los respectivos transformadores de potencia en la semana anterior del diagnóstico, en la cual se aprecia la diferencia de demanda entre cada una de las subestaciones. Como complemento en la Tabla 5-2 se muestra las especificaciones técnicas de estas subestaciones.

Específicamente, el perfil de tensión se diferencia del de corriente en la resolución con la cual se hace el muestreo de la información por parte de los medidores de energía, siendo el caso del Auditorio León de Greiff, donde esta cantidad es menor para la tensión. Al mismo tiempo, entre estas gráficas se identificó una relación en la cual la tensión se va modificando asociada con el comportamiento de la corriente en conjunto con los otros factores de la operación.




Figura 5-7.: Comportamiento semanal de la corriente para el caso de estudio




Figura 5-8.: Comportamiento semanal de la tensión para el caso de estudio

Tabla 5-2.: Valores base de subestaciones de análisis

Subestación	Tensión Nominal (V)	Potencia Nominal (kVA)	Edad (Años)
Escuela de Medicina	128	400	30
Facultad de Odontología	128	150	30
Auditorio León de Greiff	128	225	35
Edificio de Enfermería	128	300	5

5.2.1. Aplicación de modelos de referencia de análisis de transformadores

En primera instancia, al aplicar el modelo de ponderación se identificó que durante el período de análisis, correspondiente a dos semanas dentro del período con mayor demanda no se alcanza a registrar a un nivel mayor de 0.6 de la corriente máxima de los transformadores de cada subestación tal como se presenta en la Figura 5-9 para los edificios de Odontología y de Enfermería. Cabe aclarar que en vez de usar la potencia aparente consumida como se propone en [42] se analizó la corriente con motivo de comparar cada uno de los métodos en las secciones anteriores con el modelo de gestión propuesto.




Figura 5-9.: Análisis de picos de corriente con respecto a las categorías en [42]

A partir de esta información se realizó el cálculo del valor final del indicador según lo estipulado en la sección anterior, donde se obtiene un valor entre 0 y 15 asociado al índice de salud aproximado del transformador de potencia, ya que no se dispone de la totalidad de información sugerida en [42]. En la Tabla 5-3 se presenta el índice de salud obtenido para cada una de las 4 subestaciones.

Se identificó que, para este modelo, la única diferencia apreciable corresponde a la diferencia de edad entre cada dispositivo, resultando en un puntaje perfecto para el edificio de enfermería al ser el más reciente entre los demás transformadores. En los otros 3 la diferencia es mínima, asociada a su tiempo de vida actual estimado entre los 30 y 35 años.

Tabla 5-3.: Indicador final de salud siguiendo la metodología de [42]

Subestación	Valor del indicador
Medicina	13.75
Enfermería	15
Auditorio León de Greiff	13.125
Odontología	13.75

Por otra parte, en la aplicación de la guía IEEE C57.91 sólo se dispuso de la información de la subestación del edificio de medicina, si bien esta es una referencia para la identificación de la validez de la información de gestión ya que la relación de potencia consumida con respecto a la nominal afecta directamente a la temperatura de punto caliente registrada. A partir de estos valores se presenta en la Figura 5-10 el valor de años de vida remanente calculada para este edificio.

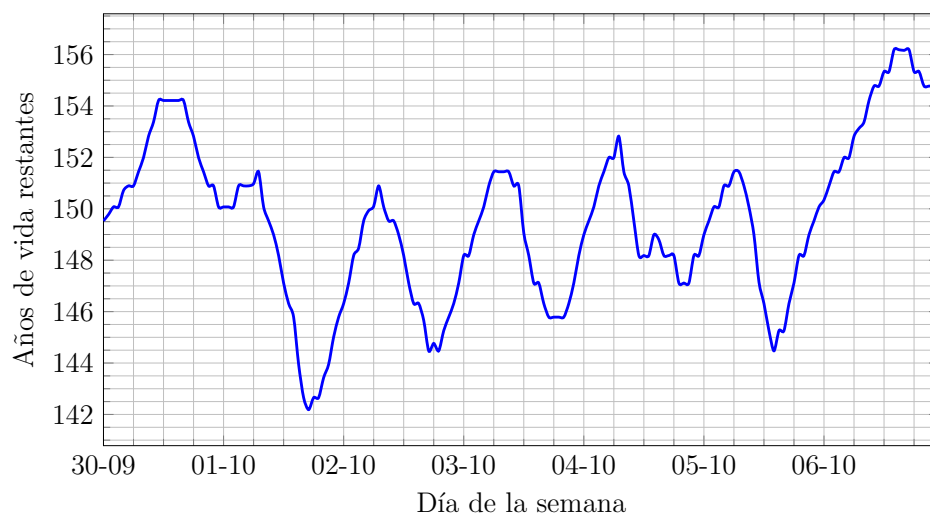


Figura 5-10.: Resultados de implementación de [73] para la subestación de medicina

En el gráfico de vida remanente se identificó un valor final mayor a 100 años, lo que representa el caso especial de consumo asociado con la capacidad nominal de la flota de transformadores que oscila entre un 20 % y 60 %, lo que también causa que se registre una temperatura del

aceite aislante entre 30 y 40 grados centígrados. No obstante, se reconoció que hay un cambio del valor final a lo largo del período de análisis, asociado con esta demanda en el edificio.

Finalmente, en el modelo de referencia de lógica difusa se obtuvo que, para cada una de las subestaciones, el valor final del indicador de salud es el mismo. En la Figura 5-11 se presenta este comportamiento, donde se registra un valor constante de 91.55 para cada uno de los transformadores analizados.




Figura 5-11.: Resultados de implementación de sistema de lógica difusa propuesta en [44]

Esto se debe a que los niveles de tensión y corriente se mantienen en las categorías óptimas de operación (corriente media y tensión alta) mientras que el nivel del aceite se mantiene constante, siendo este último el elemento a partir del cual se hace la asignación de las categorías mientras los otros parámetros corresponden al cumplimiento de calidad de la operación. En la siguiente sección se expondrán los resultados para el indicador propuesto en el documento de trabajo y su comparación con estos métodos.

5.2.2. Resultados de modelo propuesto

A partir de estos datos, y con motivo de comparar el desempeño con información real y la resultante de la predicción, se presenta la Figura 5-12 la aplicación del método de gestión con los datos reales, donde se aprecia que cada uno de los transformadores se encuentra

clasificado en una categoría diferente, a excepción de los de Odontología y Medicina en las horas de la mañana. Esto se asocia principalmente a su similitud de tiempo de operación en conjunto con el porcentaje de demanda real, si bien para el caso del edificio de la escuela de medicina el efecto de la generación solar hace disminuir la carga registrada en el medidor del transformador de la subestación principal.




Figura 5-12.: Valor real del índice de Salud

Entre la categorización se identificó que para el caso del edificio de enfermería se registró un valor máximo de 11, que representa la mejor categoría, dada por la antigüedad del edificio con respecto a las otras 3 subestaciones. De la misma manera la subestación de León de Greiff tiene un valor mínimo de 8 al ser la subestación con mayor edad, seguida por la subestación de Odontología, que registra un valor en el punto medio de análisis.

A su vez, debido a la falta de información en tiempo real luego de las 8 de la mañana del día analizado en la escuela de Medicina el indicador reduce su valor de la misma manera que la interpolación lineal de la corriente, lo que corresponde a la identificación de esta novedad por medio de la clasificación de los parámetros de tensión y corriente asociados a las funciones de membresía en la Figura 4-11 y Figura 4-12. Este tipo de gráficas permite identificar los retos de implementación para casos reales, en donde la comunicación o los medidores de energía pueden fallar.

Este comportamiento reportado en la Figura 5-12 para el edificio de Medicina también permite mostrar los cambios de categoría a medida que aumenta el consumo de energía en el día hábil, llegando a obtener en las 11 de la mañana un valor mínimo de 7.2. En este caso, a diferencia de las otras subestaciones, el comportamiento de la demanda medida en tensión y corriente permite apreciar un cambio en el indicador.

Por otro lado, como se aprecia en la Figura 5-13 los valores predichos de los indicadores de cada uno de los transformadores analizados conservan las mismas categorías que los identificados en la Figura 5-12, mostrando la eficacia del método de predicción y teniendo en cuenta que en los datos de entrenamiento no hay ningún tipo de falta de información. Esto último beneficia al modelo estadístico hacia el reconocimiento de cada uno de los casos de consumo expuestos para cada uno de los edificios analizados.




Figura 5-13.: Valor predicho del Índice de Salud

De la misma manera en el transformador del edificio de medicina se presenta un cambio de categoría a lo largo del día de operación, acercándose en las horas hábiles a los valores predichos del Auditorio León de Greiff, comportamiento similar al registrado en la Figura 5-12. A su vez, asociado con el error de la predicción se presenta en los otros 3 transformadores una fluctuación del valor en ciertas horas del día sin desviarse en un cambio de categoría. De esta forma se muestra la confiabilidad del diagnóstico y de la viabilidad de identificar de forma rápida el comportamiento de la red. Para el edificio de Enfermería se presenta un cambio

menor ya que al tener un grado de pertenencia de 1 a la máxima categoría esta fluctuación no es notoria.

Estos valores numéricos surgen del proceso de defuzzificación del sistema de lógica difuso expuesto en la sección previa, en el cual el programa ejecutado en python entrega estos valores numéricos, asociado a que gracias a la distribución como se muestra en la Figura 4-14 el grado de pertenencia del transformador varía entre 0 y 1 entre cada categoría.

Como último punto de enfoque en esta presentación de resultados se mostrará un análisis adicional con respecto a la implementación del diagnóstico en tiempo real y de uso en otro tipo de escenarios y condiciones.

5.2.3. Comparación de resultados

Para la comparación entre metodologías y de análisis de viabilidad del modelo de gestión se recopiló la clasificación final de cada sistema y se organizó la respectiva información en la Tabla 5-4. Con este punto de enfoque se identificaron las diferencias de diagnósticos basados en la comparación del valor final entre subestaciones y del desempeño basado en las categorías de cada elemento.

Tabla 5-4.: Valores de salida de los métodos analizados en el informe

Subestación	Modelo de ponderación	Modelo original de Lógica Difusa	IEEE C57.91	Modelo AM propuesto
Medicina	Muy Bueno	Buena	Alto*	Bueno
Enfermería	Muy Bueno	Buena	-	Muy Bueno
Auditorio León de Greiff	Muy Bueno	Buena	-	Bueno
Odontología	Muy Bueno	Buena	-	Bueno

En primera instancia, se evidenció que en el modelo de ponderación y lógica difusa original no se presentaron diferencias en las categorías de los 4 transformadores al considerar el mínimo consumo de potencia con respecto a la capacidad instalada. En conjunto con esta problemática se identificaron los retos asociados con la disponibilidad de información ya que para esta comparación se tuvo que reducir el número de variables consideradas para cada modelo.

Esta problemática también se identificó en el modelo térmico ya que este análisis se limita a la información disponible asociada con medidores de temperatura de los transformadores de potencia. A su vez, debido a la demanda de estos edificios se obtienen valores mayores a 60 años de vida remanente, lo que demuestra que los métodos tradicionales no se pueden aplicar para el caso de una baja demanda contrastada con el valor nominal de potencia, que corresponde a unos valores de entre 20 y 60 % en el caso de estudio.

En último lugar, entre los cuatro modelos analizados el único en el cual se puede apreciar una diferencia en la categorización del transformador de potencia entre dispositivos de la misma flota corresponde al nuevo modelo propuesto en el informe, permitiendo diferenciar la operación de cada uno y de vislumbrar maneras de gestión de la vida de los activos.

5.2.4. Retos de implementación

A partir de los casos analizados dentro de la investigación y con el objetivo de implementar el sistema de una forma continua asociada con los procesos del LAB+i se identificaron algunos retos asociados a la gestión de activos:

- **Disponibilidad continua de información:** Asociada al desempeño óptimo del diagnóstico, ya que una falta de información durante el tiempo de ejecución no permitiría la gestión adecuada del sistema.
- **Escalabilidad:** Para un diagnóstico de la flota de transformadores es clave que todas las subestaciones a analizar tengan una medición constante durante el tiempo de análisis, lo que hace difícil la construcción del sistema con un número alto de ellos.
- **Errores de diagnóstico:** El uso de los métodos de predicción dependen fuertemente de la disponibilidad de información en los intervalos esperados en conjunto con los errores causados por fallas cercanas al tiempo de análisis. A su vez, a medida que se aumenta el horizonte de predicción con respecto a la información de entrenamiento se aumenta forma proporcional el error.




Figura 5-14.: Pérdida de información en medición al Auditorio León de Greiff

En primera instancia en la Figura 5-14 se muestra el registro de información de una semana del Auditorio León de Greiff, en el cual se presenta un período de falta de información del 15 de febrero del 2020 al 17 de febrero del mismo año, lo que representa tanto un problema en tiempo real como de aumento del error en el diagnóstico.

De la misma manera, en la figura 5-15 se presenta el gráfico de corriente para el intervalo entre el 11 de diciembre de 2019 al 22 de diciembre del mismo año, en la cual se tienen disponibles para todo el intervalo los datos de 2 subestaciones mientras que para las subestaciones de Medicina y Enfermería en algunos días la información no cambia a lo largo del tiempo, haciendo que el indicador presente los resultados en la Figura 5-16.




Figura 5-15.: Comportamiento de referencia de la corriente para el caso de estudio

En específico, los valores del índice de salud para el edificio de medicina se mantienen constantes ya que los valores de diagnóstico no cambian a lo largo del intervalo analizado. A su vez, debido a la edad del transformador del edificio de Enfermería tampoco se presentan cambios en el valor del indicador en el intervalo. No obstante, las mediciones correspondientes al edificio de odontología si tuvieron una modificación asociada al estado de operación durante los días de mayor demanda, es decir, el aumento de la potencia consumida hizo que se presentara un cambio del valor numérico a lo largo del día de operación sin modificar la categoría.

Por último, en el análisis de la precisión del diagnóstico se presenta en la Figura 5-17 los datos de entrenamiento para la predicción del comportamiento de la demanda para un día hábil, que presentan un comportamiento diferenciado con un mayor pico de consumo en el día 26 de septiembre del 2018.




Figura 5-16.: Comportamiento del indicador de desempeño ante intermitencia de información




Figura 5-17.: Datos de referencia para predicción

Con esta información de base se analizó el desempeño de cada uno de los métodos propuestos, identificando en el caso del método SARIMA un resultado con una diferencia de más de 40 A entre las horas 15 y 18, tal como se evidencia en la Figura 5-18. Este comportamiento permite constatar que, a pesar de las diferencias en la forma de la curva de consumo, el método escogido continúa prediciendo valores dentro de la tendencia de consumo de la subestación.




Figura 5-18.: Predicción de corriente con alto error en el diagnóstico

5.2.5. Ampliación de escenarios de análisis

El modelo de gestión propuesto se puede escalar a un conjunto mayor de transformadores de potencia siempre que se tenga la disponibilidad de los 3 parámetros de referencia, que corresponden a la tensión, corriente y edad. En términos generales no existe un límite de implementación de este indicador ya que los tiempos de ejecución son de menos de 1 segundo por punto en el intervalo. En la tabla 5-5 se presentan las subestaciones en el LAB+I que tienen la información necesaria para la implementación del modelo de gestión, pero que por su disponibilidad, calidad de información y retos asociados a la forma de registro no fueron consideradas dentro del documento.

Dentro de este campo también se puede realizar la integración de otros tipos de variables en el proceso de diagnóstico del sistema ya que la lógica difusa tiene flexibilidad para agregar nuevas reglas y de asignar nuevas funciones de membresía. Un ejemplo de estas variables disponibles de forma intermitente en la base de datos del LAB+i se presentan en la siguiente lista:

- **Temperatura:** Valor del aceite aislante del dispositivo, a partir del cual se puede obtener una aproximación al valor del punto caliente del transformador. En la Figura 5-19 se muestra el comportamiento de este elemento para el edificio de la escuela de Medicina en el 2018.
- **Factor de Potencia:** Sugerido para identificar factores de degradación adicional del

aislante y de identificación de efectos asociados a mantenimientos y de evolución de la demanda.

- **Indicadores de calidad de potencia:** Asociados a los fenómenos causados por la inclusión de electrónica de potencia relacionada con sistemas de generación renovable y de las cargas críticas de los laboratorios de investigación.

Tabla 5-5.: Subestaciones con disponibilidad para análisis de desempeño

Subestación	Potencia Nominal (kVA)
Campus Universitario - Principal	150
Aulas de Ciencias Humanas	112.5
Postgrados en Ciencias Humanas	225
Economía	225
Museo de Arte	225
Laboratorio de Hidráulica	75
Departamento de Farmacia	150
Departamento de Química	225
Aulas de Ingeniería	225
Facultad de Ciencias Agrarias	300
Supermercado y Aulas de Agronomía	500
UNISALUD	112.5

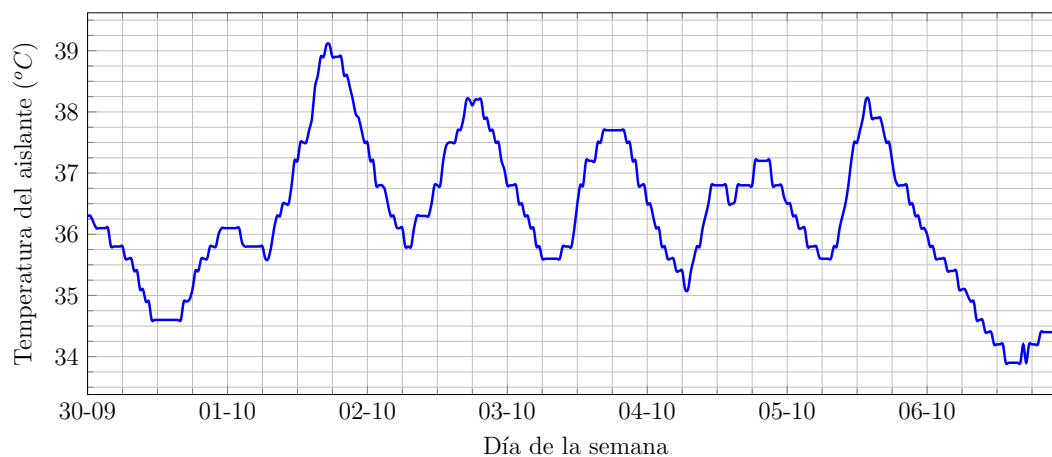


Figura 5-19.: Ejemplo de comportamiento de temperatura para subestación de Medicina

Con esta información se identifica de forma clara las tendencias que componen el comportamiento de los transformadores de potencia del Campus Universitario, utilizando una

herramienta que permite analizar tanto de forma individual como en grupos el estado de operación de estos dispositivos mientras se enfrentan problemas característicos del monitoreo en tiempo real.

5.2.6. Puntos de trabajo con respecto a modelos tradicionales

Por último, en el campo de la aplicación del modelo con respecto a las otras implementaciones disponibles en la literatura se identificó que, en conjunto con lo mencionado a lo largo del presente informe, se presenta una ventaja adicional correspondiente al manejo de la condición del transformador en tiempo real, esto a diferencia de los métodos tradicionales que buscan realizar el cálculo de un único valor que describa el estado acumulativo de sus componentes mientras se dejan de lado las variables operativas, que también aportan a su degradación y fallos en la operación.

El análisis de los valores obtenidos de la implementación de este modelo, en especial en el comportamiento que emula un cambio de categoría del transformador en tiempo real, es reflejo de la definición de las funciones de membresía del sistema. En específico, las distribuciones de campana en el caso de la corriente es la que permite la clasificación de los dispositivos, acotada a las condiciones del campus universitario. De la misma manera, el valle registrado en los casos de estudio muestra la principal ventaja del modelo de diagnosticar los cambios de condiciones de forma instantánea.

Dentro de ello en el análisis de los procesos físicos y de la representación del modelo de gestión se identificó que para el caso de los transformadores de potencia se cumplen los supuestos dados en los modelos de comparación, donde al tener un valor pequeño de corriente con respecto a su capacidad nominal en la teoría deberían ser dispositivos con una amplia vida remanente, pero no de la forma cómo se presentó por ejemplo en el modelo térmico (sujeto a errores de construcción del método de cálculo del punto caliente). Por ello, la revisión del comportamiento en tiempo real es clave para el diagnóstico del sistema, con opción de agregar información de acuerdo con la disponibilidad de mediciones.

En el caso de parámetros opcionales esta la potencia de salida, disponible para algunos medidores de energía si bien se optó por el uso de la corriente como indicador de nivel de demanda, ya que este valor no se ha utilizado en la literatura con los transformadores de distribución sino sólo como indicador de calidad de prestación del servicio. Por ello, se logró evidenciar la alternativa de usar este parámetro para eventuales sistemas de distribución, que sólo dispusieran de este valor en conjunto con la tensión. No obstante, el uso de la potencia activa, reactiva y aparente es posible a partir de la incorporación en el sistema de lógica difusa y como un aporte adicional de la calidad de prestación del servicio de energía eléctrica y su efecto en los transformadores.

6. Conclusiones y proyectos futuros

En este último capítulo se presentarán los principales hallazgos del desarrollo de la investigación, siguiendo la estructura del presente informe en conjunto con los proyectos futuros asociados con la Gestión de Activos en Flotas de transformadores de potencia.

6.1. Conclusiones

- A partir de la consulta del estado del arte asociado a la gestión de activos y de los modelos implementados de los transformadores de potencia se determinó que existe una amplia gama de formas de plantear los problemas de gestión, teniendo como base este dispositivo. No obstante, al depender de diferentes tipos de variables se dificulta su implementación para escenarios diferentes a su planteamiento inicial, es decir, no se es capaz de adaptar estos modelos a la disponibilidad de información variable y de comportamientos específicos de la demanda.
- Desde el planteamiento de los modelos de predicción se detectó el auge de la utilización de redes neuronales como método para el reconocimiento de tendencias asociadas a la operación del transformador de potencia, si bien se mantiene la dificultad de adaptar estos escenarios en los que se dispone de una información limitada.
- En el campo de la lógica difusa se dispone de metodologías basadas en el lenguaje humano con opciones de adaptación considerando distintas variables de análisis mientras que con la incorporación de modelos de predicción permite a través de un conjunto de información identificar las tendencias de los datos, diferenciados por los tiempos de ejecución y de la precisión necesaria para el análisis.
- Se identificó la facilidad del tratamiento de los datos de consumo de energía para la realización de los análisis de clasificación en conjunto con la capacidad de adaptación a cualquier lenguaje de programación y de disponibilidad de comunicaciones. De la misma manera el sistema de gestión propuesto se puede utilizar para un conjunto amplio de escenarios en los cuales se disponga de los valores de demanda de una flota de transformadores, también siendo capaz de incorporar otro tipo de variables contrastadas con la opinión de expertos.
- En el desarrollo del modelo de gestión de la flota de transformadores se determinó que el planteamiento de clasificación a partir de la lógica difusa es el paso a seguir

para crear un diagnóstico basado en opiniones de expertos, basado en una estructura que se adapta a las condiciones específicas de la investigación y de los objetivos de los operadores de red y las organizaciones involucradas.

- En la implementación de este sistema utilizando el lenguaje de programación **Python** se determinó que éste permite realizar un tratamiento organizado de la información proveniente de distintas fuentes tales como archivos de texto y bases de datos, lo que facilita su uso para sistemas de predicción y procesos de clasificación.
- La predicción basada en datos depende de la calidad de la información suministrada o almacenada por la base de datos de referencia, si bien es importante que se registre una tendencia clara en esta información que permita el entrenamiento del sistema. Con esto en consideración, el sistema de categorización de lógica difusa permite hacer un diagnóstico de la flota de transformadores de potencia a partir de las condiciones de operación y de la edad de la instalación a la vez que permite evidenciar en tiempo real posibles errores de desempeño o de registro de información, incluyendo los generados por predicciones.
- Con respecto a los métodos escogidos para el análisis de viabilidad del sistema de gestión de activos se concluye que estos no permiten la identificación de cambios en tiempo real de la condición de vida de los transformadores en conjunto con la imprecisión generada por la ausencia de información de medidas adicionales de las condiciones iniciales del dispositivo.
- El sistema de gestión propuesto permite evidenciar cambios de la condición del transformador de potencia en tiempo real en asociación con los parámetros de operación con los cuales se diseñaron las funciones de membresía y de la comparación con los datos históricos en un período dado, permitiendo ser una herramienta de diagnóstico tanto con corto como en largo plazo.
- El indicador final de gestión permite identificar a partir de un dato numérico el estado de operación de un transformador de potencia tanto de forma individual, contrastándolo con las categorías escogidas en el modelo de lógica difusa, como en comparación con otros dispositivos de la misma flota. Esto corresponde a la justificación de realización de operaciones de mantenimiento o reemplazo.
- El modelo construido es una alternativa a los modelos tradicionales para el diagnóstico de operación del transformador de potencia y su degradación, analizando su comportamiento en tiempo real en contraste con el estado acumulado de la condición del dispositivo. Esto se logró a partir del monitoreo de calidad de potencia basado en el conocimiento de las dinámicas de consumo del campus universitario.

6.2. Proyectos futuros

El uso de los sistemas de Gestión de Activos en la industria eléctrica ha cobrado importancia con respecto al cumplimiento de las nuevas normativas internacionales y de la necesidad del tratamiento del envejecimiento en los activos de los sistemas de transmisión y distribución, mientras se busca una implementación óptima en cuanto costo-beneficio. Por ello, se presentan los siguientes pasos correspondientes a la implementación de este modelo de gestión asociado a la flota de transformadores presentado en este documento:

- Aplicación en diferentes ecosistemas asociados a redes inteligentes, donde se presentan fenómenos que afectan la calidad de la energía y de la variación del consumo a lo largo del tiempo. Dentro de este ámbito se incluye el análisis de factibilidad de los distintos métodos de predicción y de la inclusión de nueva información al sistema de lógica difusa.
- Incorporación del diagnóstico a sistemas de gestión en tiempo real y de ajustes de acuerdo con los requerimientos del operador de red, entre lo que se encuentra la inclusión de nuevos factores o de otros activos del sistema para el diagnóstico de los transformadores de potencia.
- Uso del método para proyección de evolución de la red eléctrica y de reducción de riesgos de falla.

A. Resumen de Código Implementado

En el presente anexo se muestran los componentes del código implementado para el sistema de gestión, compuesto por dos archivos. El primero corresponde a las funciones de extracción de información y de predicción, donde se utilizan herramientas de Osisoft PI System para el tratamiento con el servidor principal. El segundo archivo contienen los comandos para el cálculo final del índice de salud para el respectivo conjunto de datos. La implementación se realizó con la versión 3.6.0 de python asociado a la disponibilidad de la librería pythonnet, que permite hacer la conversión de las funciones originales de tratamiento de información escritas en C# a lenguaje de python.

A.1. Funciones de Tratamiento de información proveniente del LAB+i

```
#Librerías para conexión a base de datos
import sys
sys.path.append('C:\\Program Files (x86)\\PIPC\\AF\\PublicAssemblies\\4.0\\')
import clr
clr.AddReference('OSIsoft.AFSDK')
from OSIsoft.AF.PI import *
from OSIsoft.AF.Search import *
from OSIsoft.AF.Asset import *
from OSIsoft.AF.Data import *
from OSIsoft.AF.Time import *
#Librerías para tratamiento de información
import datetime
import numpy
import csv
import pandas as pd
from numpy import array
#Librerías para construcción de predicción
from datetime import datetime as dt
import statsmodels.api as sm
import matplotlib.pyplot as plt
import holidays

#Funcion de Conexion al servidor principal
def connect_to_Server(serverName):
```

```

piServers = PIServers()
global piServer
piServer = piServers[serverName]
piServer.Connect(False)

#Función para obtener información a partir de TAG y Fecha
def get_tag_value(tagname, fecha):
    tag = PIPoint.FindPIPoint(piServer, tagname)
    valoresgraf = tag.InterpolatedValue(AFTime(fecha))
    #Valor interpolado
    try:
        float(valoresgraf.Value)
    except:
        valoresgraf.Value=numpy.nan
    return valoresgraf.Value

#Función para almacenar la información del LAB+i en una lista
def Import_PI(TAG_NAME, START_TIME, RATE, TOTAL_STEP):
    connect_to_Server("LABI")
    PI_Time=datetime.datetime.strptime(START_TIME,"%d/%m/%Y %I:%M:%S %p")
    Tot_time=[]
    Tot_Busq=[]
    for x in range(TOTAL_STEP):
        Tot_time.append((PI_Time +
                        datetime.timedelta(minutes=x*RATE)).strftime("%d/%m/%Y %I:%M:%S %p"))
    for y in Tot_time:
        Tot_Busq.append([y,get_tag_value(TAG_NAME,y)])
    time=[row[0] for row in Tot_Busq]
    data=[row[1] for row in Tot_Busq]
    Y_2=pd.DataFrame(data).interpolate().values.ravel().tolist()
    Tot_Busq_fin=[]
    for x in range(len(Y_2)):
        Tot_Busq_fin.append([time[x],Y_2[x]])
    #Graficación de referencia
    plt.plot(Tot_time,array([row[1] for row in Tot_Busq_fin]))
    plt.xticks([])
    plt.title('Datos Importados de PI System')
    plt.ylabel('Unidad de Medida')
    plt.xlabel('Tiempo')
    plt.show()
    #Variable final
    return Tot_Busq_fin

#Función para exportar información a CSV
def Export_to_CSV(NAME,VARIABLE,source):
    with open(source+NAME, mode='w', newline='') as employee_file:
        employee_writer = csv.writer(employee_file)
        employee_writer.writerow(["Tiempo", "Variable_Salida"])

```

```

employee_writer.writerows(VARIABLE)

#Registrar información en la base de datos del servidor
def Save_Data(tagname,valor,fecha):
    tag = PIPoint.FindPIPoint(piServer, tagname)
    tag.UpdateValue(AFValue(valor,AFTime(fecha)),0)

def Save_2_PI(Tag,List_Data,HEADERS):
    for data in List_Data[HEADERS:]:
        Save_Data(Tag,data[1],data[0])

#Desarrollo del método de predicción
def Prediction(y_val,df,name):
    Festivos_Col=holidays.COL()
    Dias_No_Hab=pd.DataFrame()
    Dias_Hab=pd.DataFrame()
    Viernes=pd.DataFrame()
    Sabados=pd.DataFrame()
    PI_Time=y_val
    Tot_time=[]
    for x in range(24):
        Tot_time.append((PI_Time +
                        datetime.timedelta(minutes=(x+1)*60)).strftime("%d/%m/%Y %I:%M:%S %p"))
    df = df.set_index('Time')
    #Creación de elementos de entrenamiento
    for i, row in df.iterrows():
        if i.weekday() == 6 or i in Festivos_Col:
            df1=pd.DataFrame([[i,row[name]]], columns=["Hora", "y"])
            Dias_No_Hab=Dias_No_Hab.append(df1, ignore_index=True)
        elif i.weekday() == 5:
            df1=pd.DataFrame([[i,row[name]]], columns=["Hora", "y"])
            Sabados=Sabados.append(df1, ignore_index=True)
        elif i.weekday() == 4:
            df1=pd.DataFrame([[i,row[name]]], columns=["Hora", "y"])
            Viernes=Viernes.append(df1, ignore_index=True)
        else:
            df1=pd.DataFrame([[i,row[name]]], columns=["Hora", "y"])
            Dias_Hab=Dias_Hab.append(df1, ignore_index=True)
    Comp_No_Hab=pd.DataFrame(Dias_No_Hab['y'])
    Comp_Hab=pd.DataFrame(Dias_Hab['y'])
    Sabados=pd.DataFrame(Sabados['y'])
    Viernes=pd.DataFrame(Viernes['y'])
    Fecha_ref=dt.strptime(Tot_time[0], '%d/%m/%Y %I:%M:%S %p')
    #Escogencia de información de acuerdo con día a predecir
    if Fecha_ref.weekday() ==6 or Fecha_ref in Festivos_Col:
        y=Comp_No_Hab
    elif Fecha_ref.weekday() ==5:
        y=Sabados

```



```

elif Fecha_ref.weekday()==4:
    y=Viernes
else:
    y=Comp_Hab
#Implementación método ARIMA
mod = sm.tsa.statespace.SARIMAX(y,
                                order=(0, 0, 2),
                                seasonal_order=(1, 2, 2, 24),
                                enforce_stationarity=False,
                                enforce_invertibility=False)

results = mod.fit()
print(results.summary().tables[1])
#Predicción para 24 horas
pred = results.get_forecast(steps=24)
res=pred.predicted_mean.tolist()
string_T=Tot_time
End_pred=[]
for i in range(len(string_T)):
    End_pred.append(res[i])
#Guardado de información
return End_pred

```

A.2. Código Final

```

#Librerías para tratamiento de información
import pandas as pd
from funciones import Import_PI, Prediction
#Librerías para clasificación de información
import datetime as dt
import holidays
#Librerías para implementación de lógica difusa
import skfuzzy as fuzz
from skfuzzy import control as ctrl
import math
import numpy as np
#TAGS del LAB+i para importar información
#Corrientes de subestación
Curr_A=["100_CampusBog_SE_14_Medicina_I_L1", "I_A"]
Curr_B=["100_CampusBog_SE_14_Medicina_I_L2", "I_B"]
Curr_C=["100_CampusBog_SE_14_Medicina_I_L3", "I_C"]
#Tensiones de subestación
Volt_A=["100_CampusBog_SE_14_Medicina_V_L1", "V_A"]
Volt_B=["100_CampusBog_SE_14_Medicina_V_L2", "V_B"]
Volt_C=["100_CampusBog_SE_14_Medicina_V_L3", "V_C"]
#Vector de agrupación de variables
Final=[Curr_A,Curr_B,Curr_C,Volt_A,Volt_B,Volt_C]
#Especificaciones técnicas del Transformador

```

```

Age_traf=30
KVA=400
V_Nom=128
#Parámetros de ajuste lógica difusa de acuerdo con valores nominales
Factor_Aj=math.floor(KVA*1000/(3*V_Nom))/100
Factor_Volt=V_Nom/300
Univ_Volt=math.floor(301*Factor_Volt)
Univ_Curr=math.floor(131*Factor_Aj)
#Creación de las variables que almacenan las funciones de membresía
Voltage = ctrl.Antecedent(np.arange(0,Univ_Volt, 1), 'Voltage')
Current = ctrl.Antecedent(np.arange(0, Univ_Curr, 1), 'Current')
Age=ctrl.Antecedent(np.arange(0, 61, 1), 'Age')
Health = ctrl.Consequent(np.arange(0, 14, 1), 'Health')
#Generación de las funciones de membresía de acuerdo con su categoría
Voltage['Low'] = fuzz.trapmf(Voltage.universe,
    [-26.64*Factor_Volt, 0,75*Factor_Volt,180*Factor_Volt])
Voltage['Medium'] = fuzz.trapmf(Voltage.universe,
    [160*Factor_Volt, 180*Factor_Volt, 215*Factor_Volt, 245*Factor_Volt])
Voltage['High'] = fuzz.trapmf(Voltage.universe,
    [225*Factor_Volt, 245*Factor_Volt, 312.5*Factor_Volt, 412.5*Factor_Volt])
Current['Good'] = fuzz.gaussmf(Current.universe, 20*Factor_Aj, 10.62*Factor_Aj)
Current['Medium'] = fuzz.gaussmf(Current.universe, 50*Factor_Aj, 10.62*Factor_Aj)
Current['Regular'] = fuzz.gaussmf(Current.universe, 80*Factor_Aj, 10.62*Factor_Aj)
Current['Critical'] = fuzz.gaussmf(Current.universe, 110*Factor_Aj, 10.62*Factor_Aj)
Age['New'] = fuzz.trimf(Age.universe, [-25 ,0 ,33.41])
Age['Slightly_Low'] = fuzz.trimf(Age.universe, [27.1, 37.22, 47.5])
Age['Old'] = fuzz.trimf(Age.universe, [43.1, 59.76, 79.1])
Health['Bad'] = fuzz.trapmf(Health.universe, [0, 1.5, 2.5, 4])
Health['Medium'] = fuzz.trapmf(Health.universe, [3, 4.5, 5.5, 7])
Health['Good'] = fuzz.trapmf(Health.universe, [6, 7.5, 8.5, 10])
Health['Very_Good'] = fuzz.trapmf(Health.universe, [9, 10.5, 11.5, 13])
#Reglas Difusas
rule1 = ctrl.Rule(Current['Good'] & (Voltage['High'] | Voltage['Medium'])
    & Age['New'] , Health['Very_Good'])
rule2 = ctrl.Rule(Current['Good'] & (Voltage['High'] | Voltage['Medium'])
    & Age['Slightly_Low'] , Health['Good'])
rule3 = ctrl.Rule(Current['Good'] & (Voltage['High'] | Voltage['Medium'])
    & Age['Old'] , Health['Medium'])
rule4 = ctrl.Rule(Current['Good'] & Voltage['Low'] & Age['New'] , Health['Good'])
rule5 = ctrl.Rule(Current['Good'] & Voltage['Low'] & Age['Slightly_Low'] , Health['Medium'])
rule6 = ctrl.Rule(Current['Good'] & Voltage['Low'] & Age['Old'] , Health['Bad'])
rule7 = ctrl.Rule(Current['Medium'] & (Voltage['High'] | Voltage['Medium'])
    & Age['New'] , Health['Good'])
rule8 = ctrl.Rule(Current['Medium'] & (Voltage['High'] | Voltage['Medium'])
    & Age['Slightly_Low'] , Health['Medium'])
rule9 = ctrl.Rule(Current['Medium'] & (Voltage['High'] | Voltage['Medium'])
    & Age['Old'] , Health['Bad'])
rule10 = ctrl.Rule(Current['Medium'] & Voltage['Low'] & Age['New'] , Health['Medium'])

```

```

rule11 = ctrl.Rule(Current['Medium'] & Voltage['Low'] & Age['Slightly_Low'] , Health['Bad'])
rule12 = ctrl.Rule(Current['Medium'] & Voltage['Low'] & Age['Old'] , Health['Bad'])
rule13 = ctrl.Rule(Current['Regular'] & (Voltage['High'] | Voltage['Medium'])
    & Age['New'] , Health['Medium'])
rule14 = ctrl.Rule(Current['Regular'] & (Voltage['High'] | Voltage['Medium'])
    & Age['Slightly_Low'] , Health['Bad'])
rule15 = ctrl.Rule(Current['Regular'] & (Voltage['High'] | Voltage['Medium'])
    & Age['Old'] , Health['Bad'])
rule16 = ctrl.Rule(Current['Regular'] & Voltage['Low'] & Age['New'] , Health['Bad'])
rule17 = ctrl.Rule(Current['Regular'] & Voltage['Low'] & Age['Slightly_Low'] , Health['Bad'])
rule18 = ctrl.Rule(Current['Regular'] & Voltage['Low'] & Age['Old'] , Health['Bad'])
rule19 = ctrl.Rule(Current['Critical'] & (Voltage['High'] | Voltage['Medium'])
    & Age['New'] , Health['Bad'])
rule20 = ctrl.Rule(Current['Critical'] & (Voltage['High'] | Voltage['Medium'])
    & Age['Slightly_Low'] , Health['Bad'])
rule21 = ctrl.Rule(Current['Critical'] & (Voltage['High'] | Voltage['Medium'])
    & Age['Old'] , Health['Bad'])
rule22 = ctrl.Rule(Current['Critical'] & Voltage['Low'] & Age['New'] , Health['Bad'])
rule23 = ctrl.Rule(Current['Critical'] & Voltage['Low'] & Age['Slightly_Low'] , Health['Bad'])
rule24 = ctrl.Rule(Current['Critical'] & Voltage['Low'] & Age['Old'] , Health['Bad'])
#Creación del sistema de lógica difusa
tipping_ctrl = ctrl.ControlSystem([rule1, rule2, rule3, rule4, rule5, rule6, rule7,
    rule8, rule9, rule10 , rule11, rule12, rule13, rule14, rule15 , rule16,
    rule17, rule18, rule19, rule20, rule21, rule22 , rule23, rule24])
tipping = ctrl.ControlSystemSimulation(tipping_ctrl)
#Proceso de clasificación de acuerdo con las 4 categorías de demanda
df=pd.DataFrame()
df["Time"]=0
#Festivos de Colombia
Festivos_Col=holidays.COL()
#Creación de Dataframe que contiene la información de las 2 semanas de referencia
for value in Final:
    Dat_1=pd.DataFrame()
    Dat_1=pd.DataFrame(Import_PI(value[0], "25/09/2018 12:00:00 AM",60,24*14),
        columns=['ds', 'y'])
    if df["Time"].empty:
        df["Time"]=Dat_1['ds']
    df[value[1]]=Dat_1['y']
df["Time"]=pd.to_datetime(df["Time"], format='%d/%m/%Y %I:%M:%S %p')
#Dataframes para predicción según tipo de día
Dias_No_Hab=pd.DataFrame()
Dias_Hab=pd.DataFrame()
Viernes=pd.DataFrame()
Sabados=pd.DataFrame()
x=pd.to_datetime(df['Time'], format='%d/%m/%Y %I:%M:%S %p')
y_val=x.iloc[-1]
PI_Time=y_val
Tot_time=[]

```

```

for x in range(24):
    Tot_time.append((PI_Time +
                    dt.timedelta(minutes=(x+1)*60)).strftime("%d/%m/%Y %I:%M:%S %p"))
#Proceso de predicción y almacenado en un Dataframe
df_pred=pd.DataFrame()
df_pred["Time"]=Tot_time
for value in Final:
    Dat_2=pd.DataFrame()
    Dat_2=pd.DataFrame(Prediction(y_val,df,value[1]))
    df_pred[value[1]]=Dat_2

Results=[]
#Implementación del sistema de lógica difusa con la información del LAB+i
for index,row in df_pred.iterrows():
    #Promedio de la magnitud
    tipping.input['Voltage'] = (row[Volt_A[1]]+row[Volt_A[1]]+row[Volt_A[1]])/3
    tipping.input['Current'] = (row[Curr_A[1]]+row[Curr_B[1]]+row[Curr_C[1]])/3
    tipping.input['Age'] = Age_traf
    tipping.compute()
    Results.append([row["Time"],row[Volt_A[1]],row[Volt_B[1]],row[Volt_C[1]],
                    row[Curr_A[1]],row[Curr_B[1]],row[Curr_C[1]],
                    Age_traf,tipping.output['Health']])

#Almacenado de información resultante y de exportación a archivo .CSV
df_fin=pd.DataFrame(Results, columns=['Time','Volt_A','Volt_B','Volt_C','Curr_A',
    'Curr_B','Curr_C','Age','Indicador'])
df_fin.to_csv('Medicina_Pred_Hab.csv',index=False)

```

B. Esquema de implementación del modelo de gestión

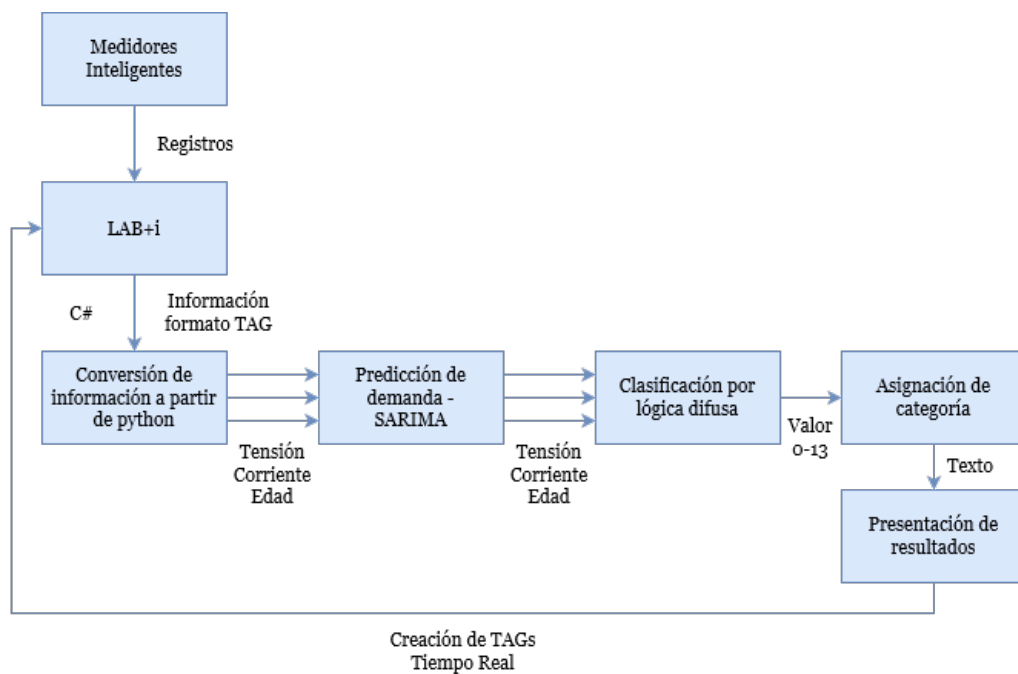


Figura B-1.: Esquema de desarrollo de modelo en sistema de monitoreo

Bibliografía

- [1] A. Doolgindachbaporn, G. Callender, P. Lewin, E. A. Simonson, and G. Wilson, “Data Driven Transformer Thermal Model for Condition Monitoring,” *IEEE Transactions on Power Delivery*, pp. 1–9, 2021. [Online]. Available: <https://ieeexplore.ieee.org/document/9599483/>
- [2] I. Soltanbayev, M. Bagheri, and T. Phung, “Real-time dry-type transformer aging evaluation,” *Proceedings of the International Symposium on Electrical Insulating Materials*, vol. 2, pp. 551–554, 2017.
- [3] M. A. Mehmood, J. Li, F. Wang, Z. Huang, J. Ahmad, and M. Shoaib Bhutta, “Analyzing the health condition and chemical degradation in field aged transformer insulation oil using spectroscopic techniques,” *2018 International Conference on Diagnostics in Electrical Engineering, Diagnostika 2018*, pp. 1–4, 2018.
- [4] Z. Chunming, X. Wenxie, and D. Zhaohong, “Transformer Oil-Paper Insulation Aging Evaluation System Based on Different Aging Characteristics,” *2021 6th International Conference on Control, Robotics and Cybernetics (CRC)*, pp. 181–185, 2021. [Online]. Available: <https://ieeexplore.ieee.org/document/9620125/>
- [5] H. Gumilang, “Cost and Benefit Analysis on Treatment Method of Aged Power Transformer Insulating Oil,” *2021 3rd International Conference on High Voltage Engineering and Power Systems (ICHVEPS)*, pp. 203–206, 2021. [Online]. Available: <https://ieeexplore.ieee.org/document/9600996/>
- [6] Y. Wang, W. Wei, P. Xue, and B. Yan, “Analysis on comprehensive fault rate of oil-immersed power transformer based on FTA,” *2021 International Conference on Electronic Information Engineering and Computer Science (EIECS)*, pp. 972–975, 2021. [Online]. Available: <https://ieeexplore.ieee.org/document/9588025/>
- [7] J. Chen, Z. Yin, X. Cheng, and Y. Liu, “Big data analysis based identification method of low-voltage substation area,” *Proceedings - 2021 2nd International Conference on Big Data and Informatization Education, ICB DIE 2021*, pp. 169–172, 2021.
- [8] Z. Y. Zheng, Z. Li, S. F. Yu, D. F. Ke, Z. J. Lao, J. Q. Lin, and J. J. Chen, “A new capacity inspection method for distribution transformer based on big data,” *China International Conference on Electricity Distribution, CICED*, pp. 38–41, 2018.

- [9] G. P. Zheng, Z. Y. Hou, and X. N. Yin, "Research of the agent technology based on multi-thread in transformer substation communication," *Proceedings of the 2006 International Conference on Machine Learning and Cybernetics*, vol. 2006, pp. 56–60, 2006.
- [10] S. Tellez, D. Alvarez, W. Montano, C. Vargas, R. Cespedes, E. Parra, and J. Rosero, "National Laboratory of Smart Grids (LAB+i) at the National University of Colombia-Bogotá Campus," in *2014 IEEE PES Transmission and Distribution Conference and Exposition, PES T and D-LA 2014 - Conference Proceedings*, vol. 2014-Octob. Institute of Electrical and Electronics Engineers Inc., 2014, pp. 1–6.
- [11] W. M. Salamanca, D. L. Álvarez, J. A. García, J. S. Marín, and E. Gómez-Luna, "State Estimator Assessment Platform in Distribution Systems with Advanced Metering Infrastructure and Distributed Generation using Real Time Simulations," in *2019 FISE-IEEE/CIGRE Conference - Living the Energy Transition, FISE/CIGRE 2019*. Institute of Electrical and Electronics Engineers Inc., 2019, pp. 1–6.
- [12] A. F. Cerón, I. F. Orduña, G. Aponte, and A. A. Romero, "Panorama de la gestión de activos para transformadores de potencia," *Informacion Tecnologica*, vol. 26, no. 3, pp. 99–110, 2015.
- [13] International Organization for Standardization, "ISO 55000: Asset Management-Overview, Principles and Terminology," 2014.
- [14] J. Woodhouse, "Briefing: Standards in asset management: PAS 55 to ISO 55000," *Infrastructure Asset Management*, vol. 1, no. 3, pp. 57–59, 2014.
- [15] A. Attwater, J. Q. Wang, A. Parlikad, and P. Russell, "Measuring the performance of asset management systems," *IET Conference Publications*, vol. 1, no. CP642, 2014.
- [16] D. Zhou, C. Li, and Z. Wang, "Power transformer lifetime modeling," in *Proceedings of IEEE 2012 Prognostics and System Health Management Conference, PHM-2012*, 2012, pp. 1–7.
- [17] A. Azmi, J. Jasni, N. Azis, and M. Z. Kadir, "Evolution of transformer health index in the form of mathematical equation," *Renewable and Sustainable Energy Reviews*, vol. 76, pp. 687–700, 2017.
- [18] G. R. Steeves, "Transformer lifecycle: Power transformer asset management," *Transformers Magazine*, vol. 3, no. 2, pp. 52–56, 2016. [Online]. Available: <https://hrcak.srce.hr/167406>
- [19] C. Liu, G. Huang, K. Zhang, F. Wen, M. A. Salam, and S. P. Ang, "Asset management in power systems," in *IET Seminar Digest*. Institution of Engineering and Technology, 2015, pp. 1–5.

-
- [20] J. L. Deng, "Introduction to Grey system theory," *Journal of Grey System*, vol. 1, no. 1, pp. 1–24, 1989.
- [21] T. Suwnansri, "Asset management of power transformer: Optimization of operation and maintenance costs," in *2014 International Electrical Engineering Congress, iEECON 2014*. Institute of Electrical and Electronics Engineers Inc., 2014.
- [22] A. Babizki, M. Foata, K. Lindl, D. Beerboom, E. Pawlowski, M. Zdrallek, R. Funk, and J. Linossier, "Practical approach for fleet management of transformers considering different stakeholders' perspectives," *4th International Colloquium "Transformer Research and Asset Management"*, 2017.
- [23] R. D. Medina, A. A. Romero, E. E. Mombello, and G. Rattá, "Assessing degradation of power transformer solid insulation considering thermal stress and moisture variation," *Electric Power Systems Research*, vol. 151, pp. 1–11, 2017.
- [24] I. Karatzas and S. E. Shreve, "Brownian Motion," in *Brownian Motion and Stochastic Calculus*. Springer, 1998, pp. 47–127.
- [25] A. A. Romero-Quete, H. D. Gómez, J. D. Molina, and G. Moreno, "Método práctico para la evaluación de riesgo en parques de transformadores de potencia," *DYNA (Colombia)*, vol. 84, no. 200, pp. 11–18, 2017.
- [26] A. A. Romero, E. E. Mombello, and G. Rattá, "An overview on power transformer management: Individual Assets and Fleets," in *2012 Sixth IEEE/PES Transmission and Distribution: Latin America Conference and Exposition (T D-LA)*, 2012, pp. 1–7.
- [27] P. Boss, J. Patelli, and J. Aubin, "Guide on economics of transformer management," pp. 1–67, 2004.
- [28] W. H. Bartley, P. E. Hartford, and S. Boiler, "Life Cycle Management of Utility Transformer Assets Breakthrough Asset Management for the Restructured Power Industry Life Cycle Management of Utility Transformer Assets," Hartford Steam Boiler Inspection & Insurance Co, Tech. Rep., 2002.
- [29] E. Duarte, D. Falla, J. Gavin, M. Lawrence, T. McGrail, D. Miller, P. Prout, and B. Rogan, "A practical approach to condition and risk based power transformer asset replacement," in *Conference Record of IEEE International Symposium on Electrical Insulation*, 2010, pp. 1–4.
- [30] A. J. Trappey, C. V. Trappey, C. Y. Wu, and C. W. Lin, "A patent quality analysis for innovative technology and product development," *Advanced Engineering Informatics*, vol. 26, no. 1, pp. 26–34, 2012.

- [31] A. J. C. Trappey, C. V. Trappey, L. Ma, and J. C. M. Chang, "Intelligent engineering asset management system for power transformer maintenance decision supports under various operating conditions," *Computers & Industrial Engineering*, vol. 2015, no. 84, pp. 3–11, 2015. [Online]. Available: <http://dx.doi.org/10.1016/j.cie.2014.12.033>
- [32] P. Sarajcev, D. Jakus, and J. Vasilj, "Optimal scheduling of power transformers preventive maintenance with Bayesian statistical learning and influence diagrams," *Journal of Cleaner Production*, vol. 258, pp. 1–13, 2020.
- [33] Y. Zhao, J. Wen, F. Xiao, X. Yang, and S. Wang, "Diagnostic Bayesian networks for diagnosing air handling units faults – part I: Faults in dampers, fans, filters and sensors," *Applied Thermal Engineering*, vol. 111, pp. 1272–1286, 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/abs/pii/S1359431116301193>
- [34] S. Ceferin, G. Janc, Z. Toros, T. Kastelic, and B. Prašnikar, "Power transformer monitoring systems for better asset management," in *CIREC - Open Access Proceedings Journal*, vol. 1. Institution of Engineering and Technology, 2017, pp. 395–399.
- [35] X. Zhang and E. Gockenbach, "Asset-management of transformers based on condition monitoring and standard diagnosis," *IEEE Electrical Insulation Magazine*, vol. 24, no. 4, pp. 26–40, 2008.
- [36] A. E. Abu-Elanien and M. M. Salama, "Asset management techniques for transformers," *Electric Power Systems Research*, vol. 80, no. 4, pp. 456–464, 2010.
- [37] A. Alqudsi and A. El-Hag, "Application of machine learning in transformer health index prediction," *Energies*, vol. 12, no. 14, pp. 1–13, 2019.
- [38] P. Bohatyrewicz, J. Płowucha, and J. Subocz, "Condition assessment of power transformers based on health index value," *Applied Sciences (Switzerland)*, vol. 9, no. 22, pp. 1–11, 2019.
- [39] W. Zuo, H. Yuan, Y. Shang, Y. Liu, and T. Chen, "Calculation of a Health Index of Oil-Paper Transformers Insulation with Binary Logistic Regression," *Mathematical Problems in Engineering*, vol. 2016, pp. 1–9, 2016. [Online]. Available: <https://doi.org/10.1155/2016/6069784>
- [40] A. F. Cerón, D. F. Echeverry, G. Aponte, and A. A. Romero, "Índice de salud para transformadores de potencia inmersos en aceite mineral con voltajes entre 69kV y 230kV usando lógica difusa," *Informacion Tecnológica*, vol. 26, no. 2, pp. 107–116, 2015.
- [41] F. Scatiggio and M. Pompili, "Health index: The TERNAs practical approach for transformers fleet management," in *2013 IEEE Electrical Insulation Conference, EIC 2013*, 2013, pp. 178–182.

- [42] A. N. Jahromi, R. Piercy, S. Cress, J. R. Service, and W. Fan, "An approach to power transformer asset management using health index," *IEEE Electrical Insulation Magazine*, vol. 25, no. 2, pp. 20–34, 2009.
- [43] A. J. Patil, A. Singh, and R. K. Jarial, "A Novel Fuzzy Based Technique for Transformer Health Index Computation," in *2019 6th IEEE International Conference on Advances in Computing, Communication and Control, ICAC3 2019*. Institute of Electrical and Electronics Engineers Inc., 2019, pp. 1–6.
- [44] G. C. Jaiswal, M. S. Ballal, and D. R. Tutakne, "Health index based condition monitoring of distribution transformer," in *IEEE International Conference on Power Electronics, Drives and Energy Systems, PEDES 2016*, vol. 2016-Janua. Institute of Electrical and Electronics Engineers Inc., 2017, pp. 1–5.
- [45] N. L. Keijsers, "Neural Networks," *Encyclopedia of Movement Disorders*, pp. 257–259, 2010. [Online]. Available: <https://www.sciencedirect.com/topics/neuroscience/neural-networks>
- [46] K. L. Du and M. N. Swamy, *Fundamentals of Machine Learning*. Springer-Verlag London Ltd, 2014, vol. 1.
- [47] S. Kittan, S. Kornhuber, P. Kastel, G. Nitsche, G. Valtin, and M. Weise, "Review and Implementation of Transformer Health Index Methods in line with the Development of a Condition Assessment Tool," in *2018 International Conference on Diagnostics in Electrical Engineering, Diagnostika 2018*. Institute of Electrical and Electronics Engineers Inc., 2018, pp. 1–4.
- [48] A. Y. Alqudsi and A. H. Elhag, "A cost effective artificial intelligence based transformer insulation health index," in *2017 3rd International Conference on Condition Assessment Techniques in Electrical Systems, CATCON 2017 - Proceedings*, vol. 2018-Janua. Institute of Electrical and Electronics Engineers Inc., 2018, pp. 108–111.
- [49] R. A. Ghunem, A. H. El-Hag, K. Assaleh, and F. Al Dhaheri, "Estimating transformer oil parameters using artificial neural networks," in *2009 International Conference on Electric Power and Energy Conversion Systems, (EPECS)*, 2009, pp. 1–4.
- [50] S. Sinha and S. Tiwari, "An Improvement in Performance and Computational Cost of ANN Based Wind Speed Prediction System," in *Proceedings of the 4th International Conference on Communication and Electronics Systems, ICCES 2019*. Institute of Electrical and Electronics Engineers Inc., 2019, pp. 542–546.
- [51] V. Richard, R. Loison, R. Gillard, H. Legay, and M. Romier, "Loss analysis of a reflectarray cell using ANNs with accurate magnitude prediction," in *2017 11th European*

- Conference on Antennas and Propagation, EUCAP 2017*. Institute of Electrical and Electronics Engineers Inc., 2017, pp. 2396–2399.
- [52] S. Pervaiz, I. Deiab, S. Zafar, and S. Shams, “Prediction of energy consumption and surface roughness in reaming operation of Al-6061 using ANN based models,” in *2012 International Conference on Robotics and Artificial Intelligence, ICRAI 2012*, 2012, pp. 169–173.
- [53] X. Su, C. Pan, X. Yang, and J. Zou, “Application of Elman Neural Network in Top Oil Temperature Prediction of Transformer,” in *ICHVE 2018 - 2018 IEEE International Conference on High Voltage Engineering and Application*. Institute of Electrical and Electronics Engineers Inc., 2019, pp. 1–4.
- [54] G. Athanasopoulos and R. Hyndman, *Forecasting: principles and practice*, 3rd ed. Melbourne: OTexts, 2021. [Online]. Available: [OTexts.com/fpp3](https://otexts.com/fpp3)
- [55] S. I. Vagropoulos, G. I. Chouliaras, E. G. Kardakos, C. K. Simoglou, and A. G. Bakirtzis, “Comparison of SARIMAX, SARIMA, modified SARIMA and ANN-based models for short-term PV generation forecasting,” *2016 IEEE International Energy Conference, ENERGYCON 2016*, pp. 1–6, 2016.
- [56] N. K. Chikkakrishna, C. Hardik, K. Deepika, and N. Sparsha, “Short-term traffic prediction using sarima and FbPROPHET,” *2019 IEEE 16th India Council International Conference, INDICON 2019 - Symposium Proceedings*, pp. 1–4, 2019.
- [57] F. Wu, C. Cattani, W. Song, and E. Zio, “Fractional ARIMA with an improved cuckoo search optimization for the efficient Short-term power load forecasting,” *Alexandria Engineering Journal*, vol. 59, no. 5, pp. 3111–3118, 2020.
- [58] C. E. D’Negri and E. L. D. Vito, “Introducción al razonamiento aproximado: lógica difusa,” *Revista Americana de Medicina Respiratoria*, vol. 6, no. 3, pp. 126–136, 2006. [Online]. Available: <https://www.redalyc.org/articulo.oa?id=382138367007>
- [59] A. KHALIL, N. MBAREK, and O. TOGNI, “Fuzzy Logic based model for self-optimizing energy consumption in IoT environment,” in *2021 IEEE Wireless Communications and Networking Conference (WCNC)*. IEEE, 2021, pp. 1–7. [Online]. Available: <https://ieeexplore.ieee.org/document/9417265/>
- [60] M. K. Paramathma, D. Devaraj, V. A. I. Selvi, and M. Karuppasamyandian, “Development of Fuzzy Logic Based Approach for Consumer Side Management in Smart Home,” in *2021 International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*. IEEE, 2021, pp. 1056–1061. [Online]. Available: <https://ieeexplore.ieee.org/document/9404550/>

- [61] F. Krykhtine, L. E. N. Safortes, C. A. Nunes Cosenza, M. Villarino, J. Caldeira, M. Aredes, and P. De Oliveira Reis Filho, “Fuzzy Logic for Evaluating Electrician Maintenance Teams at Transmission Lines Work Environment,” in *Proceedings of the 3rd International Conference Ergo-2018: Human Factors in Complex Technical Systems and Environments, Ergo 2018*. Institute of Electrical and Electronics Engineers Inc., 2018, pp. 234–240.
- [62] M. S. Uddin, Y. A. Sekercioglu, and N. Mani, “Fuzzy logic systems: A classification based on capabilities in handling uncertainty,” in *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics*, 2007, pp. 807–811.
- [63] S. Tellez, J. Chinchilla, O. Duarte, and J. Rosero, “Demand side management through LAB+i platform: Case study,” in *2016 IEEE PES Transmission and Distribution Conference and Exposition-Latin America, PES T and D-LA 2016*. Institute of Electrical and Electronics Engineers Inc., 2017, pp. 1–6.
- [64] D. Alvarez, J. Reyes, W. Montano, and E. Parra, “Sistema de Gestión de Energía en Tiempo Real del Campus de la Universidad Nacional de Colombia, Sede Bogotá,” *Mundo Eléctrico*, vol. 101, pp. 48 – 57, 2015. [Online]. Available: <http://www.mundoelectrico.com/index.php/component/k2/item/159-edicion-101-automatizacion>
- [65] W. M. Salamanca and J. A. García, “Computing platform for power flow models in real time: Case study - Real-time monitoring on a photovoltaic generation system and its integration into the load flow of Universidad Nacional de Colombia power grid model,” in *2016 IEEE PES Transmission and Distribution Conference and Exposition-Latin America, PES T and D-LA 2016*. Institute of Electrical and Electronics Engineers Inc., 2017, pp. 1–8.
- [66] R. Cespedes, “Applications of a reference model to smarter electrical energy systems,” in *2013 IEEE Grenoble Conference PowerTech, POWERTECH 2013*, 2013, pp. 1–5.
- [67] J. A. Restrepo, S. E. Sierra, and J. A. Rosero, “Load curve characterization based on real time measurements: Case of study in Colombia,” in *Proceedings of the 2018 IEEE PES Transmission and Distribution Conference and Exhibition - Latin America, T and D-LA 2018*. Institute of Electrical and Electronics Engineers Inc., 2018, pp. 1–5.
- [68] W. M. Salamanca and J. R. García, “Metering Management Center for Colombia and short-term strategies to implement programs related to smart metering,” in *2019 FISE-IEEE/CIGRE Conference - Living the Energy Transition, FISE/CIGRE 2019*. Institute of Electrical and Electronics Engineers Inc., 2019, pp. 1–7.

- [69] J. Schneider, A. J. Gaul, C. Neumann, J. Hogräfer, W. Wellßow, M. Schwan, and A. Schnettler, “Asset management techniques,” *International Journal of Electrical Power and Energy Systems*, vol. 28, no. 9 SPEC. ISS., pp. 643–654, 2006.
- [70] M. Dachyar and M. I. Perkasa, “Asset management improvement design in state university,” in *2018 International Conference on Information Management and Processing, ICIMP 2018*, vol. 2018-Janua. Institute of Electrical and Electronics Engineers Inc., 2018, pp. 21–25.
- [71] J. Van Der Aelst, “A field proven vision on Asset Management in an industrial environment,” in *IET Conference Publications*, 2011, pp. 1–5.
- [72] J. R. Garcia, A. A. Zambrano P, and O. Duarte, “Implementation of an Energy Demand Forecasting Model under a Smart Grids Environment,” in *Proceedings of the 2018 IEEE PES Transmission and Distribution Conference and Exhibition - Latin America, T and D-LA 2018*. Institute of Electrical and Electronics Engineers Inc., 2018, pp. 1–5.
- [73] D. Duckett, C. Arpino, and S. McNelly, “IEEE Guide for Loading Mineral-Oil-Immersed Transformers and Step-Voltage Regulators,” *IEEE Std C57.91-2011 (Revision of IEEE Std C57.91-1995)*, pp. 1–123, 2012.
- [74] Icontec, “GTC 50:1997. Electrotecnia. Transformadores de distribución sumergidos en liquido refrigerante con 65°c de calentamiento en los devanados. Guía de cargabilidad.” pp. 1–32, 1997.
- [75] J. A. Rodrigo, “Predicción (forecasting) de la demanda eléctrica con Python,” 2021. [Online]. Available: <https://www.cienciadedatos.net/documentos/py29-forecasting-demanda-energia-electrica-python.html>
- [76] S. Taylor and B. Letham, “Prophet: forecasting at scale - Facebook Research,” 2017. [Online]. Available: <https://research.fb.com/blog/2017/02/prophet-forecasting-at-scale/>
- [77] I. The MathWorks, “Time Series Forecasting Using Deep Learning - MATLAB & Simulink - MathWorks América Latina,” 2021. [Online]. Available: <https://la.mathworks.com/help/deeplearning/ug/time-series-forecasting-using-deep-learning.html>
- [78] J. Perktold, S. Seabold, and J. Taylor, “statsmodels - Statistical models, hypothesis tests, and data exploration,” 2021. [Online]. Available: <https://www.statsmodels.org/stable/index.html>