



# ¡POSGRADOS!

## MAESTRÍA EN \_\_\_\_\_ ELECTRICIDAD

RPC-SO-22-No.325-2018

OPCIÓN DE  
TITULACIÓN:

PROYECTO DE DESARROLLO

TEMA:

PREDICCIÓN SOBRE LA FRECUENCIA DE FALLAS EN LOS  
TRANSFORMADORES DE POTENCIA DE UNA SUBESTACIÓN  
ELÉCTRICA

AUTOR:

TEDDY JHENNSE NEGRETE PEÑA

DIRECTOR:

BEN CEVALLOS MIELES

GUAYAQUIL - ECUADOR  
2021

***Autor:***



**Teddy Jhennse Negrete Peña.**

Ingeniero en electricidad especialización electrónica.  
Candidato a Magíster en Electricidad, Mención Sistemas Eléctricos de Potencia.

Universidad Politécnica Salesiana, Sede Guayaquil

tnegrete@ups.edu.ec

teddynegrete@gmail.com

***Director:***



**Ben Cevallos Miele.**

Ingeniero en electricidad especialización potencia.

Magister en sistemas eléctricos de potencia.

ben.cevallos@celec.gob.ec

Todos los derechos reservados.

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

DERECHOS RESERVADOS

©2021 Universidad Politécnica Salesiana.

GUAYAQUIL – ECUADOR – SUDAMÉRICA

TEDDY JHENNSE NEGRETE PEÑA.

**PREDICCIÓN SOBRE LA FRECUENCIA DE FALLAS EN LOS TRANSFORMADORES DE POTENCIA DE UNA SUBESTACIÓN ELÉCTRICA**

## **Agradecimientos**

Este proyecto se ha realizado con la bendición de Dios, con la colaboración del personal de la subestación eléctrica CELEC -EP TRANSELECTRIC Pascuales y con la ayuda de tutores y docentes de la Universidad Politécnica Salesiana.

# Índice general

<b>Índice de Figuras</b>	<b>5</b>
<b>Índice de Tablas</b>	<b>8</b>
<b>Abstract</b>	<b>9</b>
<b>1. Introducción</b>	<b>11</b>
1.1. Antecedentes . . . . .	12
1.2. Descripción general del problema . . . . .	13
1.3. Objetivos . . . . .	15
1.3.1. Objetivo general . . . . .	15
1.3.2. Objetivos específicos . . . . .	15
1.4. Contribuciones . . . . .	16
1.5. Organización del manuscrito . . . . .	17
<b>2. Marco teórico referencial</b>	<b>18</b>
2.1. Introducción . . . . .	18
2.2. Fundamentación Teórica . . . . .	19
<b>3. Metodología propuesta</b>	<b>31</b>
3.1. Introducción . . . . .	31
3.2. Problema: Tratamiento de los datos . . . . .	33
3.3. Problema de determinación de la condición de trabajo del Transformador de Potencia . . . . .	35
3.3.1. Aplicación de Sistemas de Inferencias Difusos . . . . .	35
3.3.2. Problema de entrenamiento y la predicción con modelos de Aprendizaje Automático . . . . .	41

<i>ÍNDICE GENERAL</i>	4
<b>4. Análisis de resultados</b>	<b>45</b>
4.1. Introducción . . . . .	45
4.2. Resultados Generales . . . . .	45
4.2.1. Aplicación de Sistemas de Inferencias Difusos . . . . .	45
4.2.2. Problema de entrenamiento y la predicción con modelos de Aprendizaje Automático . . . . .	47
<b>5. Conclusiones</b>	<b>71</b>
<b>6. Glosario</b>	<b>73</b>
<b>Glosario</b>	<b>77</b>
<b>Referencias</b>	<b>78</b>

# Índice de Figuras

1.1. Patio 230 kV de la subestación eléctrica CELEC-EP TRANSELECTRIC Pascuales - Fuente: CELEC-EP. . . . .	13
2.1. Resultados de la Prueba Electrica (PE), AGD y AFQ Fuente: SE PASCUALES & MS Morgan Schaffer Julio 2021. . . . .	21
2.2. Tabla de datos de las principales variables para el SID. Fuente: Autor. . . . .	22
2.3. Tipos de modelos de la Máquinas de Aprendizaje. Fuente: MathWorks, 2019 [1]. . . . .	26
2.4. Flujo de trabajo completo del procesamiento de un Modelo. Fuente: Python Machine Learning by Sebastian Raschka [2]. . . . .	29
3.1. Diagrama del bloque del proyecto de investigación. Fuente: Autor.	32
3.2. Flujo de trabajo que utiliza el modelo de SID. Fuente: Autor. . . . .	36
3.3. Diagrama de Entradas y Salidas del modelo Mamdani construido para el SID. Fuente: Autor y MathWorks, 2014 [3]. . . . .	37
3.4. Función de Pertenencia o Membresía de la señal de Entrada "Water". Fuente: Autor y MathWorks, 2014 [3]. . . . .	38
3.5. Tabla de las 42 reglas lingüísticas creadas para el modelo de SID. Fuente: Autor y MathWorks, 2014 [3]. . . . .	39
3.6. Editor de Resultados de la "Condición de Trabajo" obtenida del modelo de SID. Fuente: Autor y MathWorks, 2014 [3]. . . . .	40
3.7. Diagrama de bloque que aborda el Problema del Aprendizaje. Fuente: Autor y MathWorks, 2014 [3]. . . . .	41
3.8. Flujo de trabajo de un Modelo de Aprendizaje Automático. Fuente: MathWorks [1]. . . . .	42
3.9. Base de Datos de Entrenamiento. Fuente: Autor. . . . .	43
3.10. Base de Datos de Prueba. Fuente: Autor. . . . .	43

4.1. SID: Entradas y resultados de la CT de un transformador Fuente: Autor. . . . .	46
4.2. SID: Resultados de la CT de todos los transformadores Fuente: Autor. . . . .	47
4.3. SID: Gráfico de CT desde 1995 hasta 2021, para todos los transfor- madores Fuente: Autor. . . . .	47
4.4. Transformador 5BA225405. RESPUESTAS: Modelo 1. Fuente: Autor.	48
4.5. Transformador 5BA225405. VALIDACIÓN: Modelo 1. Fuente: Autor.	49
4.6. Transformador 5BA225405. PRUEBA: Modelo 1. Fuente: Autor. . .	50
4.7. Transformador 5BA225405. RESPUESTAS: Modelo 2. Fuente: Autor.	51
4.8. Transformador 5BA225405. VALIDACIÓN: Modelo 2. Fuente: Autor.	52
4.9. Transformador 5BA225405. PRUEBA: Modelo 2. Fuente: Autor. . .	53
4.10. Transformador 5BA225405. RESPUESTAS: Modelo 3. Fuente: Autor.	54
4.11. Transformador 5BA225405. VALIDACIÓN: Modelo 3. Fuente: Autor.	55
4.12. Transformador 5BA225405. PRUEBA: Modelo 3. Fuente: Autor. . .	56
4.13. Transformador 5BA225405. RESPUESTAS: Modelo 4. Fuente: Autor.	57
4.14. Transformador 5BA225405. VALIDACIÓN: Modelo 4. Fuente: Autor.	58
4.15. Transformador 5BA225405. PRUEBA: Modelo 4. Fuente: Autor. . .	59
4.16. Transformador 5BA225405. RESPUESTAS: Modelo 5. Fuente: Autor.	60
4.17. Transformador 5BA225405. VALIDACIÓN: Modelo 5. Fuente: Autor.	61
4.18. Transformador 5BA225405. PRUEBA: Modelo 5. Fuente: Autor. . .	62
4.19. Transformador 5BA225405. RESPUESTAS: Modelo 6. Fuente: Autor.	63
4.20. Transformador 5BA225405. VALIDACIÓN: Modelo 6. Fuente: Autor.	64
4.21. Transformador 5BA225405. PRUEBA: Modelo 6. Fuente: Autor. . .	65
4.22. Transformador 5BA225405. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor. .	66
4.23. Transformador 5BA225406. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor. .	66
4.24. Transformador 5BA225407. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor. .	67
4.25. Transformador 5BA225408. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor. .	67
4.26. Transformador 62484. Cuadro de resultados de Indicadores de to- dos los Modelos de Aprendizaje Automático. Fuente: Autor. . . . .	68
4.27. Transformador 62486. Cuadro de resultados de Indicadores de to- dos los Modelos de Aprendizaje Automático. Fuente: Autor. . . . .	68

4.28.INDICADOR RMSE: Gráfico del RMSE respecto a cada Transformador sobre los datos de ENTRENAMIENTO para todos los Modelos de Aprendizaje Automático. Fuente: Autor. . . . .	69
4.29.INDICADOR RMSE: Gráfico del RMSE respecto a cada Transformador sobre los datos de PRUEBA para todos los Modelos de Aprendizaje Automático. Fuente: Autor. . . . .	70



# Índice de Tablas

2.1. Causas de fallas más frecuentes en los transformadores de potencia. Fuente: Santana R. y col., 2013 [4]. . . . .	24
2.2. Resumen del "Estado del Arte" sobre predicciones de fallas de transformadores de potencia basados en modelos de Aprendizaje Automático aplicando resultados de las pruebas eléctricas y análisis de gases disueltos en el aceite del transformador Análisis de Gases Disueltos (AGD). . . . .	30
3.1. Variables o Conjuntos Difusos de Entrada. Fuente: Prasojo R. y col.,2021 [5]. . . . .	35
3.2. Modelos de Aprendizaje Automático utilizados. Fuente: Autor y MathWorks, 2019 [1]. . . . .	44

# Resumen

En la región sur occidental del Ecuador está la subestación eléctrica (CE-LEC)-EP TRANSELECTRIC PASCUALES, de 230/138/69 kV y 1198 MVA, nodo fundamental del Sistema Nacional Interconectado (SNI). El patio 230 kV tiene 7 transformadores de potencia, 3 operan desde hace 40 años. Se utilizó 27 años de resultados de pruebas eléctricas en 6 modelos de Aprendizaje Automático para estimar la -condición- de operación, para el apoyo en la planificación del mantenimiento predictivo definido. Se utilizó un Sistemas de Inferencias Difusas (SID) para estimar la condición de operación del transformador en cada prueba, con 8 variables que caracterizan tipos de daños, obtenidas del AGD, del (AFQ), del (IEC)-60076-3 o (ASTM)-(IEEE) C57.12.90-1993, y del criterio técnico sobre resultados de pruebas. Es confuso considerar muchas recomendaciones al mismo tiempo, ante este escenario se establecieron 42 reglas lingüísticas difusas para estimar la -condición- de cada transformador, para cada medición. Con bases de datos sobre resultados de 56 tipos de pruebas eléctricas y 324 registros de 15 atributos o variables y 1 objetivo llamado -condición- se definió la estructura de los datos, la primera base se utiliza para el entrenamiento de 6 modelos de regresión de Aprendizaje Automático y la otra base de las mismas características se utilizó para las pruebas de predicción. La validación del modelo entrenado se la realiza con una porción de los datos, para la evaluación del modelo validado y probado se calcularon 4 indicadores de validación, el principal es (RMSE). Uno de los mejores resultados se dio con Árboles de Decisión, con un RMSE inferior al 1% en promedio, la -condición- de operación está entre 56% y 42%, y las predicciones en los siguientes 5 años se registra una caída de hasta 2.5%. Se considera una contribución para la sociedad técnica iniciar este tipo de tratamiento con técnicas de Inteligencia Artificial.

# Abstract

In the southwestern region of Ecuador is the substation (CELEC) -EP TRANS-ELÉCTRICA PASCUALES, 230/138/69 kV and 1198 MVA, fundamental node of the National Interconnected System (SNI). The 230 kV yard has 7 power transformers, 3 of them have been in operation for 40 years. 27 years of electrical test results on 6 machine learning models were used to estimate operational condition, to support defined predictive maintenance planning. A Fuzzy Inference System (FID) was used to estimate the operating condition of the transformer in each test, with 8 variables that characterize the types of damage, obtained from the (DGA), the (QFA), the (IEC) -60076-3 or (ASTM) - (IEEE) C57.12.90-1993, and technical criteria on test results. It is confusing to consider many recommendations at the same time. Faced with this scenario, 42 fuzzy linguistic rules were established to estimate the -condition- of each transformer, for each measure. With databases on the results of 56 types of electrical tests and 324 records of 15 attributes or variables and 1 objective called -condition- the data structure was defined, the first base is used for the training of 6 Machine regression models. Learning and the other basis of the same characteristics was used for the prediction tests. The validation of the trained model is carried out with a portion of the data, for the evaluation of the validated and tested model, 4 validation indicators were calculated, the main one being (RMSE). One of the best results was with Decision Trees, with an average RMSE of less than 1%, the operating -condition- is between 56% and 42%, and the predictions in the next 5 years register a drop of up to 2.5%. It is considered a contribution for the technical society to start this type of treatment with Artificial Intelligence techniques.

# Capítulo 1

## Introducción

Aquí se encuentran las bases que originan esta investigación, desde la motivación de resolver el problema hasta la delimitación de la investigación, además se inicia en la Zona Sur Occidental de CELEC-EP TRANSELECTRIC, la aplicación de elementos de Inteligencia Artificial y algoritmos de Aprendizaje Automático, para el análisis de problemas técnicos, en una de las subestaciones de dicha zona.

La subestación eléctrica CELEC-EP TRANSELECTRIC Pascuales forma parte del Sistema Nacional de Transmisión de la zona sur occidental, pertenece a la parroquia Pascuales, cantón Guayaquil, provincia del Guayas, a 16.5 km de Guayaquil, en la carretera Guayaquil-Daule, es del tipo doble barra con los niveles de voltaje 230kV, 138kV y 69kV, en el SNI se conecta con las subestaciones eléctricas Chorrillos, Dos Cerritos, Milagro y Molino; cuenta con siete transformadores de potencia en el patio 230 kV, para garantizar un funcionamiento confiable y estable, se dispone de un plan de mantenimiento preventivo que recibe mucha información proveniente de pruebas, mediciones, especificaciones de los fabricantes y estándares de la industria.

La aplicación de un sistema inteligente, basados en métodos de aprendizaje automático es un aporte a esta industria de la Transmisión de Energía Eléctrica, ya que poco a poco estas subestaciones se están actualizando con equipos de la nueva generación que son capaces de recolectar información continua de los procesos, de tal manera que se puede aplicar metodologías similares a problemas en otras áreas que tengan equipos de alta demanda de trabajo y que su servicio sea de altas prestaciones.

Los primeros beneficiados son los usuarios ya que recibirán el servicio de energía eléctrica, en forma continua y con la calidad requerida, sin molestias e inconvenientes. El estado se beneficiará porque optimiza los recursos invertidos para entregar energía eléctrica al menor costo posible, considerando que los mantenimientos se implementarán en función directa de los resultados que estime el modelo que se alimentará con resultados de las continuas pruebas eléctricas que se han establecido. La subestación eléctrica utiliza la información generada de su funcionamiento y de los resultados de las pruebas desarrolladas, con esta metodología cada recurso invertido es aprovechado, tanto en tiempo, en uso de equipos y en mano de obra.

Se justifica elaborar una investigación que permita desarrollar las actividades de mantenimiento puntuales y necesarias para garantizar el funcionamiento confiable y de calidad durante la mayor cantidad de tiempo. Se estima el costo de operación \$ 1000 por hora de funcionamiento de dicho transformador [6], se puede calcular la pérdida durante un período de tiempo fuera de servicio.

La metodología empleada requiere de un procesamiento de la información adecuado, de un proceso holístico más ordenado y desarrollado cuidadosamente a intervalos de tiempo adecuados, se debe controlar cada etapa en la adquisición, procesamiento y análisis de los resultados. Se requiere un equipo interdisciplinario que cumpla adecuadamente con cada una de las funciones requeridas, para que los resultados sean confiables y garanticen una predicción acertada.

## 1.1. Antecedentes

La subestación eléctrica Pascuales representa el nodo central en la Zona Sur Occidental del SNI su ubicación geográfica es clave en la interconexión de esta zona. Es responsabilidad del Departamento de Mantenimientos garantizar un funcionamiento óptimo y continuos de toda la subestación y de las subestaciones que tienen conexión directa con ella, para lo cual se realizan las PE, a los diferentes dispositivos y equipos denominados Equipos Primarios (EP), que en esta subestación son de 56 tipos diferentes, sin contar con la cantidad de cada uno de ellos, recordando que también deben ser controlados y supervisados los EP de las subestaciones que se unen a este nodo, con lo cual la cantidad de EP que se debe atender es considerable.

La figura 1.1 permite ver el patio de 230 kV de la subestación Pascuales del SNI se observan los principales equipos primarios que son el centro de esta investigación.



Figura 1.1: Patio 230 kV de la subestación eléctrica CELEC-EP TRANSELECTRIC Pascuales - Fuente: CELEC-EP.

## 1.2. Descripción general del problema

Actualmente se realizan mantenimiento preventivo y correctivos a los Equipos Primarios de la subestación eléctrica CELEC-EP TRANSELECTRIC Pascuales, los transformadores de potencia son los Elementos Primarios más importantes de la subestación de transmisión, se cuenta con un histórico de datos de varias Pruebas Eléctricas, con resultados de un estudio de pronóstico que utilice estos datos y aplique técnicas actualizadas, se pueden utilizar para tomar la decisión y efectuar un plan de mantenimiento que garantice una operación confiable de los transformadores de potencia.

Anticipar un deterioro continuo en el funcionamiento del transformador de potencia, por el análisis de datos o resultados de pruebas es posible [7], también se tienen diferentes formas para evaluar el estado de los equipos que forman parte del sistema de transmisión de la energía eléctrica, entre otros: el

análisis de efecto en modo de falla [8], mantenimiento centrado en la confiabilidad [9]. El funcionamiento inestable puede ser detectado por los gases que contiene el transformador de potencia, y de aquí se debe realizar el análisis de predicción por los gases disueltos en el aceite del transformador [10].

Al utilizar el historial de datos correspondientes a las PE de los transformadores de potencia EP de la subes CELEC-EP TRANSELECTRIC Pascuales y una metodología que involucran técnicas de aprendizaje automático, análisis matemático y estadístico, con cuyos resultados se utilizan para el apoyo de la evaluación del mantenimiento de estos equipos de alta importancia para la subestación eléctrica.

Aquí se muestran datos estadísticos relevantes, diagnósticos previos, informes que se han recopilado para estimar la magnitud de los antecedentes que se consideran en la investigación. Con la actualización de los datos sobre pruebas y mediciones a los Transformadores de Potencia, se obtiene los siguientes datos:

- 7 Transformadores de potencia del patio 230kV.
- 12 Pruebas eléctricas a transformadores de potencia.
- 10 Variables medidas en la prueba AGD.
- 7 Variables medidas en la prueba AFQ del aceite.
- 27 años de mediciones y pruebas.
- 56 tipos de pruebas eléctricas a todos los EP.
- 31 Equipos primarios que atender en el patio 230 kV.

El Departamento de Mantenimiento de la subestación Pascuales tiene que garantizar una operación de transporte de la energía eléctrica a otras subestaciones del sistema interconectado, lo que conlleva a una completa sinfonía de equipos en cada subestación, para lo cual se apoya en los resultados de las pruebas eléctricas y de la información recomendada que proviene desde el fabricante y de las normas y estándares de la industria, tales como IEEE, ANSI, ASTM, IEC y [InterNational Electrical Testing Association \(NETA\)](#).

Considerando que muchos de los equipos y los transformadores tienen más de 30 años de servicio, es muy importante atender cualquier anomalía o alerta que se presente en los resultados de las pruebas. Se cuentan con muchos datos, de muchas variables, de muchas pruebas, de varios equipos y de varios sistemas de la interconexión, que fácilmente pueden confundir su tratamiento o el método para organizar y analizar una posible falla significativa que se puede dar en el futuro. Además no hay un sistema computacional que almacene, administre, actualice y depure la información que se cuenta sobre el resultados de todas las pruebas y de todos los equipos. La planificación de los mantenimientos preventivos y predictivos de los Transformadores de Potencia y elementos primarios relacionados se debe realizar con mucha precisión para garantizar un funcionamiento confiable y seguro de la subestación y ahorrar costos por imperfecciones o por reparaciones.

¿Es posible contar con un algoritmo computacional basado en técnicas de Aprendizaje Automático que utilice los resultados de las "Pruebas Eléctricas" de los Transformadores de Potencia del patio 230kV de la subestación Pascuales para predecir su -Condición de Trabajo- de tal manera que funcione para prevenir fallas eléctricas y se considere como un apoyo para la planificación de mantenimientos preventivos?

### **1.3. Objetivos**

#### **1.3.1. Objetivo general**

Analizar el modelamiento matemático e implementar el algoritmo computacional que estime la predicción del comportamiento de las pruebas eléctricas de los transformadores de potencia del patio 230kV de la SE Pascuales de CELEC EP TRANSELECTRIC, con la aplicación de interpolación segmentaria, elementos finitos, técnicas de aprendizaje automático, para el apoyo en la evaluación del mantenimiento preventivo de estos equipos.

#### **1.3.2. Objetivos específicos**

1. Ordenar, revisar y digitalizar los datos históricos de las pruebas eléctricas y de la operación de los transformadores de potencia, correspondientes a las bahías del patio primario de 230 kV de la subestación eléctrica Pascuales.



2. Seleccionar el modelo matemáticos y métodos de aprendizaje automático para realizar la predicción más apropiada de acuerdo con los datos históricos, de las pruebas eléctricas en los transformadores de potencia que se encuentran en las bahías del patio de 230 kV de la subestación eléctrica Pascuales.
3. Implementar los algoritmos estudiados, usando un software para ingeniería y ciencias, apropiado para el análisis profesional, académico y científico que simule el comportamiento del transformador de potencia, respecto a las pruebas eléctricas que se han realizado en la subestación eléctrica.

## 1.4. Contribuciones

Es la primera ocasión que se realiza un trabajo con la aplicación de técnicas de -Aprendizaje Automático- e -Inteligencia Artificial- a los resultados de las pruebas eléctricas de los equipos primarios y en especial a los Transformadores de Potencia de la subestación de CELEC-EP TRANSELECTRIC Pascuales, lo que supone una innovación a los métodos tradicionalmente empleados. En la medida que los equipos se vayan actualizando éstos tendrán nuevas características, las mismas que involucrará mayor número de prestaciones para el tratamiento de la información, mejores características de comunicación y de adquisición automática de datos lo cual facilitará implementar un sistema centralizado de datos que ayude con la organización, actualización y tratamiento de la información.

Aunque este modelo es particular, las técnicas empleadas han sido desarrolladas para el estudio similares en Transformadores de Potencia, así mismo se dispone de más Equipos Primarios y más subestaciones que pertenecen a la red interconectada, para los cuales también se dispone de una mediana base de datos que debe ser configurada y centralizada para que la herramienta se implemente en un eje transversal de equipos ya que simplemente depende de los datos, de los criterios técnicos que se utilizan de acuerdo con los estándares y normas internacionales, así como de la experiencia de mantenimientos y del análisis de los resultados apriori de las pruebas eléctricas realizadas a los equipos primarios que componen el sistema.

## 1.5. Organización del manuscrito

La memoria de esta investigación ha sido configurada de la siguiente forma:

El capítulo 1 explica el problema planteado en la investigación, los objetivos propuestos y el alcance que tendrá el trabajo.

El capítulo 2 revisa trabajos similares en los que se ha utilizado técnicas de Sistemas Inteligentes y de Aprendizaje Automático para plantear una propuesta de solución y cumplir con los objetivos propuestos.

En el capítulo 3 se estructura la problemática encontrada en cada fase del proyecto y se describe los pasos realizados para resolver cada uno de dichos problemas, utilizando los Sistemas de Inferencias Difusas y varias técnicas de Aprendizaje Automático para realizar el entrenamiento con los datos de las pruebas eléctricas, cuyo modelo se utiliza para obtener una Condición de Trabajo estimada por regresión, se aplica un método basado en Inferencias Difusas para determinar un estimado valor de la Condición de Trabajo para cada transformador de potencia.

El capítulo 4 se presentan cuatro tipos de indicadores que permiten evaluar el modelo aplicado, tanto para el ajuste del modelo con la base de datos de entrenamiento, como para el resultado que se obtiene con el modelo aplicado a la base de datos de prueba y que permiten establecer un criterio de predicción del funcionamiento de cada transformador de potencia. Se presenta un análisis de los resultados obtenidos con cada modelo después de haber realizado varias simulaciones, afinando parámetros y propiedades de tal manera que se minimice el indicador.

Finalmente el capítulo 5 concluye este trabajo y se sintetizan los resultados en función de los objetivos planteados en esta investigación.

# Capítulo 2

## Marco teórico referencial

### 2.1. Introducción

Aquí se explican algunas investigaciones similares o con temas relacionadas a esta investigación, en el área de las predicciones de los resultados de pruebas eléctricas que se realizan al principal elemento primario de una subestación de transmisión de energía eléctrica, el transformador de potencia, basados en técnicas de aprendizaje automático, en la literatura se encuentran conceptos y definiciones que posteriormente en el mismo capítulo se amplía la descripción para una mejor comprensión de la temática tratada, tanto para los entendidos en la especialidad de la ingeniería eléctrica como para los lectores en el área del análisis de datos y en la especialidad de computación.

Se espera que una subestación eléctrica realice la transmisión de energía eléctrica en todo momento, para lo cual deben operar en estado óptimo todos sus equipos y su funcionamiento debe ser continuo y confiable, para brindar un servicio de calidad a todos sus usuarios, aún cuando aparezcan anomalías naturales o hayan elementos defectuosos de fabricación. Para mantener una operación segura, se realizan diagnósticos y pruebas a los equipos primarios y se analiza el estado de las protecciones, todo lo cual se registra para su futuro estudio.

## 2.2. Fundamentación Teórica

Los transformadores de potencia son máquinas no rotatorias, totalmente encerradas, cuyo núcleo esta sumergida en aceite, y es muy poco probable que fallen, pero cuando fallan pueden traer consecuencias muy severas, para la recuperación del sistema se requiere que este transformador con falla sea aislado y reemplazado. Desde el punto de vista físico las fallas del transformador de potencia pueden dividirse en tres grupos:

1. Fallas en un equipo auxiliar del transformador.
2. Fallas en las partes internas del transformador.
3. Fallas por sobrecargas o cortocircuitos externas.

Las pruebas eléctricas que se implementan a los equipos primarios: transformadores de potencia son aplicadas de acuerdo con la norma IEC-60076-3 o ASTM-IEEE C57.12.90-1993, las mismas que se realizan al aislamiento de devanados del transformador y su núcleo.

Actualmente son varias Pruebas Eléctricas a Transformadores de Potencia que se toman en cuenta para estimar un estado de funcionamiento aceptable o que demanden más pruebas para la consideración de alguna alerta o predicción de una futura falla, entre ellas se tiene:

- Medición de resistencia de aislamiento.
- Tomas de muestra de aceite para AFQ y AGD.
- Medición de rigidez dieléctrica del aceite.

La subestación eléctrica Pascuales cuenta con una aplicación para el análisis de las tendencias que tienen las pruebas eléctricas para los equipos primarios [11] donde se estudia el comportamiento de las pruebas eléctricas en forma individual, parámetro por parámetro de todos los equipos primarios incluidos los transformadores de potencia, todas son funciones dinámicas en el tiempo. Se realizan varias formas de interpolación, dependiendo de la cantidad de datos para cada prueba, y posee un módulo de interpolación segmentaria o splines que también incluyen las tendencias para los transformadores de potencia.

En este proyecto se prefiere no realizar la interpolación de una variable (curvas de ajustes por segmentos de interpolación) pues al considerar simultáneamente más variables en un análisis holístico por inteligencia artificial, la predicción depende de más factores a la vez, lo que proporciona una situación más cercana a la realidad.

Respecto a la aplicación del método de elementos finitos se simuló el comportamiento dieléctrico del aislamiento del transformador de potencia a partir de condiciones normales y defectuosas mostradas por burbujas y partículas metálicas en el aceite del transformador y cuyo resultado se muestra en los campos eléctricos del transformador defectuoso [12]. Se aplica con mucho éxito el modelamiento y simulación del diseño en 3D a partir de la geometría compleja y de las características térmicas, eléctricas y condiciones ambientales, en modelos de aislamiento. Lo que permite analizar fallas o defectos de diseños del transformador de potencia en el dominio del tiempo [13].

En esta investigación se decidió no utilizar el [Finite Element Method \(FEM\)](#) puesto que se requiere de las geometrías exactas de todos los transformadores de potencia y un registro de las fallas físicas internas, es decir dimensiones, formas y cantidad de las partículas internas (incluidas burbujas en el aceite y fragmentos de la celulosa) del diseño dieléctrico de cada uno de los transformadores, lo cual requiere de instrumentación y pruebas adicionales que no se realizan normalmente en la subestación eléctrica.

La construcción de métodos y técnicas que simulen la inteligencia del hombre mediante algoritmos que hagan que una computadora también sea inteligente es lo que se denomina -Inteligencia Artificial- [14]. Se debe considerar esta alternativa de solución en los siguientes casos:

1. Cuando no hay solución analítica disponible.
2. Si hay muchas variantes que hace complejo el proceso, entonces se debe utilizar un método heurístico o meta-heurístico.
3. Si la información presenta problemas por estar incompleta o ser imprecisa, inclusive si tuviera errores.
4. Si se cuenta con un problema para el cual se dispone del conocimiento empírico o sentido común de expertos en el problema planteado.



## OIL ANALYSIS REPORT

### REFERENCE

Client:	Mr. James Gonzales (ZSD01)	P.O. No	SBSTR	Sample No:	M0971524
E-mail:		Work Order	130720-7	Authorized by:	<i>EG</i>
Company:	Sistemas Digitales de Control		130720-7	Sent Date:	2020-08-18

### EQUIPMENT

Apparatus Type:	TRN	KV:	138	Sampling Point:	MAIN
Location:	S/E BABAHOYO	MVA:	100	Oil Temp. (°C):	50
Equipment No:	1ZDB30000P-263	Oil type:	Mineral Oil	Sampled by:	Transelectric
Serial No.:	1ZDB30000P-263	Year built:	2008	Sampling Date:	2020-07-03
Additional info:					
Description:	ATR				

### DGA

2019-05-21	2020-07-03	Parameter	Screening Code(T/R)	Test Method
16	13	Hydrogen		D3612-17
<1	<1	Acetylene		ppm (V/V)
4	2	Ethane		at 273 K
16	11	Ethylene		and 760 Torr
9	10	Methane		
300	352	Carbon Monoxide		
1756	1665	Carbon Dioxide		
75466	48061	Nitrogen		
16516	9427	Oxygen		
346	388	TDCG (ppm)		
9.41	5.95	Total Dissolved Gas (%)		

### OIL QUALITY

	Previous	2020-07-03	Parameter	Screening Code(T/R)	Test Method
			Moisture in Oil (ppm)		W1017-00
2019-05-21	11	10	Moisture in Oil (ppm)		D 1533-12
2019-05-21	41.8	43.6	Interfacial Tension (mN/m)		D 971-20
2019-05-21	< 0.01	< 0.01	Acid Number (mg KOH/g)		D 974-14e2
2019-05-21	<0.5	<0.5	Color Number		D1500-12
2019-05-21	Pass	Pass	Visual Examination		D 1524-15
2019-05-21	39	31	Dielectric Breakdown (kV)		D 877M-19
			Dielectric Breakdown 2 mm (kV)		D 1816-19
			Power Factor @ 25 °C (%)		D 924-15

Figura 2.1: Resultados de la PE, AGD y AFQ Fuente: SE PASCUALES & MS Morgan Schaffer Julio 2021.

En esta investigación los datos que provienen de los resultados de las pruebas eléctricas realizados a los transformadores de potencia toman mucha relevancia, y para el diseño del modelo matemático computacional creado, se deben considerar los siguientes aspectos:

- Exactitud y precisión de los datos.

- Integridad en la recolección de los datos.
- Periodicidad y frecuencia de recolección de los datos.

A continuación se presenta una metodología que contempla los aspectos que se han llevado y que se sigue llevando en la práctica de pruebas y mediciones realizada a los 7 transformadores de potencia de 230 kV de tensión nominal, por más de 30 años en la subestación eléctrica Pascuales. Para considerar los Mantenimientos Basados en la Condición, se requiere definir una -Condición de Trabajo- de los transformadores EP desde esta perspectiva se utiliza las pruebas AGD (análisis de gases disueltos) y AFQ (análisis físico químico), también la Rigidez dieléctrica (MRDA) (medición de rigidez dieléctrica del aceite) [10], que determinan un diagnóstico muy completo de la situación del transformador.

BDV	Water	Acid	IFT	COLOR	DGA	CO2_CO	AGE
0.93447293	0.16875	0.80582524	0.76712329	0.48780488	0.2416257	0.00583772	15
0.96866097	0.225	0.19902913	0.63013699	0.48780488	0.32336204	0.00528028	16
0.93732194	0.290625	0.17475728	0.83561644	0.48780488	0.48683473	0.02100002	17
0.98860399	0.5625	0.19902913	0.69863014	0.48780488	0.32336204	0.02321119	18
0.71225071	0.4375	0.24757282	0.66438356	0.51219512	0.2416257	0.01872567	19
0.56980057	0.34375	0.27184466	0.63013699	0.49268293	0.45834144	0.0112848	20
0.42735043	0.28125	0.32038835	0.59589041	0.49756098	0.15988936	0.05795813	21
0.28490028	0.15625	0.34466019	0.61643836	0.48780488	0.08438378	0.18623128	22
0.24501425	0.73125	0.13106796	0.55479452	0.48780488	0.75465202	0.0125746	23
0.42735043	0.51875	0.19660194	0.57739726	0.73170732	0.00665416	0.00949827	24
0.51282051	0.4375	0.1868932	0.59589041	0.68292683	0.07815302	0.01531416	25
0.56980057	0.375	0.17475728	0.63013699	0.65853659	0.11902119	0.07217278	26
0.62678063	0.28125	0.16262136	0.64383562	0.63414634	0.2416257	0.00962829	27
0.71225071	0.21875	0.15048544	0.65068493	0.6097561	0.28249387	0.01531416	28
0.74074074	0.15625	0.13834951	0.68493151	0.70731707	0.2416257	0.00806747	29
0.7977208	0.125	0.13106796	0.69863014	0.73170732	0.20075753	0.01531416	30
0.85470085	0.09375	0.10194175	0.75342466	0.75609756	0.23198081	0.01007424	31
0.85470085	0.0625	0.0776699	0.73287671	0.73170732	0.2416257	0.00678536	32
0.85470085	0.03125	0.12621359	0.63013699	0.70731707	0.40509839	0.00516083	33
0.88319088	0.03125	0.10194175	0.65068493	0.75609756	0.72468748	0.00019093	34
0.74074074	0.0625	0.10194175	0.71232877	0.75609756	0.64213378	0.0014869	35
0.68376068	0.21875	0.10194175	0.67123288	0.95121951	0.66501995	0.00350777	36
0.71225071	0.1875	0.13834951	0.65753425	0.85365854	0.48683473	0.00820683	37
0.7977208	0.1875	0.12621359	0.64383562	0.90243902	0.56857107	0.00646948	38
0.85470085	0.21875	0.10194175	0.63013699	0.95121951	0.75411256	0.01174107	39
0.54131054	0.21875	0.34466019	0.59589041	1	0.85955244	0.00922943	40
0.74074074	0.28125	0.36893204	0.49315068	0.41463415	0.73204375	0.00922216	41

Figura 2.2: Tabla de datos de las principales variables para el SID. Fuente: Autor.

En esta investigación la predicción de la frecuencia de fallas se basarán principalmente por las fallas detectadas con estos análisis en el interior del transformador de potencia AGD [15],[5].

Es una necesidad establecer un índice que proporcione un grado o una valoración del estado, de la condición física y de funcionalidad del Transformador de Potencia, se establece el "Índice de Salud" a partir de los datos disponibles y por lo tanto tiene las limitaciones prácticas de dichos resultados, para asignar una ponderación adecuada se utiliza los criterios de IEC, IEEE y CIGRE para estimar el parámetro de la condición [16]. Es conveniente utilizar los resultados del AGD, ya que dispone de muchas variables importantes que han sido estudiadas por las instituciones de normalización como la IEEE y CIGRE.

En 2008 Naderian y col., también consideran otros parámetros como el cambiador de taps, la condición de los bushing, las observaciones físicas, el historial de carga, las ordenes de trabajo y la edad del transformador. Este análisis de criterios múltiples conlleva la combinación de diversos factores de ponderación, así como ajustar los diferentes criterios que recomiendan las normas indicadas en ASTM, IEC, IEEE y CIGRE, pero finalmente el conocimiento del estado y la funcionalidad que tienen los equipos, así como las observaciones físicas es un aspecto de gran importancia para definir una "Condición".

Siguiendo la tendencia mundial, las empresas de tratamiento de la electricidad desarrollan planes de mantenimiento de sus activos basados en la "Condición", conocido como **Mantenimiento Basado en la Condición (CBM)** (Condition Based Management), con el propósito de aumentar la potencialidad, la confiabilidad y la disponibilidad de dicho activo [4]. De una forma más práctica y directa se establece la estimación de la "Condición" del Transformador de Potencia, pero considerando las pruebas más significativas, sin considerar parámetros o pruebas redundantes que aborden los mismos aspectos para la estimación de esta "Condición".

En 2013 Santana R. y col., realizan un análisis de las principales fallas que suceden en los transformadores de potencia, las que utiliza para considerar las pruebas eléctricas más significativas que se requieren para detectar las mismas, según se muestra la tabla 2.1.



Tabla 2.1: Causas de fallas más frecuentes en los transformadores de potencia.

Fuente: Santana R. y col., 2013 [4].

INTERNAS	EXTERNAS
Envejecimiento del aislamiento Sobrecarga, Humedad, Oxígeno Descargas parciales, Problemas mecánicos Partículas contaminantes	Descargas atmosféricas Descargas por maniobras Sobrecarga del sistema Fallas en la red

En la actualidad se cuentan con algoritmos de Inteligencia Artificial muy eficientes y con gran capacidad computacional que permiten la convergencia de dichos algoritmos y la Máquinas de Aprendizaje o Aprendizaje Automático ha evolucionado que es posible aplicarlo prácticamente en muchos aspecto de la ingeniería [17].

Se ha realizado la evaluación de la "Condición" del Transformador de Potencia como un valor porcentual del "Índice de Salud" [Health Index \(HI\)](#), basados en modelos de regresión que se estudian como técnicas de la Máquina de Aprendizaje o Aprendizaje Automático [17]. Las técnicas inteligentes de aprendizaje automático requieren datos que se deben utilizar para ajustar el modelo, primero la máquina automática requiere un proceso de entrenamiento hasta que la máquina se ha ajustado o ha aprendido y luego es posible estimar una respuesta de predicción que podrá ser contrastada con una respuesta que se ha indicado como una respuesta verdadera o una respuesta objetivo.

En 2020 Leauprasert K. y col., desarrollaron un proyecto que permite evaluar una estimación de la condición de los transformadores de potencias usando varios modelos de regresión que se utilizan en Aprendizaje Automático, los seis modelos empleados fueron:

1. Regresión Lineal.
2. Regresión Ridge.
3. Regresión Lasso.
4. Regresión con Bosque Aleatorio.

5. Regresión con Máquina de Vector de Soporte.
6. Regresión con Red Neuronal Profunda.

Para la evaluación de las condiciones de cada elementos del transformador de potencia se utiliza el siguiente conjunto de datos de entrada, para cada uno de los modelos de regresión implementada en la investigación.

- Datos de inspección visual.
- Pruebas eléctricas.
- Pruebas de aislamiento del aceite.
- Pruebas de aislamiento del papel.

En total se seleccionan 90 atributos o características de estos conjuntos de datos de entrada para los modelos de regresión y determinar el "Índice de Salud" HI predictivo. En esta investigación se tomaron datos de 317 transformadores.

En la figura 2.3, se muestra un diagrama de bloques en donde se clasifican las técnicas de "Aprendizaje Supervisado" (Supervised learning) y "Aprendizaje no supervisado" (Unsupervised learning) que son los principales métodos que se usan en la "Máquina de Aprendizaje". En el aprendizaje Supervisado el modelo se entrena a partir de los datos de entrada y de salida hasta llegar a su ajuste y luego se puede realizar las predicciones de futuras salidas. En el aprendizaje No Supervisado el modelo se entrena a partir de los datos solo de entrada, pues la salida está oculta y se estima como una estructura intrínseca relacionada con los datos de la entrada. En el segundo nivel del diagrama de bloques se observan tres tipos de operaciones que se realizan estas son:

1. La Clasificación (Classification).
2. La regresión (Regression).
3. El agrupamiento (Clustering).

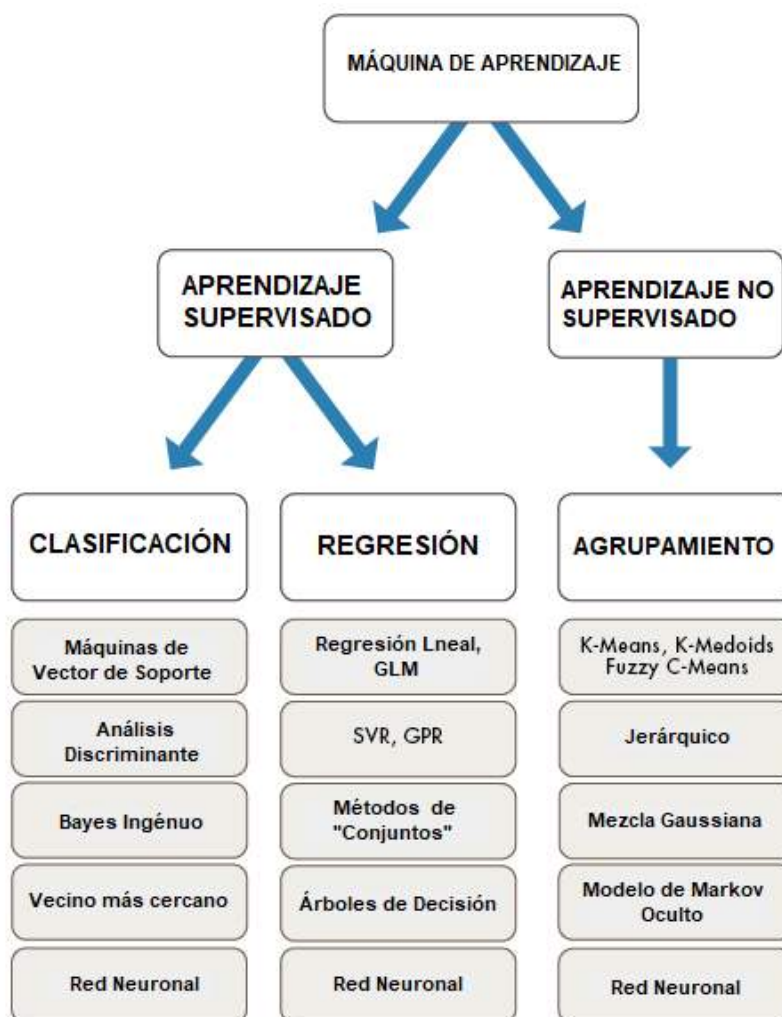


Figura 2.3: Tipos de modelos de la Máquinas de Aprendizaje. Fuente: Math-Works, 2019 [1].

En esta investigación el diseño de la máquina de aprendizaje se ha basado en el aprendizaje supervisado por los datos proporcionados a partir de las PE del Departamento de Mantenimiento de la subestación Pascuales. Se considera los datos de entrada de varios grupos de las PE que se realizan a los Transformadores de Potencia, es decir se escogerán de las siguientes:

1. Medición de factor de potencia del aislamiento.
2. Medición de factor de potencia de bushings.
3. Medición de factor de potencia de aceite dieléctrico.
4. Medición de corriente de excitación.
5. Medición de relación de transformación (TTR).
6. Medición de resistencia de devanados.
7. Medición de resistencia de aislamiento.
8. Medición de respuesta de frecuencia.
9. Medición de reactancia de dispersión.
10. Pruebas de TC's tipo bushings.
11. Tomas de muestra de aceite para AFQ y AGD.
12. Medición de rigidez dieléctrica del aceite.

La salida es la "Condición" de funcionamiento del transformador de potencia, que ha sido determinada a partir de la técnica basada en Inferencias Difusas explicadas anteriormente y se la ha denominado "Condición de Trabajo" (CT). El valor de [Condición de Trabajo \(CT\)](#) es un número decimal entre [0,1], donde el valor "CERO" significa que el transformador de potencia no está en operación o que está inhabilitado, y que el valor "UNO" significa que el transformador de potencia esta al 100% de su condición de funcionamiento y es como si recién estuviera en operación

Otro aspecto importante que se debe tener en cuenta es el procesamiento de los modelos de Aprendizaje Automático seleccionados. El flujo de este procesamiento se define en varias etapas que deben cumplir todos los modelos predictivos para alcanzar el objetivo de la predicción de un banco de datos de prueba. La figura 2.4 [17] consta de las siguientes etapas:

1. Preprocesamiento de los datos, los datos se configuran como entradas que están formados por uno o varios atributos o características de las variables y el etiquetamiento es el resultado o destino que tiene la respuesta del modelo para dichas entradas, se configuran una base de datos segmentada, los de Entrenamiento y los de Validación. Aquí se debe extraer las características de los datos, en ciertos casos es necesario aplicar reducción de dimensionalidad o aplicar técnicas de muestreo.

2. Aprendizaje, que es el objetivo de realizar el entrenamiento y aquí se diferencian los modelos, ya que los algoritmos de aprendizaje dependen del diseño del modelo y de los parámetros que requiere cada uno, que se relacionan con formas de validación, medición del rendimiento y formas de optimización y convergencia.

3. Evaluación del modelo, con la fracción de la base de datos (datos de Validación) se realiza la validación del modelo, con estos datos se determinan uno o varios Indicadores de Evaluación (entre las Etiquetas de la respuesta Verdadera y las Etiquetas de la respuesta predicha por el modelo) que dan la referencias del rendimiento del modelo entrenado. Según sea la operación realizada, Regresión, Clasificación o Agrupamiento, se van a definir diferentes tipos de Indicadores de Evaluación.

4. Predicción, con una nueva base de datos o simplemente datos configurados en atributos o características de entrada y Etiquetas que son las respuestas asumidas como una predicción, se carga al modelo ajustado o entrenado previamente, ya que el modelo debe estar listo con el aprendizaje óptimo. Ahora los resultados de la evaluación tendrán otros valores, pues los datos y las etiquetas son diferentes.

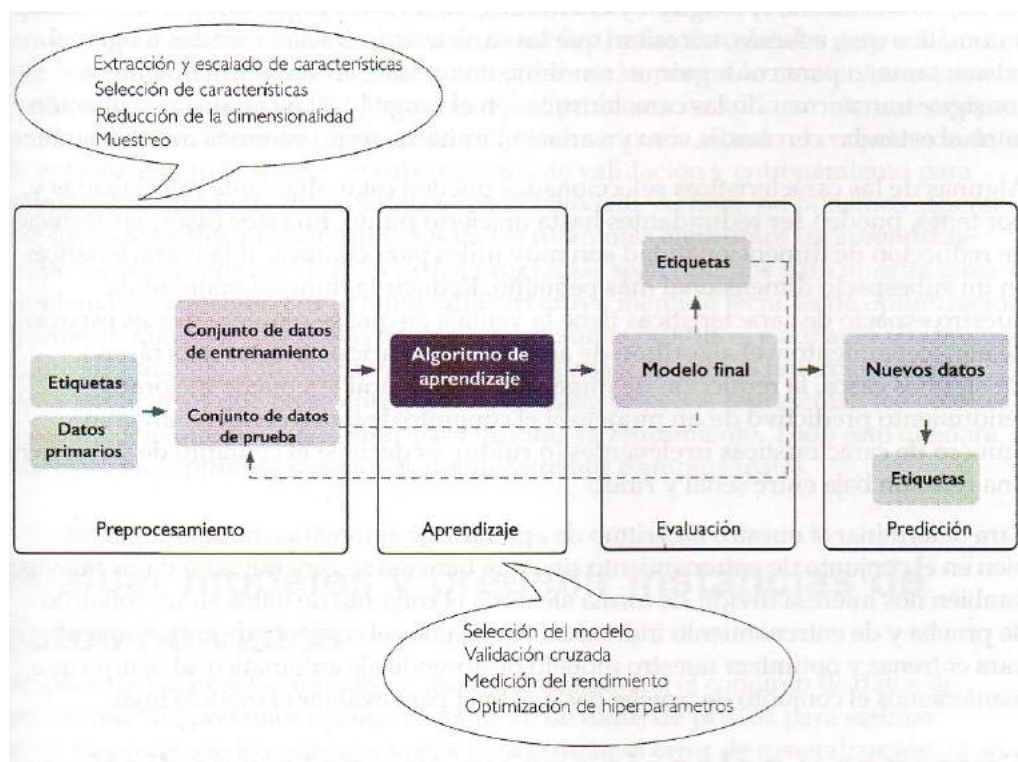


Figura 2.4: Flujo de trabajo completo del procesamiento de un Modelo. Fuente: Python Machine Learning by Sebastian Raschka [2].

Para que el modelo de la "Maquina de Aprendizaje" sea efectiva y tenga un rendimiento satisfactorio siempre es necesario realizar muchos ajustes y varias simulaciones, algunas veces es más eficiente cuando se cuenta con una base de datos de entrenamiento lo suficientemente grande para que el ajuste sea óptimo, por esa razón se recomienda utilizar varios Indicadores de la Evaluación para garantizar un modelo efectivo [18]. A continuación la Tabla 2.2 muestra los principales artículos seleccionados y estudiados del Estado del Arte que se utilizó para hacer la propuesta de la solución al problema planteado en esta investigación AGD <sup>1</sup> adicionalmente se ha utilizado un trabajo previo sobre la recopilación y tratamiento de los datos de las pruebas eléctricas de los equipos primarios de la subestación eléctrica Pascuales.

<sup>1</sup>Las referencias [17, 18, 19]

Tabla 2.2: Resumen del "Estado del Arte" sobre predicciones de fallas de transformadores de potencia basados en modelos de Aprendizaje Automático aplicando resultados de las pruebas eléctricas y análisis de gases disueltos en el aceite del transformador AGD.

Artículo	Temática			Problema				Restricciones				Propuesta				
	Pruebas eléctricas	Normativas	Predicción	Mantenimientos	Recolección datos	Correcciones	Recursos	Fallas eléctricas	Cantidad datos	Pruebas aplicadas	Tiempo proyección	Confiabledad datos	Condición Trabajo	Modelos Lógicos	Modelos Probabilísticos	Modelos Redes Neuronales
Mahrugh [15]		✘	✘		✘		✘		✘	✘	✘		✘	✘		✘
Leauprasert [17]	✘	✘	✘	✘	✘	✘		✘	✘	✘		✘				✘
Naderian [16]	✘		✘		✘		✘		✘		✘				✘	✘
Arias [18]	✘						✘	✘			✘	✘	✘			
Prasojo [5]		✘	✘	✘	✘	✘		✘	✘	✘		✘				✘
Kong [19]	✘		✘		✘		✘		✘		✘				✘	✘
Wu-liang [20]	✘		✘	✘	✘	✘		✘		✘		✘		✘		✘
Santana [4]	✘					✘	✘			✘	✘	✘	✘			✘
Haema [21]		✘	✘	✘	✘	✘		✘	✘	✘	✘	✘		✘	✘	✘
Murugan [7]	✘						✘	✘			✘	✘	✘			
Aldhubaib [9]	✘	✘	✘	✘	✘	✘		✘	✘	✘	✘	✘		✘	✘	✘
Alvarado [6]	✘		✘		✘		✘		✘		✘				✘	✘
Duval [10]	✘						✘	✘			✘	✘	✘			

# Capítulo 3

## Metodología propuesta

### 3.1. Introducción

La propuesta se basa en la aplicación de redes neuronales que utilizarán la información de las pruebas eléctricas correspondientes al análisis físico y químico, al análisis de gases disueltos, la edad de los transformadores de potencia. Ha sido una selección de pruebas eléctricas basadas en las recomendaciones que hace las normas de la IEEE Std C57.104-2019.

La figura 3.1 muestra en bloques las etapas que conforman el método diseñado y construido para resolver el problema. El primer bloque de la izquierda cuyo centro dice "SISTEMAS DE INFERENCIAS DIFUSOS" (SID) indica que este sistema se utiliza para obtener un resultado llamado "CONDICIÓN" (Condición de Trabajo - CT) que es obtenido a partir de las variables seleccionadas como entradas, a través de las funciones de membresía son fusificadas a cada conjunto del universo difuso de acuerdo con las etiquetas que se utilizan en las reglas lingüísticas del sistema para definir una operación de la lógica difusa y después de realizar el proceso de defusificación y determinar dicho resultado. Estas reglas son consideradas por el criterio de operación y por los criterios y recomendaciones que proporcionan las normas y estándares del IEEE Std C57.104-2019.

El segundo bloque es el de la derecha que requiere el resultado obtenido del SID como resultado objetivo de la "CONDICIÓN" que tiene cada transformador de potencia para cada una de las mediciones realizadas, los atributos o características de entrada han sido tomadas de los resultados de las prue-



bas eléctricas seleccionadas con sus valores tal como se dan en la mediciones, a este conjunto de datos se los conoce como "Datos de Entrenamiento" y son utilizados por el modelo para que realice su ajuste. Después de sintonizar los parámetros de aprendizaje y que el resultado del entrenamiento sea satisfactorio, pues el Indicador del Rendimiento de la Máquina de Aprendizaje tienen un valor adecuado (esto verificamos con el resultado de la validación del modelo) entonces el "Modelo es APTO" y se recomienda testearlo con la base de prueba.

El tercer bloque es el de la parte inferior izquierda y es utilizado cuando el modelo de la "Máquina de Aprendizaje" ya está listo, y aún así los resultados son evaluados con los mismos indicadores con los que fueron probados con la base de Entrenamiento. A la derecha de este bloque se encuentra el resultado de la "Predicción" y según el modelo esté variará, ya que la idea no es modificar la base de "Datos de Prueba" sino probar todos los modelos con la misma base de predicción.

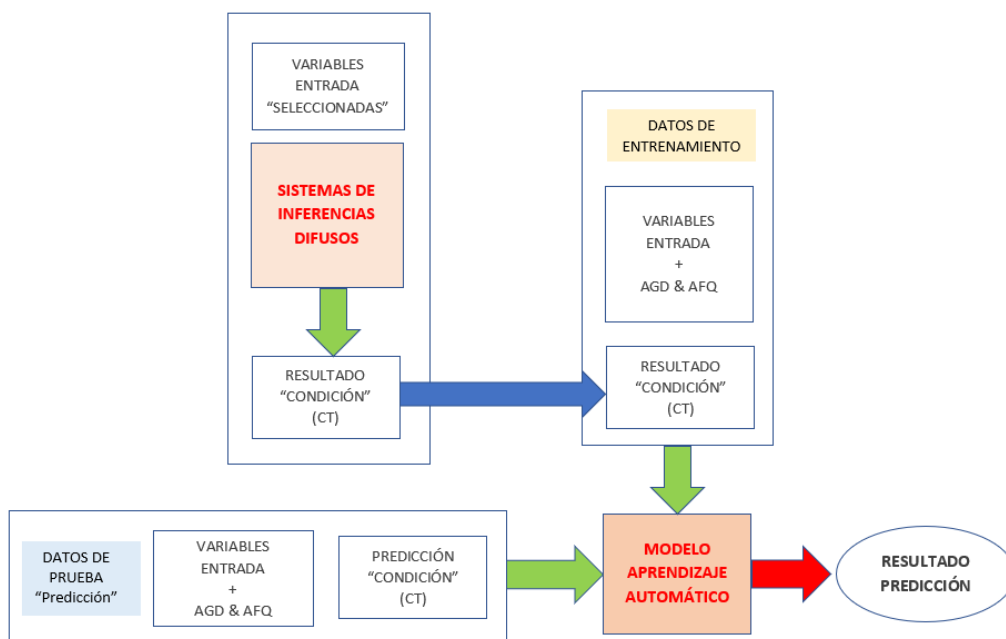


Figura 3.1: Diagrama del bloque del proyecto de investigación. Fuente: Autor.

## 3.2. Problema: Tratamiento de los datos

De los archivos físicos y digitales recibidos por la jefatura y el departamento de mantenimiento de la [Zona Sur Occidental de la Corporación Eléctrica del Ecuador \(ZOSX\)](#) de la subestación CELEC EP TRANSELECTRIC Pascuales, se encuentran los registros más antiguos de 1982, con periodicidad muy variada, y en algunos casos no poseen los valores de todos los parámetros que se indican en las pruebas. Este trabajo se ha concentrado en las pruebas eléctricas de los transformadores de potencia de la subestación, denominados:

- ATT-FA TRANSELECTRIC.
- ATT-FB TRANSELECTRIC.
- ATT-FC TRANSELECTRIC.
- ATU-FA TRANSELECTRIC.
- ATU-FB TRANSELECTRIC.
- ATU-FC TRANSELECTRIC.

El objetivo de la presente etapa es definir las pruebas más significativas y que conceptualmente sean más abarcadoras de posibles fallas, pues varias pruebas podrían ser absorbidas por un sola prueba, tal como es el caso de las siguientes pruebas [4]:

1. Factor de potencia.
2. Análisis de gases disueltos.
3. Factor de potencia en boquillas.
4. Resistencia de aislamiento.
5. Relación de transformación.
6. Corriente de excitación.
7. Furaldehído.

Los resultados de la primera, tercera, cuarta, quinta y sexta pruebas pueden ser equivalentes a los resultados de la prueba 3.12 Medición de rigidez dieléctrica del aceite **MRDA**, en inglés esta prueba es BDV (Breakdown Voltage). De acuerdo a los resultados de la pruebas en [16], se seleccionan otras variables más abarcadoras, y si se revisan el trabajo de [5] se puede reducir a las siguientes variables:

1. Tensión de ruptura (BDV).
2. Contenido de Humedad (Water).
3. Número de neutralización (Acid).
4. Tensión Interfacial (IFT).
5. Prueba de color (Color).
6. Análisis de Gases Disueltos (DGA).
7. Relación Dióxido a Monóxido de Carbono ( $\text{CO}_2/\text{CO}$ ).
8. 2 Furfuraldehido (2FAL).
9. Tiempo de operación (AGE).

Los siguientes pasos corresponden a la metodología empleada para configurar los datos que se utilizaron para la fase de entrenamiento, se debe indicar que para el esquema de aprendizaje supervisado aplicado se debe aprovechar el conocimiento y la experiencia de más de 30 años que tienen los supervisores y técnicos de mantenimiento en la subestación eléctrica, sobre el estado y la "condición de trabajo" de los transformadores de potencia, que es estimada en base a los resultados de las pruebas y de la operación permanente y continua del sistema.

Para el desarrollo de esta investigación en la subestación eléctrica Pascuales se cuenta con todas estas pruebas, para todos los transformadores, excepto las mediciones de Furaldehido 2 (2FAL), pues se ha realizado con muy poca frecuencia y no se ha aplicado a todos los transformadores de potencia, por lo que se ha excluido como variable a considerar la determinación de la "Condición", así como para el entrenamiento de los modelos de "Aprendizaje Automático".

### 3.3. Problema de determinación de la condición de trabajo del Transformador de Potencia

El resultado esperado es la "Condición de Trabajo" que poseería cada transformador de potencia, para los valores de predicción que se estima en las variables de entrada, pero que se basan en el modelo de entrenamiento configurado con redes neuronales artificiales. El modelo de aprendizaje supervisado requiere que un conjunto de valores de entrada se emparejan con una o varias de variables de salida.

#### 3.3.1. Aplicación de Sistemas de Inferencias Difusos

El sistema de inferencias difusos [SID](#), se aplica como la herramienta más adecuada para estimar la –condición– de cada transformador de potencia de la subestación eléctrica, considerando la experiencia y el conocimiento del personal técnico del Departamento de Mantenimiento de la [ZOSX](#).

Tabla 3.1: Variables o Conjuntos Difusos de Entrada. Fuente: Prasojo R. y col.,2021 [5].

1.	El conjunto BDV.
2.	El conjunto Water.
3.	El conjunto Acid.
4.	El conjunto IFT.
5.	El conjunto Color.
6.	El conjunto DGA.
7.	El conjunto CO <sub>2</sub> /CO.
8.	El conjunto AGE.

En la Tabla [3.1](#) se muestran los conjuntos difusos que se han utilizado para establecer las relaciones difusas y que posteriormente estos conjuntos requieren definir uno a uno las funciones de pertenencia según la "etiqueta" que los expertos (especialistas del departamento de mantenimiento) deben definir, con las prioridades correspondientes según la importancia o el grado de relevancia que cada uno tiene.

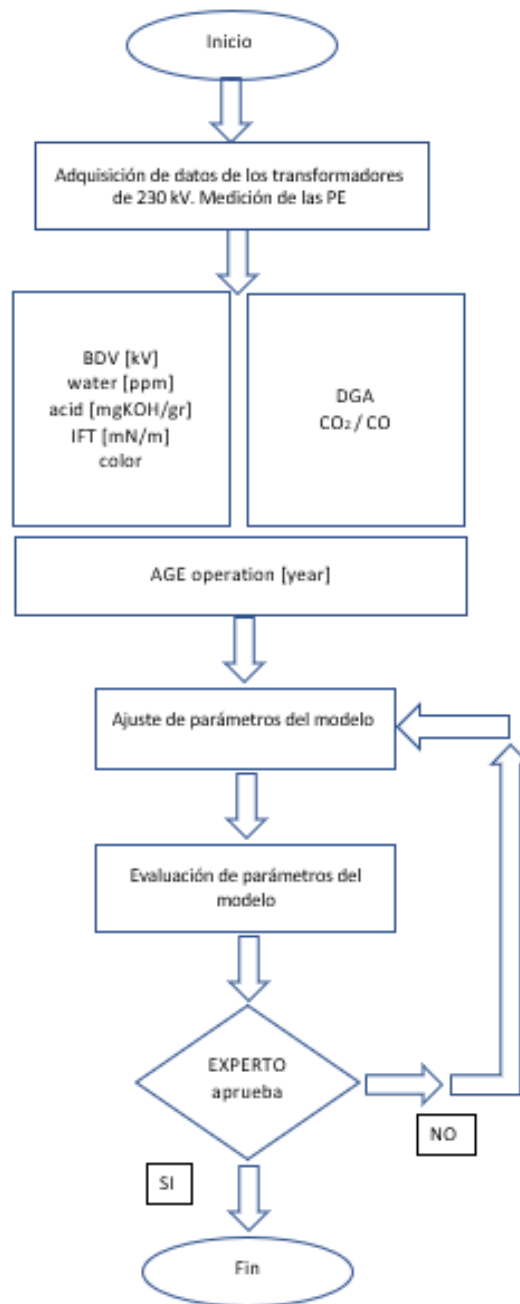


Figura 3.2: Flujo de trabajo que utiliza el modelo de SID. Fuente: Autor.

En la figura 3.2, se muestra un diagrama de flujo que representa el diseño del modelo aplicado al Sistema de Inferencias Difusas, se da paso cuando el Jefe del Departamento de Mantenimiento ha aprobado la "Condición de Trabajo" de cada uno de los resultados de las pruebas eléctricas realizadas, para cada uno de los transformadores.

El flujograma inicia con la adquisición de los datos de las pruebas eléctricas, corresponden a las mediciones de varias pruebas en diferentes unidades y corresponden a las variables del "Análisis de Gases Disueltos" y al "Análisis Físico y Químico" del aceite interior de los transformadores de potencia, los que serán normalizados en sus correspondientes conjuntos difusos, excepto el tiempo de funcionamiento de los transformadores que se denominan "AGE". También se han configurado las operaciones difusas para la fusificación según las "etiquetas" y las "reglas lingüísticas", el experto contribuye con sus criterios y experiencias sobre la prioridad y relevancia, en el proceso de la salida también se aplica el proceso de defusificación que establece el nivel requerido en todo el modelo, todo lo cual se ha denominado "Ajustes de parámetros del modelo", al final el resultado del modelo es aprobado por el personal técnico del departamento de mantenimiento de la subestación.




Figura 3.3: Diagrama de Entradas y Salidas del modelo Mamdani construido para el SID. Fuente: Autor y MathWorks, 2014 [3].

En la figura 3.3, se muestra un diagrama de bloques construido con el editor de Inferencias difusas de (MATLAB) donde se indica el modelo lingüístico difuso Mamdani, las variables de entrada y las variables de salida [3].

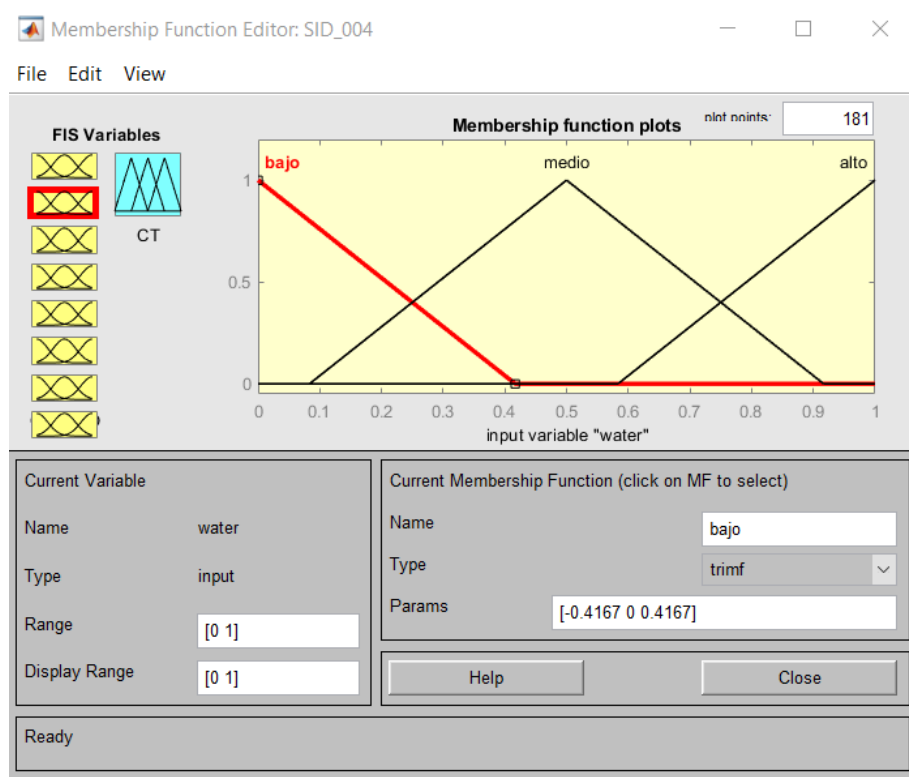


Figura 3.4: Función de Pertencia o Membresía de la señal de Entrada "Water".  
Fuente: Autor y MathWorks, 2014 [3].

En la figura 3.4, se muestra un diagrama de las funciones de Membresía para cada una de las etiquetas relacionadas con la característica de la variable o atributo de la prueba eléctrica indicada en el nombre de la variable de entrada.

Para cada una de las variables de los conjuntos difusos, de entrada y de salida se han definidos las funciones de pertenencia: "Alto", "Medio" y "Bajo", del tipo "Triangular" la más adecuada, pero no es la única que se puede definir, y que está en correspondencia con las "etiquetas" lingüísticas usadas en el modelo por el experto. Los valores de pertenencia han sido establecidos por el criterio y la experiencia del personal técnico de la subestación eléctrica.

En la figura 3.5, se muestra el editor de las reglas lingüísticas de las 8 variables utilizadas de las pruebas eléctricas, con las cuales se ha realizado 42 reglas y a todas las reglas se les ha asignado un ponderación de importancia o valor de prioridad.

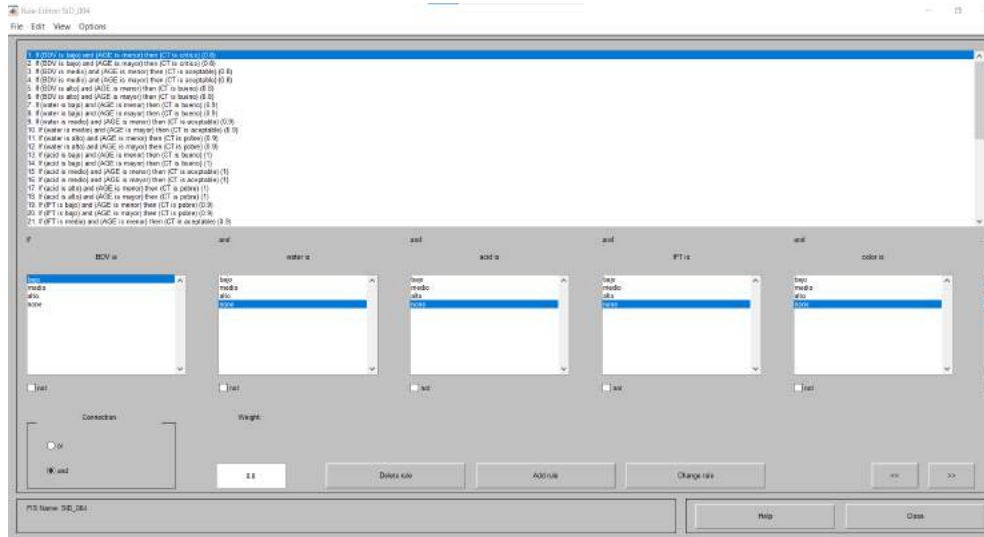


Figura 3.5: Tabla de las 42 reglas lingüísticas creadas para el modelo de SID. Fuente: Autor y MathWorks, 2014 [3].

Las reglas lingüísticas se fundamentan en las relaciones difusas que establece el experto, tal cual los realiza en el nivel lógico de análisis propio, para estimar que anda mal en los resultados mostrados en las pruebas, fundamentado en su conocimiento y experiencia de las normas y estándares de la industria eléctrica nacional e internacional.

En este trabajo, para establecer con claridad como afectan todas las entradas del modelo (mediciones de las pruebas eléctricas) a la salida "Condición de Trabajo" (CT) el experto recomienda analizarlas por grupos relacionadas según las normas, las mediciones de "Gases Disueltos" respecto al tiempo de operación "AGE" y las mediciones del "Aceite" respecto al tiempo de operación "AGE". Así mismo es el experto que determina la prioridad de las 42 reglas difusas que son establecidas para estimar (CT).



En la figura 3.6, se muestra el resultado que se obtiene a partir del modelo de Inferencia Difuso con los valores de cada una de las variables de entradas al sistema llamado SID, este resultado es el que se conoce como "Condición de Trabajo" (CT).

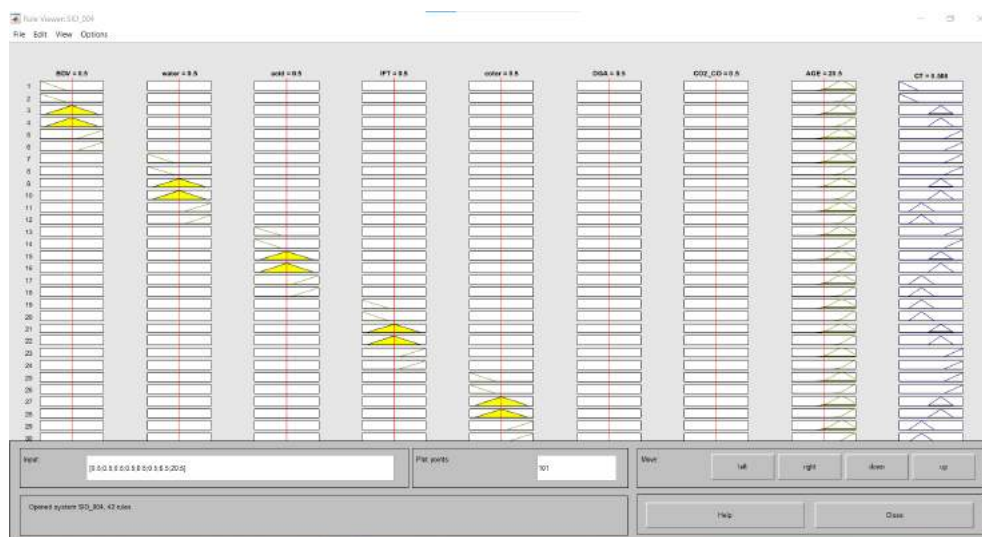


Figura 3.6: Editor de Resultados de la "Condición de Trabajo" obtenida del modelo de SID. Fuente: Autor y MathWorks, 2014 [3].

El supervisor del departamento de mantenimiento de la subestación eléctrica recomendó usar los niveles recomendados por normas y estándares:

- BUENO equivalente a "excellent".
- ACEPTABLE equivalente a "normal".
- POBRE equivalente a "poor".
- CRÍTICO equivalente a "bad".

Luego se debe aplicar este modelo SID a todos los juegos de variables de entradas al sistema, entonces para cada juego se obtienen la salida llamada CT, las mismas que se utilizarán para los modelos de Aprendizaje Automático, se requieren como "objetivo" o también llamados "Destinos" (targets) para que el

modelo de aprendizaje automático se entrene y se ajuste. Las reglas difusas son configuradas por los expertos, y con ellas se obtiene la "Condición de Trabajo" a partir de los estados o de las etiquetas que poseen las funciones de pertenencia para cada una de las variables de las pruebas eléctricas aplicadas.

### 3.3.2. Problema de entrenamiento y la predicción con modelos de Aprendizaje Automático

En esta sección se explica como se plantea el modelo matemático configurado con las redes neuronales aplicada a la estructura de los datos utilizados SID. En la estructura se plantea una porción de los datos para realizar el ajuste del modelo, otra porción de los datos se utiliza para la verificación del modelo y la última porción de datos que se utiliza para hacer la "prueba de la predicción" que es el fin de este proyecto. Se debe indicar las medidas de certeza que tiene el modelo y para ello se han colocado algunos indicadores.

En la figura 3.7, se muestra el diagrama de bloque general que en forma simplificada se explica cómo funciona el modelo de la "Máquina de Aprendizaje": Con un "Problema resuelto" ("Juego de Datos Originales"), el modelo obtiene el "Conocimiento".<sup>a</sup> partir de este "Conocimiento" se puede probar un "Nuevo problema" ("Datos de pruebas o de pronóstico") y con ello se tendrá "Solución del nuevo problema" ("Resultados de pronóstico").

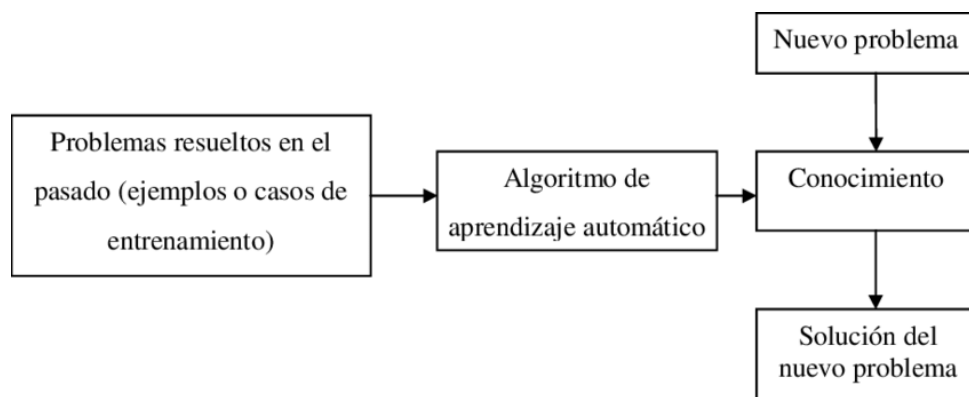


Figura 3.7: Diagrama de bloque que aborda el Problema del Aprendizaje. Fuente: Autor y MathWorks, 2014 [3].

En la figura 3.8, se muestra el diagrama de bloques que define las etapas de los actuales modelos de "Aprendizaje Automático", primero se carga los datos, segundo hay que reducir depurar o simplificar los datos, tercero se extraen las principales características, cuarto la repetición con muchos datos se llama entrenamiento, hasta llegar "aprender" y el modelo se construye o ajusta, quinto hay que iterar modificando parámetros del modelo porque no siempre se llegan a resultados buenos es por eso que se requiere evaluar el modelo con indicadores de su rendimiento, finalmente se realiza la aplicación del modelo ajustado para un pronóstico.

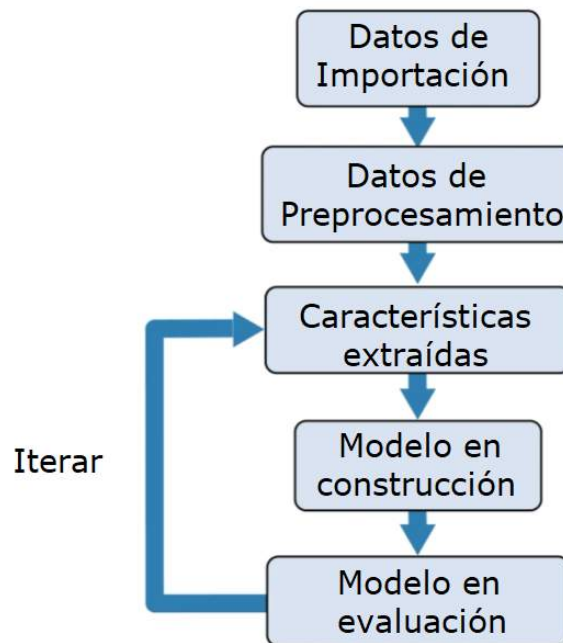


Figura 3.8: Flujo de trabajo de un Modelo de Aprendizaje Automático. Fuente: MathWorks [1].

Este flujo de trabajo refleja la operación que se ha realizado en la segunda etapa de este proyecto de desarrollo, pues con los datos ordenados y el objetivo fijado como "condición" (CT) se construyen los diferentes modelos aquí desarrollados, cada uno de ellos extrae las características de los datos hasta construirlos y se aplican diferentes índices para evaluarlos.

En la figura 3.9, se muestra una fracción de la tabla que contienen los datos para el entrenamiento, se visualizan 15 atributos por cada muestra, es decir que cada muestra para un modelo tiene 15 variables de entrada y una variable objetivo o de salida.

57.8	59	57.9	59.7	50	45	40	35	33.6	40
8.4	10.2	12.3	21	17	14	12	8	26.4	19.6
0.039	0.014	0.013	0.014	0.016	0.017	0.019	0.02	0.0112	0.0139
37	35	38	36	35.5	35	34.5	34.8	33.9	34.23
1.45	1.45	1.45	1.45	1.5	1.46	1.47	1.45	1.45	1.95
15	12	10	16	13	14	15	12	16	14
26	24	20	15	28	30	35	26	24	25
30	33	36	35	32	30	26	24	28	33
150	170	100	90	100	127	80	50.82	165	13.687
1000	1100	1200	1150	1120	1090	2000	3563.5	1491	108.87
25000	26000	28000	35000	32000	31500	30000	25000	35000	37000
2500	2200	1800	2200	1900	2300	2500	2800	1950	1800
3	4	6	4	3	5.6514	2	1.07623	9.2766	0.12525
6.66666667	6.47058824	12	12.77777778	11.2	8.58267717	25	70.1200315	9.03636364	7.95426317
15	16	17	18	19	20	21	22	23	24
0.5	0.51312241	0.51312241	0.51312241	0.51317757	0.51317757	0.51322245	0.50545498	0.50962446	0.52814404
1995	1996	1997	1998	1999	2000	2001	2002	2003	2004

Figura 3.9: Base de Datos de Entrenamiento. Fuente: Autor.

En la figura 3.10, se muestra el una fracción de la tabla que contienen los datos para la prueba o predicción, se visualizan 15 atributos por cada muestra, es decir que cada muestra para un modelo tiene 15 variables de entrada y una variable de predicción o de salida.

57.8	59	57.9	59.7	50	45	40	35	33.6	40	43
8.4	10.2	12.3	21	17	14	12	8	26.4	19.6	17
0.039	0.014	0.013	0.014	0.016	0.017	0.019	0.02	0.0112	0.0139	0.0135
37	35	38	36	35.5	35	34.5	34.8	33.9	34.23	34.5
1.45	1.45	1.45	1.45	1.5	1.46	1.47	1.45	1.45	1.95	1.85
15	12	10	16	13	14	15	12	16	14	13
26	24	20	15	28	30	35	26	24	25	28
30	33	36	35	32	30	26	24	28	33	31
150	170	100	90	100	127	80	50.82	165	13.687	20
1000	1100	1200	1150	1120	1090	2000	3563.5	1491	108.87	200
25000	26000	28000	35000	32000	31500	30000	25000	35000	37000	38000
2500	2200	1800	2200	1900	2300	2500	2800	1950	1800	2000
3	4	6	4	3	5.6514	2	1.07623	9.2766	0.12525	1
6.66666667	6.47058824	12	12.77777778	11.2	8.58267717	25	70.1200315	9.03636364	7.95426317	10
42	42.25	42.5	42.75	43	43.25	43.5	43.75	44	44.25	44.5
0.5	0.51312241	0.51312241	0.51312241	0.51317757	0.51317757	0.51322245	0.50545498	0.50962446	0.52814404	0.54055554
2022	2022.25	2022.5	2022.75	2023	2023.25	2023.5	2023.75	2024	2024.25	2024.5

Figura 3.10: Base de Datos de Prueba. Fuente: Autor.

La Tabla que contienen los "datos de prueba" o "predicción" se debe realizar continuamente según se vayan obteniendo los nuevos resultados de las mediciones futuras, es necesario que los especialistas estimen una nueva "condición" (CT) y son los modelos que estiman el valor más probable.

En esta investigación debido a las características y cantidad de datos se ha preferido realizar la aplicación de diferentes modelos de Aprendizaje Automático para regresiones, y se han configurado con funciones de MATLAB versión 2021a, las mismas que están indicados en la Tabla 3.2

Tabla 3.2: Modelos de Aprendizaje Automático utilizados. Fuente: Autor y MathWorks, 2019 [1].

1.	Regresión con árboles de decisión.
2.	Regresión con SVM Lineal.
3.	Regresión de proceso gaussiano.
4.	Regresión con Bosques aleatorios.
5.	Regresión con red neuronal corta.
6.	Regresión lineal.

Basados en las investigaciones observadas y analizadas en el "Estado del Arte" se han considerado los modelos que se encuentran en la Tabla 3.2, además los algoritmos computacionales que se han utilizado a partir de los modelos matemáticos de estas regresiones aplicadas en "Aprendizaje Automático" están documentadas y explicadas en Toolboxes, Apps y Funciones de MATLAB y en la plataforma de Mathworks. Esta memoria no incluyen las bases matemáticas que sustentan los modelos matemáticos de estas regresiones por considerarlas de menor impacto que el resultado y de la aplicación de las matemáticas al problema planteados en esta investigación [1].

# Capítulo 4

## Análisis de resultados

### 4.1. Introducción

En esta sección se presentan diferentes simulaciones sobre las predicciones realizadas a los transformadores de potencia, respecto a las pruebas eléctricas que permiten estimar una condición de estado y de funcionamiento, por lo tanto proporcionan soluciones a los problemas planteados en la sección 3.2 respecto del Problema de entrenamiento y la predicción con modelos de Aprendizaje Automático para determinar la condición de trabajo que tendrá el Transformador de Potencia EP, así como establecer medidas apropiadas para evitar las posibles fallas de su funcionamiento.

### 4.2. Resultados Generales

#### 4.2.1. Aplicación de Sistemas de Inferencias Difusos

Para resolver el problema de la aplicación del Sistema de Inferencias Difusos detallado en el capítulo 3, se ha utilizado: N mediciones en una base de datos correspondientes a 27 años de pruebas eléctricas, reglas lingüísticas del Supervisor de Mantenimiento de la subestación, fundamentadas en la experiencia y en las normas o estándares recomendados de la IEEE, [American National Standards Institute \(ANSI\)](#), IEC, para determinar un valor de la "Condición de Trabajo" (CT) que debe tener cada Transformador de Potencia EP.

Para establecer un criterio unificado para definir la Condición de Trabajo (CT) de los transformadores de potencia, todos han sido analizados con las mismas siete variables, indicadas anteriormente en el capítulo anterior. Fue necesario realizar una normalización al valor unitario para trabajar como un solo conjunto entre los transformadores de potencia cuya identificación es el número de serie, el mismo que se indica en el siguiente listado:

- Transformador 1: 5BA225406.
- Transformador 2: 5BA225405.
- Transformador 3: 5BA225408.
- Transformador 4: 5BA225407.
- Transformador 5: 62484.
- Transformador 6: 62486.

En la figura 4.1 se presentan fracción de la matriz que se utilizó en el SID para el transformador 5BA225405, contiene el valor de 7 entradas normalizadas y la variable AGE, se presenta con su valor real. el resultado llamada "Condición de Trabajo" (CT) se presenta con valores en el intervalo [0,1] y la fila que contiene esta información para cada una de las mediciones es de color verde.

0.93447293	0.96866097	0.93732194	0.98860399	0.71225071	0.56980057	0.42735043	0.28490028	0.24501425	0.42735043
0.16875	0.225	0.290625	0.5625	0.4375	0.34375	0.28125	0.15625	0.73125	0.51875
0.80582524	0.19902913	0.17475728	0.19902913	0.24757282	0.27184466	0.32038835	0.34466019	0.13106796	0.19660194
0.76712329	0.63013699	0.83561644	0.69863014	0.66438356	0.63013699	0.59589041	0.61643836	0.55479452	0.57739726
0.48780488	0.48780488	0.48780488	0.48780488	0.51219512	0.49268293	0.49756098	0.48780488	0.48780488	0.73170732
0.2416257	0.32336204	0.48683473	0.32336204	0.2416257	0.45834144	0.15988936	0.08438378	0.75465202	0.00665416
0.00583772	0.00528028	0.02100002	0.02321119	0.01872567	0.0112848	0.05795813	0.18623128	0.0125746	0.00949827
15	16	17	18	19	20	21	22	23	24
0.5	0.51312241	0.51312241	0.51312241	0.51317757	0.51317757	0.51322245	0.50545498	0.50962446	0.52814404
1995	1996	1997	1998	1999	2000	2001	2002	2003	2004

Figura 4.1: SID: Entradas y resultados de la CT de un transformador Fuente: Autor.

En la figura 4.2 se muestra todos los resultados de la "Condición de Trabajo" (CT) obtenidos utilizando el SID, un valor ara cada una delas mediciones de las pruebas para cada uno de los transformadores.

	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004
5BA225406_1	0.5	0.51312241	0.51312241	0.51312241	0.51317757	0.51317757	0.51322245	0.50545498	0.50962446	0.52814404
5BA225405_1	0.5	0.51312241	0.51312241	0.51312241	0.51317757	0.51090715	0.51063683	0.51017131	0.5113229	0.52392132
5BA225408_1	0.49382911	0.51312241	0.51312241	0.51312241	0.51317757	0.51090715	0.51542885	0.52819128	0.50962446	0.61337944
5BA225407_1	0.51312241	0.51312241	0.51312241	0.51312241	0.51317757	0.51317757	0.51322245	0.50545498	0.50962446	0.52814404
62484_1	0.51312241	0.51312241	0.51312241	0.51134185	0.51312241	0.51134185	0.51134185	0.51134185	0.51134185	0.51312241
62486_1	0.51312241	0.51312241	0.51312241	0.51312241	0.51312241	0.51312241	0.51312241	0.51312241	0.51134185	0.51312241

Figura 4.2: SID: Resultados de la CT de todos los transformadores Fuente: Autor.

En la figura 4.3, se muestra un gráfico de la "Condición de Trabajo" (CT) en función de los años de servicio desde 1995 hasta 2021, una curva para cada uno de los transformadores de potencia, estos resultados son a partir de la aplicación del modelo matemática de lógica difusa del SID.




Figura 4.3: SID: Gráfico de CT desde 1995 hasta 2021, para todos los transformadores Fuente: Autor.

#### 4.2.2. Problema de entrenamiento y la predicción con modelos de Aprendizaje Automático

Para resolver el problema de entrenamiento y la predicción con modelos de Aprendizaje Automático detallado en el capítulo 3, se ha planteado N alternativas para de realizar el proceso de entrenamiento y lograr una regresión cuya



predicción objetivo es un determinado valor de la "Condición de Trabajo" (CT) que debe tener cada Transformador de Potencia. Estos modelos son:

- Modelo 1. Regresión con Árboles de decisión: Fine Tree.
- Modelo 2. Regresión SVM: Linear [Support Vector Machine \(SVM\)](#).
- Modelo 3. Regresión PG: Rational Quadratic [Gaussian Process \(GPR\)](#).
- Modelo 4. Regresión con Bosque Aleatorio: Boosted Trees.
- Modelo 5. Regresión con Red Neuronal: Narrow Neural Network.
- Modelo 6. Regresión Lineal: Linear.

En la figura 4.4 se presenta un gráfico de la respuesta de valores CT la –condición– del transformador 5BA225405 de los datos de Entrenamiento (color AZUL) y la respuesta de valores CT del modelo 1. Fine Tree, entrenado (color NARANJA), ambos en función de las mediciones en cada año desde 1995 hasta el 2021.




Figura 4.4: Transformador 5BA225405. RESPUESTAS: Modelo 1. Fuente: Autor.

En la figura 4.5 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 1. Fine Tree validado con una fracción de los datos de entrenamiento en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen la fracción de datos de entrenamiento. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad.

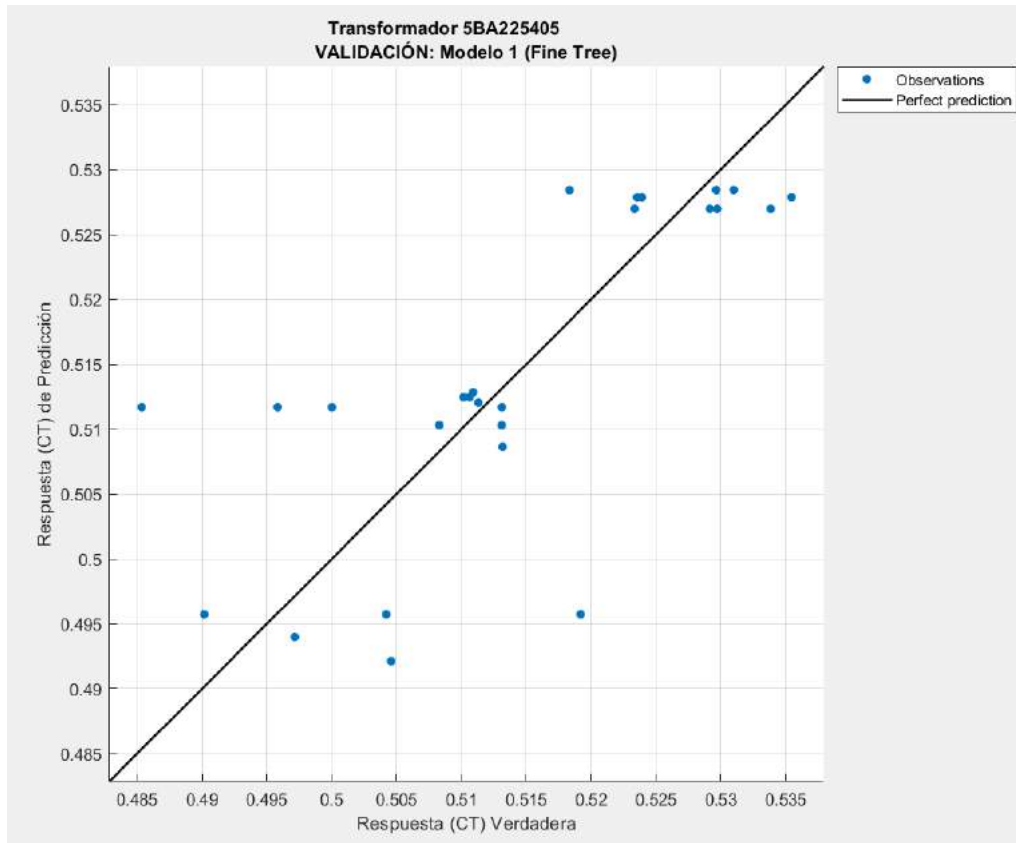


Figura 4.5: Transformador 5BA225405. VALIDACIÓN: Modelo 1. Fuente: Autor.

En la figura 4.6 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 1. Fine Tree probado con los datos de PRUEBA en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen los datos de PRUEBA. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad. Esta es la predicción del transformador de potencia 5BA225405.

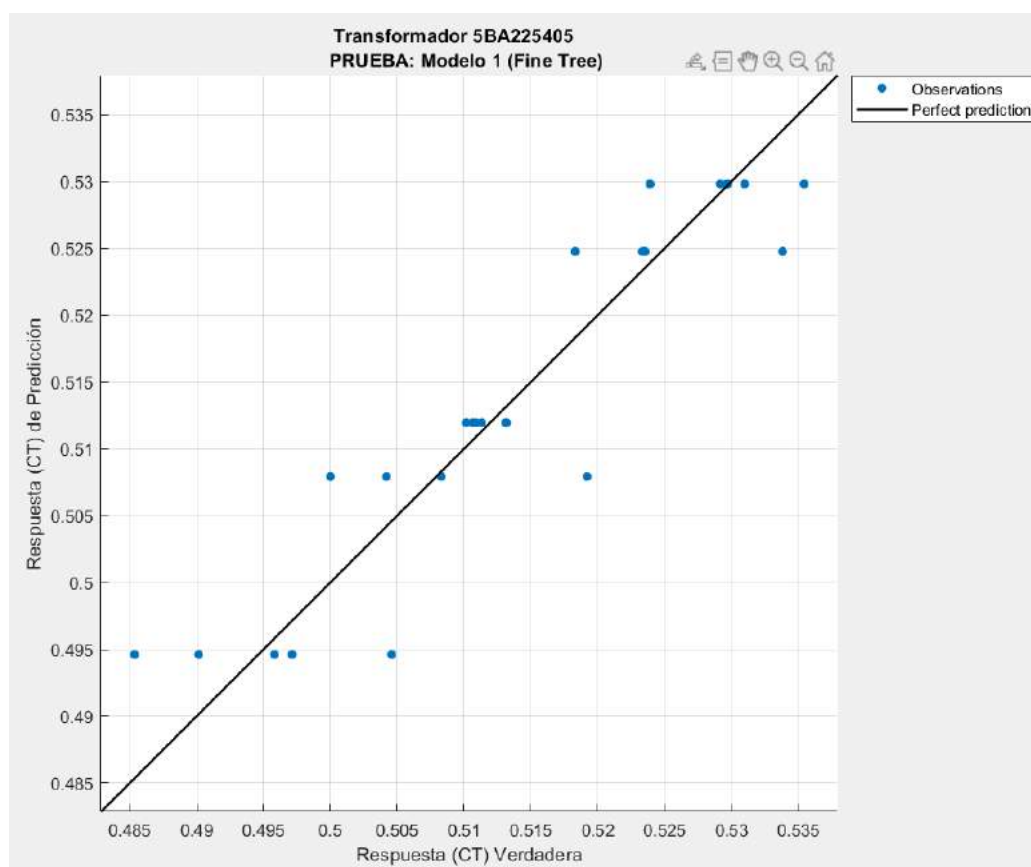


Figura 4.6: Transformador 5BA225405. PRUEBA: Modelo 1. Fuente: Autor.

En la figura 4.7 se presenta un gráfico de la respuesta de valores CT la – condición– del transformador 5BA225405 de los datos de Entrenamiento (color AZUL) y la respuesta de valores CT del modelo 2. Linear SVM, entrenado (color NARANJA), ambos en función de las mediciones en cada año desde 1995 hasta el 2021.

Para interpretar la exactitud y precisión a partir del gráfico, se debe observar la escala vertical de la variable Respuesta (CT), en este caso la escala tiene divisiones de 0.005. La primera década las mediciones y predicciones presentan valores aproximadamente constantes, en la segunda década las mediciones y las predicciones toman una forma de zigzag ambas se aproximan, en el tercer segmento no se ve un patrón y se visualiza una dispersión mayor.




Figura 4.7: Transformador 5BA225405. RESPUESTAS: Modelo 2. Fuente: Autor.

En la figura 4.8 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 2. Linear SVM validado con una fracción de los datos de entrenamiento en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen la fracción de datos de entrenamiento. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad.

Para interpretar la exactitud y precisión a partir del gráfico, se debe observar la escala vertical de la variable Respuesta (CT) de Predicción respecto a la escala horizontal de la variable Respuesta (CT) Verdadera, en este caso ambas escalas tienen divisiones de 0.005. Cada punto (color AZUL) tiene una distancia vertical respecto a la línea (color NEGRO) que representa la función Identidad, dicha distancia representa el *–error verdadero–*, es decir, negativo si el modelo coloca al punto sobre la línea, y positivo si el modelo lo coloca debajo de la línea. Esto es, si se considera error verdadero como la diferencia del Valor Verdadero menos el Valor Predicho.

En la figura 4.8 se interpreta que la VALIDACIÓN del modelo tiene una precisión respecto a los datos medidos de 4 sobre 27, tomando en cuenta los puntos que están sobre la línea de la función identidad o que se encuentran a una gran cercanía.




Figura 4.8: Transformador 5BA225405. VALIDACIÓN: Modelo 2. Fuente: Autor.

En la figura 4.9 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 2. Linear SVM probado con los datos de PRUEBA en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen los datos de PRUEBA. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad. Esta es la predicción del transformador de potencia 5BA225405.

En la figura 4.9 se interpreta que la PRUEBA del modelo tiene una precisión respecto a los datos medidos de 4 sobre 27, tomando en cuenta los puntos que están sobre la línea de la función identidad o que se encuentran a una gran cercanía, de la gráfica se visualiza menos dispersión que la –validación–.




Figura 4.9: Transformador 5BA225405. PRUEBA: Modelo 2. Fuente: Autor.

En la figura 4.10 se presenta un gráfico de la respuesta de valores CT la – condición– del transformador 5BA225405 de los datos de Entrenamiento (color AZUL) y la respuesta de valores CT del modelo 3. Rational Quadratic GPR, entrenado (color NARANJA), ambos en función de las mediciones en cada año desde 1995 hasta el 2021.

En la figura 4.10 se visualizan puntos de medición y de predicción, de lo cual se interpreta que para la primera década hay una predicción muy precisa, en la segunda década baja la precisión, pero el modelo se mantiene con una exactitud aceptable, pues el modelo sigue la misma forma que poseen los datos medidos, con muy pocas excepciones.

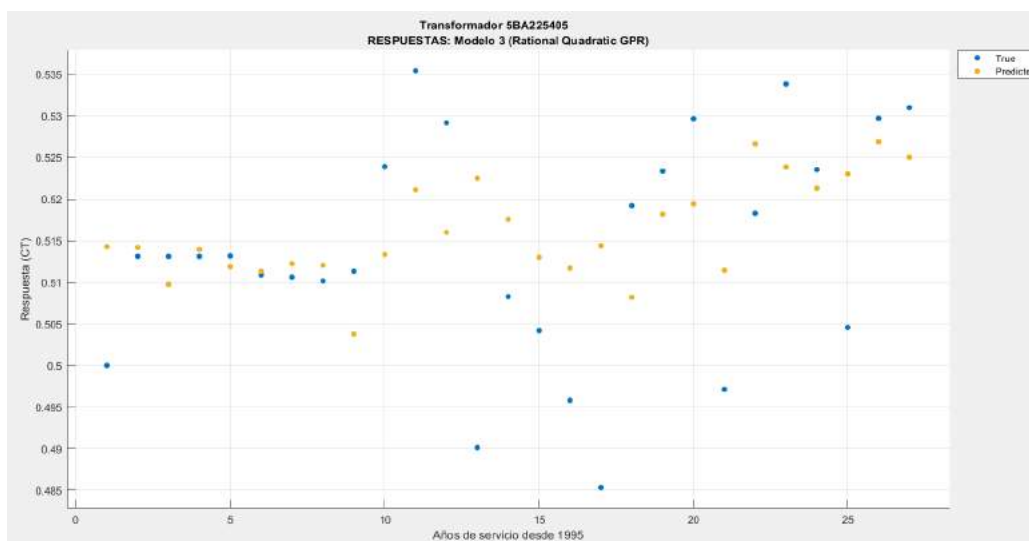


Figura 4.10: Transformador 5BA225405. RESPUESTAS: Modelo 3. Fuente: Autor.

En la figura 4.11 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 3. Rational Quadratic GPR validado con una fracción de los datos de entrenamiento en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen la fracción de datos de entrenamiento. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad.

En la figura 4.11 se interpreta que la VALIDACIÓN del modelo tiene una precisión respecto a los datos medidos de 6 sobre 27, tomando en cuenta los puntos que están sobre la línea de la función identidad o que se encuentran a una gran cercanía. Se visualiza la misma proporción de puntos bajo la línea y sobre la línea y la dispersión es aceptable considerando la escala de los datos, esto garantiza un –error cuadrático medio– muy bajo que es uno de los indicadores de evaluación utilizado en este proyecto.

En la figura 4.11 se visualiza que la VALIDACIÓN del modelo presenta una dispersión aceptable pero no ideal, por lo tanto es uno de los modelos que ha sido considerado.

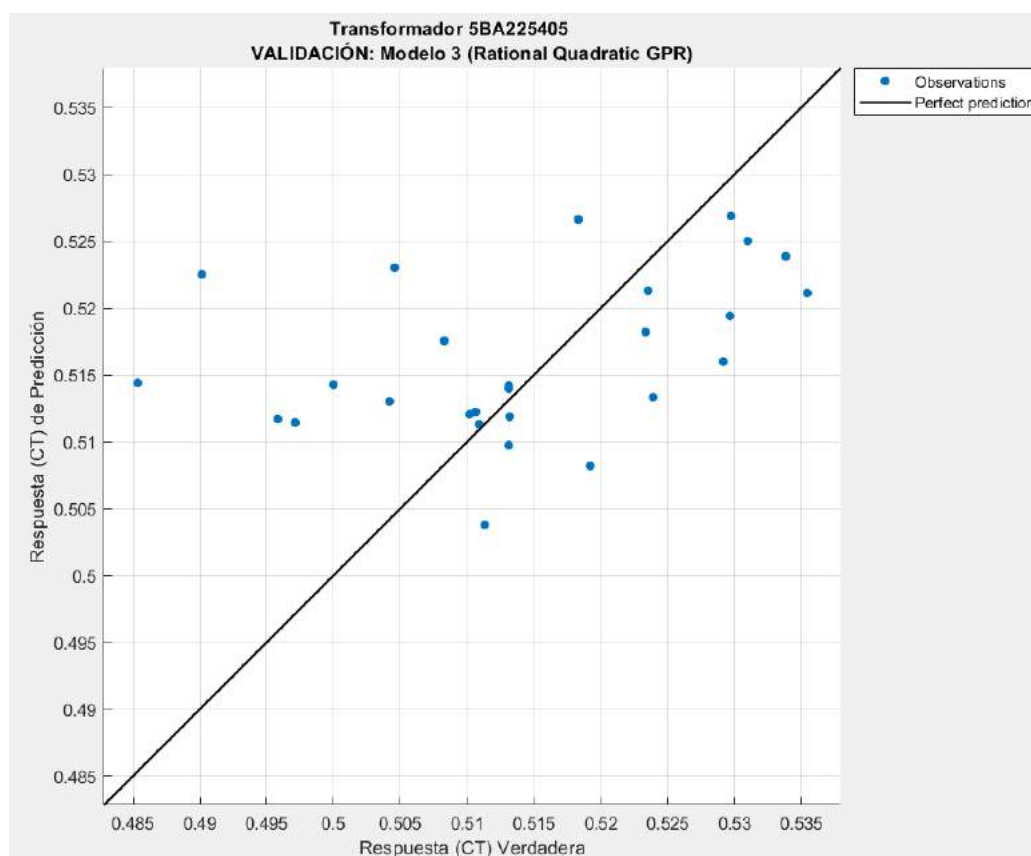


Figura 4.11: Transformador 5BA225405. VALIDACIÓN: Modelo 3. Fuente: Autor.

En la figura 4.12 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 3. Rational Quadratic GPR probado con los datos de PRUEBA en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen los datos de PRUEBA. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad. Esta es la predicción del transformador de potencia 5BA225405.

En la figura 4.12 se visualiza que la PRUEBA del modelo presenta una dispersión muy aceptable, mejor que la –validación– pero no ideal, por lo tanto es uno de los modelos que ha sido considerado. Se observan 8 de 27 puntos muy cercanos a la función Identidad.



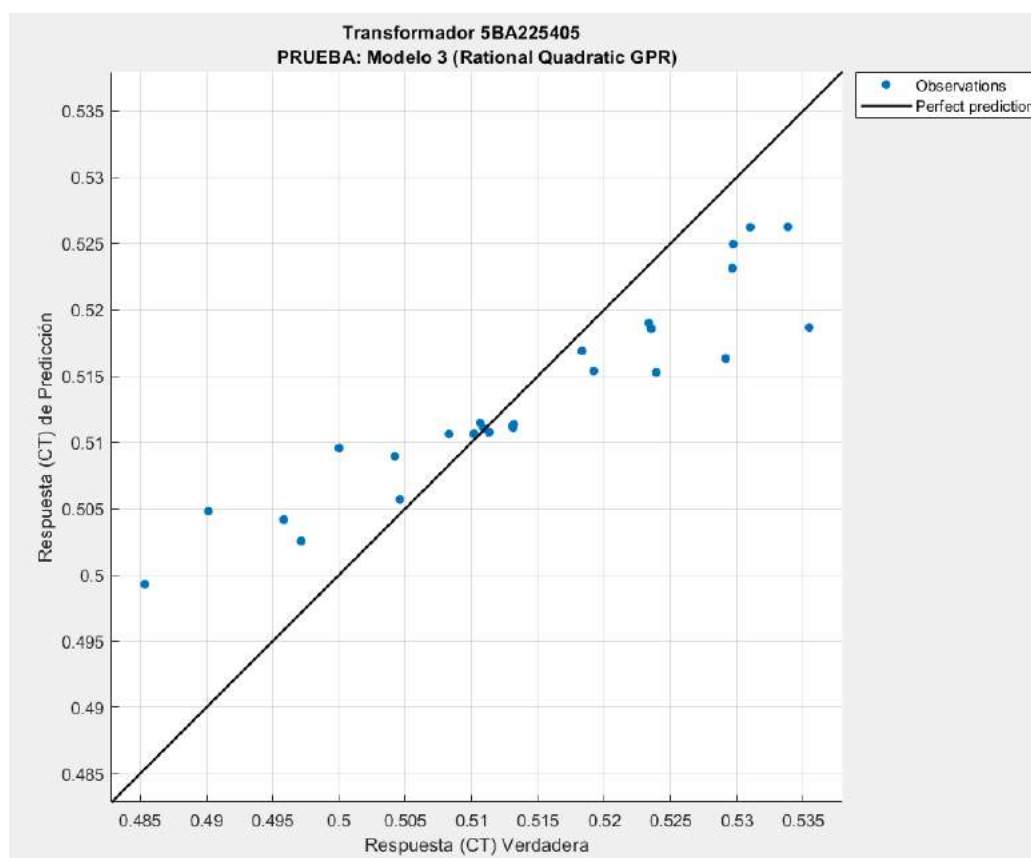


Figura 4.12: Transformador 5BA225405. PRUEBA: Modelo 3. Fuente: Autor.

En la figura 4.13 se presenta un gráfico de la respuesta de valores CT la – condición– del transformador 5BA225405 de los datos de Entrenamiento (color AZUL) y la respuesta de valores CT del modelo 4. Boosted Trees, entrenado (color NARANJA), ambos en función de las mediciones en cada año desde 1995 hasta el 2021.

En la figura 4.13 se visualizan puntos de medición y de predicción, de lo cual se interpreta que para la primera década hay una predicción imprecisa pero con un buen grado de exactitud, en la segunda década y en el resto del tiempo, baja exactitud y precisión, el modelo no sigue la misma forma que poseen los datos medidos.




Figura 4.13: Transformador 5BA225405. RESPUESTAS: Modelo 4. Fuente: Autor.

En la figura 4.14 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 4. Boosted Trees validado con una fracción de los datos de entrenamiento en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen la fracción de datos de entrenamiento. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad.

En la figura 4.14 se interpreta que la VALIDACIÓN del modelo tiene una precisión respecto a los datos medidos de 2 sobre 27, tomando en cuenta los puntos que están cercanos a la línea de la función identidad. Se visualiza que casi todos las predicciones están bajo la línea y tiene una dispersión alta considerando la escala de los datos, esto no garantiza un –error cuadrático medio– bajo, que es uno de los indicadores de evaluación utilizado en este proyecto.

En la figura 4.14 se visualiza que la VALIDACIÓN del modelo presenta alta dispersión, con valores que hacen suponer que el modelo tiene poca exactitud y una escasa precisión.

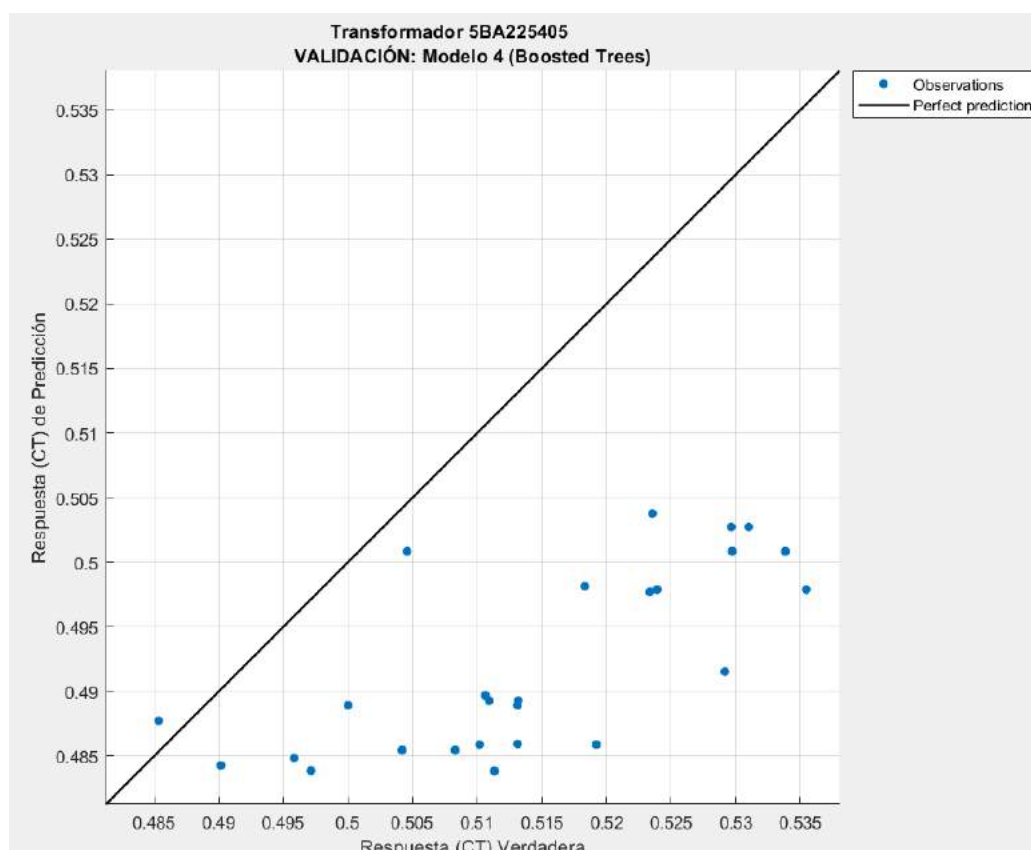


Figura 4.14: Transformador 5BA225405. VALIDACIÓN: Modelo 4. Fuente: Autor.

En la figura 4.15 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 4. Boosted Trees probado con los datos de PRUEBA en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen los datos de PRUEBA. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad. Esta es la predicción del transformador de potencia 5BA225405.

En la figura 4.15 se visualiza que la PRUEBA del modelo presenta una dispersión aceptable, mejor que la –validación– pero no ideal, por lo tanto es uno de los modelos que ha sido considerado. Se observa que no tiene mucha exactitud pero si un buen grado de precisión, pues los puntos del modelo siguen a la función Identidad.




Figura 4.15: Transformador 5BA225405. PRUEBA: Modelo 4. Fuente: Autor.

En la figura 4.16 se presenta un gráfico de la respuesta de valores CT la – condición– del transformador 5BA225405 de los datos de Entrenamiento (color AZUL) y la respuesta de valores CT del modelo 5. Narrow Neural Network, entrenado (color NARANJA), ambos en función de las mediciones en cada año desde 1995 hasta el 2021.

Para interpretar la exactitud y precisión a partir del gráfico, se debe observar la escala vertical de la variable Respuesta (CT), en este caso la escala tiene divisiones de 0.1, lo que visualmente no es una garantía, por ser una magnitud muy grande. Las mediciones y predicciones presentan valores muy diferentes, se puede afirmar escasa exactitud y muy baja precisión del modelo.




Figura 4.16: Transformador 5BA225405. RESPUESTAS: Modelo 5. Fuente: Autor.

En la figura 4.17 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 5. Narrow Neural Network validado con una fracción de los datos de entrenamiento en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen la fracción de datos de entrenamiento. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad.

Para interpretar la exactitud y precisión a partir del gráfico, se debe observar la escala vertical de la variable Respuesta (CT) de Predicción respecto a la escala horizontal de la variable Respuesta (CT) Verdadera, en este caso ambas escalas tienen divisiones de 0.1, lo que manifiesta baja exactitud para la VALIDACIÓN de los datos de Entrenamiento del modelo. Cada punto (color AZUL) tiene una distancia vertical respecto a la línea (color NEGRO) que representa la función Identidad, dicha distancia representa el –error verdadero–. Aunque el modelo no es exacto, 9 de 27 observaciones o predicciones se encuentran cerca o sobre la función Identidad.

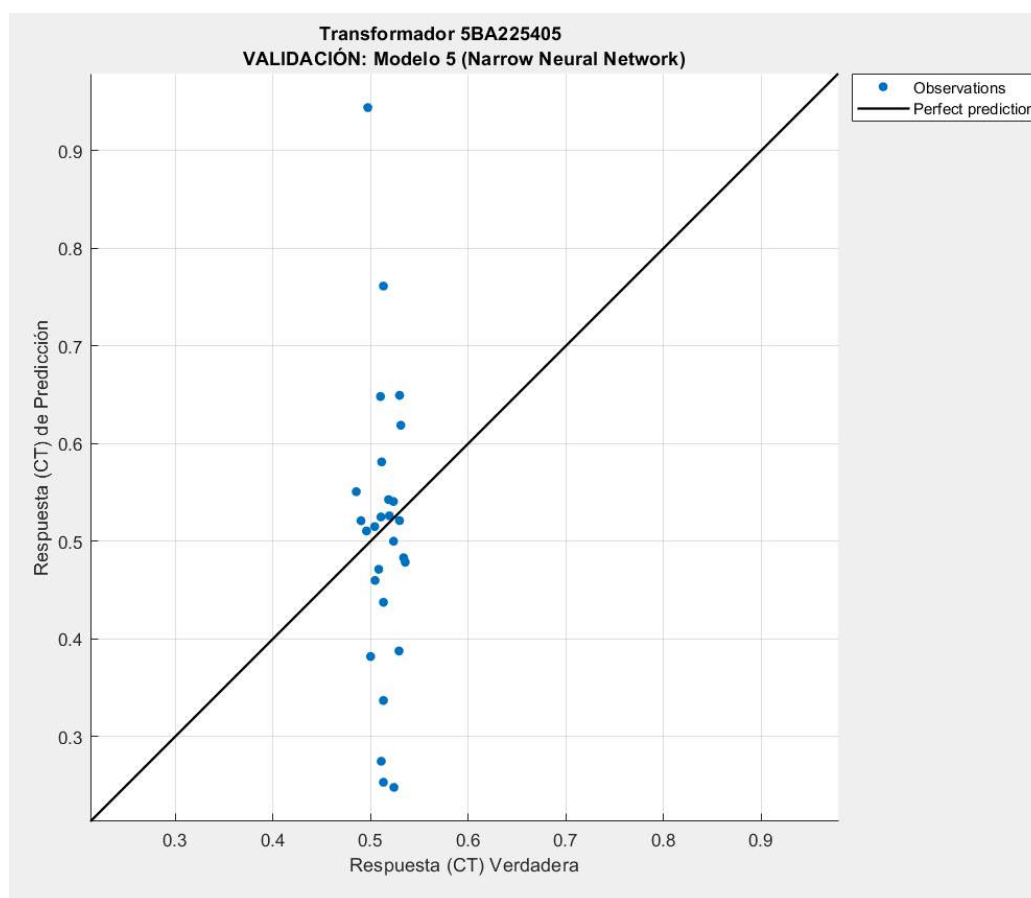


Figura 4.17: Transformador 5BA225405. VALIDACIÓN: Modelo 5. Fuente Autor.

En la figura 4.18 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 5. Narrow Neural Network probado con los datos de PRUEBA en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen los datos de PRUEBA. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad. Esta es la predicción del transformador de potencia 5BA225405.

Sobre la exactitud y precisión a partir del gráfico, se debe observar la escala vertical de la variable Respuesta (CT) de Predicción respecto a la escala horizontal de la variable Respuesta (CT) Verdadera, ambas escalas tienen divisiones de 0.01, esto es exactitud media para los de datos PRUEBA del modelo.

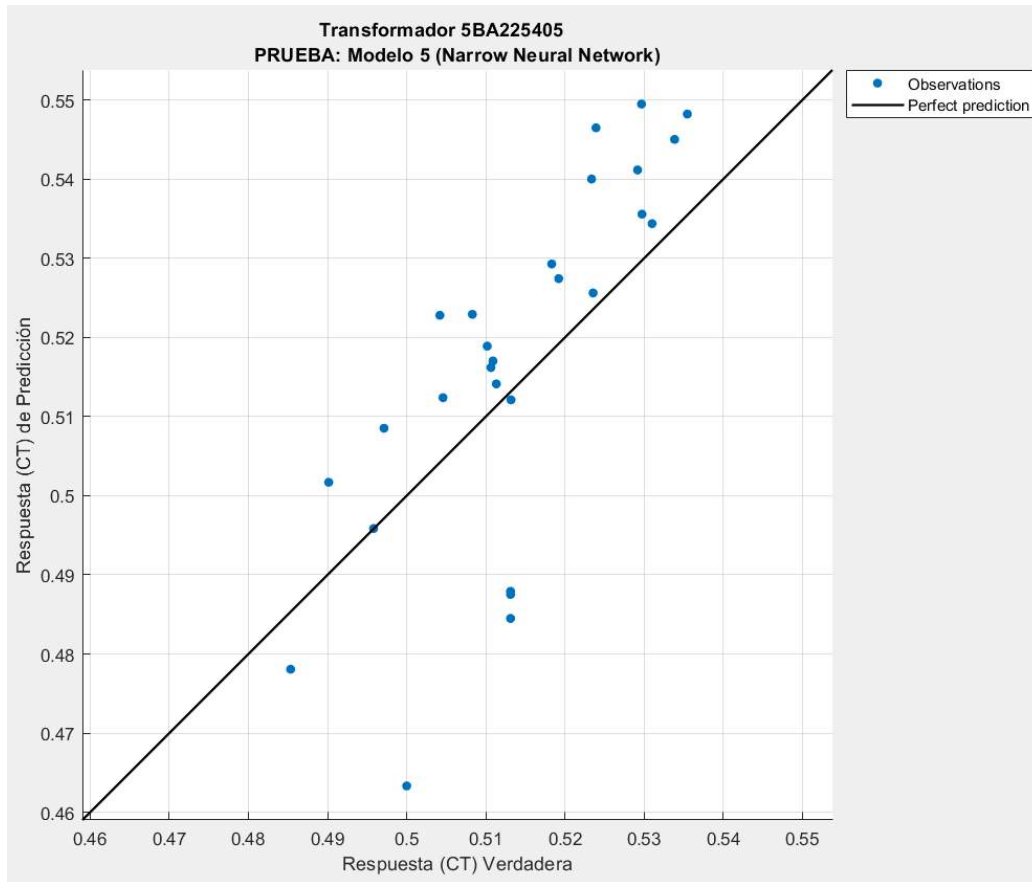


Figura 4.18: Transformador 5BA225405. PRUEBA: Modelo 5. Fuente: Autor.

En la figura 4.19 se presenta un gráfico de la respuesta de valores CT la –condición– del transformador 5BA225405 de los datos de Entrenamiento (color AZUL) y la respuesta de valores CT del modelo 6. Linear, entrenado (color NARANJA), ambos en función de las mediciones en cada año desde 1995 hasta el 2021. Para interpretar la exactitud y precisión a partir del gráfico, se debe observar la escala vertical de la variable Respuesta (CT), en este caso la escala tiene divisiones de 0.02, lo que visualmente representa una aproximación aceptable. Las mediciones y predicciones presentan valores diferentes, se puede afirmar escasa exactitud y baja precisión del modelo. En el modelo se observa un porción de 15 sobre 27 datos medidos una predicción muy cercana, pues se visualizan más puntos predichos cercanos a los datos medidos.

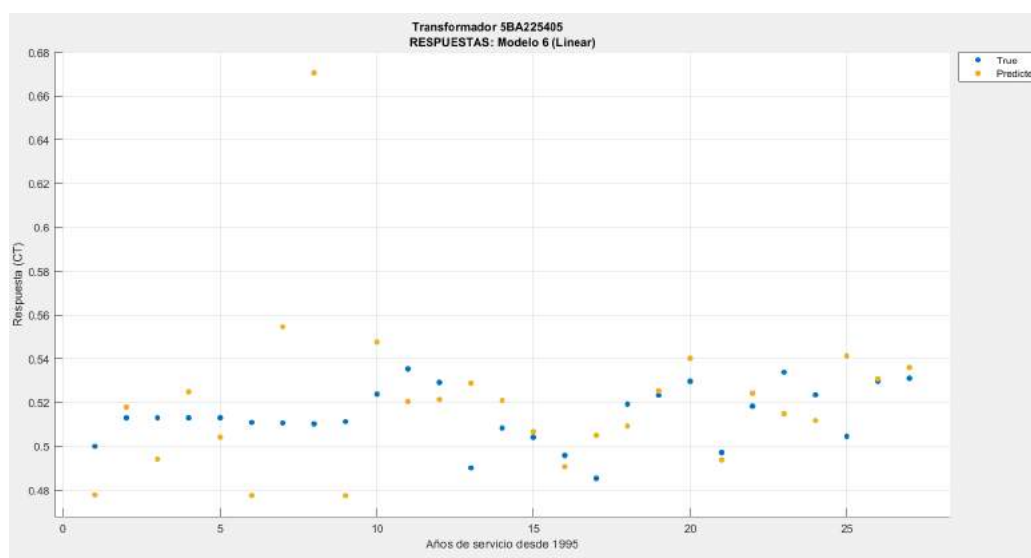


Figura 4.19: Transformador 5BA225405. RESPUESTAS: Modelo 6. Fuente: Autor.

En la figura 4.20 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 6. Linear validado con una fracción de los datos de entrenamiento en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen la fracción de datos de entrenamiento. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad.

Para interpretar la exactitud y precisión a partir del gráfico, se debe observar la escala vertical de la variable Respuesta (CT) de Predicción respecto a la escala horizontal de la variable Respuesta (CT) Verdadera, en este caso ambas escalas tienen divisiones de 0.02, lo que manifiesta aceptable exactitud para la VALIDACIÓN de los datos de Entrenamiento del modelo. Cada punto (color AZUL) tiene una distancia vertical respecto a la línea (color NEGRO) que representa la función Identidad, dicha distancia representa el –error verdadero–. Aunque el modelo no es muy preciso, 8 de 27 observaciones o predicciones se encuentran cerca o sobre la función Identidad, y el resto de puntos presentan mayor dispersión respecto a la función Identidad.

En la figura 4.20 se visualiza una predicción que está muy lejana del valor observado o medido, lo que incrementa el error del modelo y debería ignorarse.






Figura 4.20: Transformador 5BA225405. VALIDACIÓN: Modelo 6. Fuente: Autor.

En la figura 4.21 se presenta un gráfico que relaciona la Respuesta (CT) de predicción del modelo 6. Linear probado con los datos de PRUEBA en función a la Respuesta (CT) Verdadera, llamada así porque se refiere a la que definen los datos de PRUEBA. Observe la escala de los ejes y la distribución de los puntos a lo largo de la función Identidad. Esta es la predicción del transformador de potencia 5BA225405.

Sobre la exactitud y precisión a partir del gráfico, se debe observar la escala vertical de la variable Respuesta (CT) de Predicción respecto a la escala horizontal de la variable Respuesta (CT) Verdadera, ambas escalas tienen divisiones de 0.02, esto representa una aceptable exactitud para los datos de PRUEBA del modelo, con baja precisión ya que no cuentan puntos cercanos a la identidad.




Figura 4.21: Transformador 5BA225405. PRUEBA: Modelo 6. Fuente: Autor.

En la figura 4.21 se visualizan los resultados del modelo 6, Regresión Lineal, con los datos de PRUEBA para realizar la predicción y se muestra similar al gráfico de VALIDACIÓN, pero con poca exactitud y baja precisión.

En la figura 4.22 se presenta una matriz que corresponden a los resultados de la evaluación de todos los modelos de Aprendizaje Automático realizados al transformador de potencia 5BA225405. Esta evaluación se la realiza con los indicadores **RMSE**, **Coeficiente de determinación  $R^2$  (R-Squared)**, **Mean squared error (MSE)** y **Mean Absolute Error (MAE)**, observe que hay indicadores para el modelo evaluado con los datos de VALIDACIÓN y también para el modelo evaluado con los datos de PRUEBA.

TRANSFORMADOR	NUM. MOD	MODELO	TIPO RESULTADO	RMSE	R-Squared	MSE	MAE	VELOCIDAD PREDICCIÓN	TIEMPO ENTRENAMIENTO sec
5BA225405	1	Fine Tree	Training	0.0090812	0.6	8.25E-05	0.0063425	~2100 obs/sec	0.37504
5BA225405	1	Fine Tree	Test	0.0048121	0.87	2.32E-05	0.0034088		
5BA225405	2	Linear SVM	Training	0.011387	0.37	0.00012967	0.0091528	~1900 obs/sec	0.45305
5BA225405	2	Linear SVM	Test	0.0083879	0.59	7.04E-05	0.0061274		
5BA225405	3	Rational Quadratic GPR	Training	0.012316	0.26	0.00015169	0.0094186	~2000 obs/sec	0.6294
5BA225405	3	Rational Quadratic GPR	Test	0.0071318	0.7	5.09E-05	0.005419		
5BA225405	4	Boosted Trees	Training	0.024042	-1.8	0.00057803	0.022227	~640 obs/sec	1.2625
5BA225405	4	Boosted Trees	Test	0.022288	-1.88	0.00049674	0.02179		
5BA225405	5	Narrow Neural Network	Training	0.31341	-481.03	0.098224	0.19825	~500 obs/sec	2.1183
5BA225405	5	Narrow Neural Network	Test	0.020378	-1.41	0.00041525	0.016617		
5BA225405	6	Linear	Training	0.036551	-6.06	0.001336	0.021063	~1500 obs/sec	0.36842
5BA225405	6	Linear	Test	0.057531	-18.2	0.0033098	0.054213		

Figura 4.22: Transformador 5BA225405. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor.

En la figura 4.23 se presenta una matriz que corresponden a los resultados de la evaluación de todos los modelos de Aprendizaje Automático realizados al transformador de potencia 5BA225406. Esta evaluación se la realiza con los indicadores RMSE, R-Squared, MSE y MAE, observe que hay indicadores para el modelo evaluado con los datos de VALIDACIÓN y también para el modelo evaluado con los datos de PRUEBA.

TRANSFORMADOR	NUM. MOD	MODELO	TIPO RESULTADO	RMSE	R-Squared	MSE	MAE	VELOCIDAD PREDICCIÓN	TIEMPO ENTRENAMIENTO sec
5BA225406	1	Fine Tree	Training	0.017962	0.02	0.00032262	0.013093	~2200 obs/sec	0.35955
5BA225406	1	Fine Tree	Test	0.0091293	0.73	8.33E-05	0.0066406		
5BA225406	2	Linear SVM	Training	0.01311	0.47	0.00017188	0.0090724	~2300 obs/sec	0.37917
5BA225406	2	Linear SVM	Test	0.010824	0.62	0.00011717	0.0075857		
5BA225406	3	Rational Quadratic GPR	Training	0.013394	0.45	0.00017939	0.010579	~410 obs/sec	2.5825
5BA225406	3	Rational Quadratic GPR	Test	0.0069137	0.85	4.78E-05	0.0050838		
5BA225406	4	Boosted Trees	Training	0.028088	-1.41	0.00078895	0.025467	~140 obs/sec	5.725
5BA225406	4	Boosted Trees	Test	0.02297	-0.7	0.0005276	0.021873		
5BA225406	5	Narrow Neural Network	Training	0.20817	-131.14	0.043334	0.15254	~1900 obs/sec	0.57645
5BA225406	5	Narrow Neural Network	Test	0.079861	-19.52	0.0063777	0.069365		
5BA225406	6	Linear	Training	0.02556	-0.99	0.00065329	0.018889	~630 obs/sec	2.0148
5BA225406	6	Linear	Test	0.020274	-0.32	0.00041105	0.018397		

Figura 4.23: Transformador 5BA225406. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor.

En la figura 4.24 se presenta una matriz que corresponden a los resultados de la evaluación de todos los modelos de Aprendizaje Automático realizados al transformador de potencia 5BA225407. Esta evaluación se la realiza con los indicadores RMSE, R-Squared, MSE y MAE, observe que hay indicadores para el modelo evaluado con los datos de VALIDACIÓN y también para el modelo evaluado con los datos de PRUEBA.

TRANSFORMADOR	NUM. MOD	MODELO	TIPO RESULTADO	RMSE	R-Squared	MSE	MAE	VELOCIDAD PREDICCIÓN	TIEMPO ENTRENAMIENTO sec
5BA225407	1	Fine Tree	Training	0.019283	-0.11	0.00037184	0.012494	~2400 obs/sec	0.35689
5BA225407	1	Fine Tree	Test	0.012998	0.46	0.00016896	0.0095604		
5BA225407	2	Linear SVM	Training	0.014159	0.4	0.00020047	0.0096196	~410 obs/sec	1.7111
5BA225407	2	Linear SVM	Test	0.01489	0.29	0.00022173	0.011572		
5BA225407	3	Rational Quadratic GPR	Training	0.011078	0.63	0.00012273	0.0071943	~380 obs/sec	2.154
5BA225407	3	Rational Quadratic GPR	Test	0.0062174	0.88	3.87E-05	0.0049373		
5BA225407	4	Boosted Trees	Training	0.025607	-0.96	0.00065573	0.023772	~140 obs/sec	5.6725
5BA225407	4	Boosted Trees	Test	0.026307	-1.22	0.00069208	0.024986		
5BA225407	5	Narrow Neural Network	Training	0.15201	-68.14	0.023108	0.094616	~430 obs/sec	2.376
5BA225407	5	Narrow Neural Network	Test	0.040762	-4.34	0.0016615	0.032055		
5BA225407	6	Linear	Training	0.054506	-8.4	0.0029709	0.027403	~280 obs/sec	1.5267
5BA225407	6	Linear	Test	0.0052294	0.91	2.73E-05	0.0038929		

Figura 4.24: Transformador 5BA225407. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor.

En la figura 4.25 se presenta una matriz que corresponden a los resultados de la evaluación de todos los modelos de Aprendizaje Automático realizados al transformador de potencia 5BA225408. Esta evaluación se la realiza con los indicadores RMSE, R-Squared, MSE y MAE, observe que hay indicadores para el modelo evaluado con los datos de VALIDACIÓN y también para el modelo evaluado con los datos de PRUEBA.

TRANSFORMADOR	NUM. MOD	MODELO	TIPO RESULTADO	RMSE	R-Squared	MSE	MAE	VELOCIDAD PREDICCIÓN	TIEMPO ENTRENAMIENTO sec
5BA225408	1	Fine Tree	Training	0.028468	-0.05	0.0008104	0.021212	~370 obs/sec	1.5049
5BA225408	1	Fine Tree	Test	0.013966	0.74	0.00019505	0.0088796		
5BA225408	2	Linear SVM	Training	0.0078629	0.92	6.18E-05	0.005936	~360 obs/sec	1.7395
5BA225408	2	Linear SVM	Test	0.005732	0.96	3.29E-05	0.004555		
5BA225408	3	Rational Quadratic GPR	Training	0.021767	0.39	0.00047381	0.013339	~350 obs/sec	2.3945
5BA225408	3	Rational Quadratic GPR	Test	0.005197	0.96	2.70E-05	0.0046025		
5BA225408	4	Boosted Trees	Training	0.028256	-0.04	0.00079842	0.020547	~140 obs/sec	5.7847
5BA225408	4	Boosted Trees	Test	0.026025	0.1	0.00067732	0.021983		
5BA225408	5	Narrow Neural Network	Training	0.17957	-39.73	0.032247	0.12464	~1700 obs/sec	0.48135
5BA225408	5	Narrow Neural Network	Test	0.011789	0.82	0.00013898	0.008713		
5BA225408	6	Linear	Training	0.050328	-2.29	0.002533	0.020236	~270 obs/sec	1.774
5BA225408	6	Linear	Test	0.01329	0.76	0.00017663	0.012036		

Figura 4.25: Transformador 5BA225408. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor.

En la figura 4.26 se presenta una matriz que corresponden a los resultados de la evaluación de todos los modelos de Aprendizaje Automático realizados al transformador de potencia 62484. Esta evaluación se la realiza con los indicadores RMSE, R-Squared, MSE y MAE, observe que hay indicadores para el modelo evaluado con los datos de VALIDACIÓN y también para el modelo evaluado con los datos de PRUEBA.

TRANSFORMADOR	NUM. MOD	MODELO	TIPO RESULTADO	RMSE	R-Squared	MSE	MAE	VELOCIDAD PREDICCIÓN	TIEMPO ENTRENAMIENTO sec
62484	1	Fine Tree	Training	0.021048	0.3	0.00044301	0.0081602	~1900 obs/sec	0.36881
62484	1	Fine Tree	Test	0.016638	0.53	0.00027681	0.0064371		
62484	2	Linear SVM	Training	0.019149	0.42	0.0003667	0.0077551	~350 obs/sec	1.822
62484	2	Linear SVM	Test	0.016829	0.52	0.0002832	0.0068965		
62484	3	Rational Quadratic GPR	Training	0.014116	0.69	0.00019927	0.0067875	~440 obs/sec	2.4557
62484	3	Rational Quadratic GPR	Test	0.013861	0.68	0.00019211	0.012963		
62484	4	Boosted Trees	Training	0.030082	-0.43	0.00090493	0.028033	~120 obs/sec	6.3452
62484	4	Boosted Trees	Test	0.037226	-1.34	0.0013857	0.036281		
62484	5	Narrow Neural Network	Training	0.13676	-28.55	0.018702	0.096924	~340 obs/sec	4.6078
62484	5	Narrow Neural Network	Test	0.23231	-90.25	0.053969	0.16928		
62484	6	Linear	Training	0.024729	0.03	0.00061153	0.014159	~240 obs/sec	2.0664
62484	6	Linear	Test	0.06658	-6.49	0.0044329	0.062972		

Figura 4.26: Transformador 62484. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor.

En la figura 4.27 se presenta una matriz que corresponden a los resultados de la evaluación de todos los modelos de Aprendizaje Automático realizados al transformador de potencia 62486. Esta evaluación se la realiza con los indicadores RMSE, R-Squared, MSE y MAE, observe que hay indicadores para el modelo evaluado con los datos de VALIDACIÓN y también para el modelo evaluado con los datos de PRUEBA.

TRANSFORMADOR	NUM. MOD	MODELO	TIPO RESULTADO	RMSE	R-Squared	MSE	MAE	VELOCIDAD PREDICCIÓN	TIEMPO ENTRENAMIENTO sec
62486	1	Fine Tree	Training	0.022487	-0.37	0.00050566	0.014061	~410 obs/sec	1.5514
62486	1	Fine Tree	Test	0.014377	0.39	0.00020671	0.0057541		
62486	2	Linear SVM	Training	0.019458	-0.03	0.00037862	0.0086541	~1900 obs/sec	0.50137
62486	2	Linear SVM	Test	0.014642	0.37	0.0002144	0.0076352		
62486	3	Rational Quadratic GPR	Training	0.0091453	0.77	8.36E-05	0.0044602	~1800 obs/sec	0.62421
62486	3	Rational Quadratic GPR	Test	0.0018108	0.99	3.28E-06	0.0013352		
62486	4	Boosted Trees	Training	0.026852	-0.95	0.00072102	0.025128	~770 obs/sec	1.3083
62486	4	Boosted Trees	Test	0.025058	-0.85	0.00062788	0.024313		
62486	5	Narrow Neural Network	Training	0.073854	-13.77	0.0054543	0.050753	~2200 obs/sec	0.61246
62486	5	Narrow Neural Network	Test	0.077361	-16.67	0.0059848	0.06831		
62486	6	Linear	Training	0.020576	-0.15	0.00042338	0.013654	~1600 obs/sec	0.56059
62486	6	Linear	Test	0.0093128	0.74	8.67E-05	0.0082393		

Figura 4.27: Transformador 62486. Cuadro de resultados de Indicadores de todos los Modelos de Aprendizaje Automático. Fuente: Autor.

Se dice que un gráfico explica más que mil palabras o lo que se puede analizar con los datos en una tabla, es por ello que en la figura 4.28 se ilustra un gráfico de los resultados del indicador de evaluación RMSE en función a todos los transformadores de potencia analizados en esta investigación, y se han trazado 6 curvas correspondientes para cada uno de los modelos de Aprendizaje Automático.

Los valores del indicador de evaluación a utilizado los resultados con los datos de ENTRENAMIENTO para que el modelo aprenda y quede ajustado como valores predichos, con respecto a los valores observados o medidos de las pruebas eléctricas de los datos.

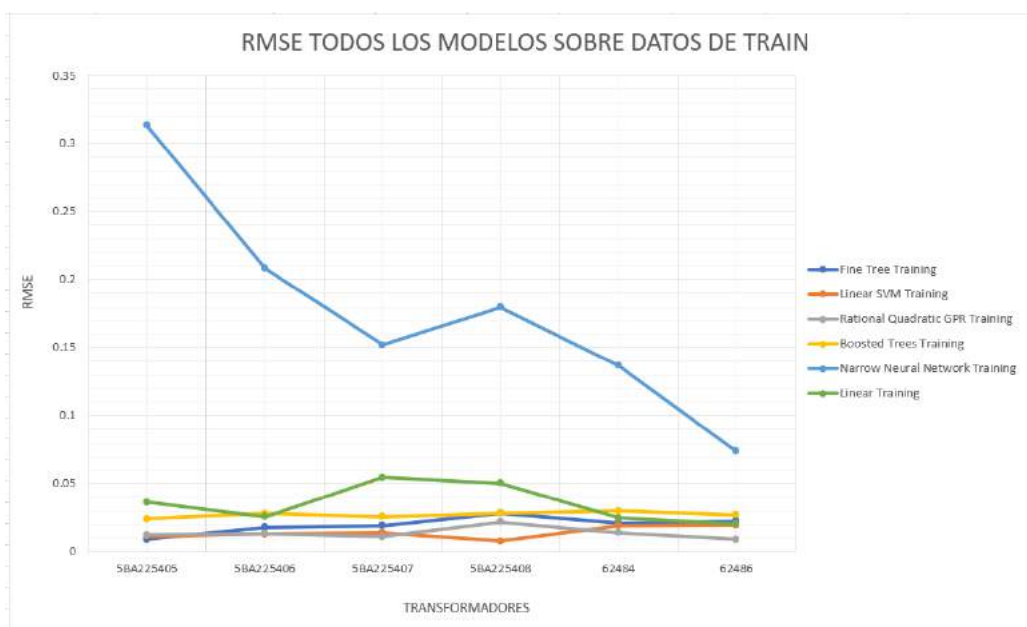


Figura 4.28: INDICADOR RMSE: Gráfico del RMSE respecto a cada Transformador sobre los datos de ENTRENAMIENTO para todos los Modelos de Aprendizaje Automático. Fuente: Autor.

Se dice que un gráfico explica más que mil palabras o lo que se puede analizar con los datos en una tabla, es por ello que en la figura 4.29 se ilustra un gráfico de los resultados del indicador de evaluación RMSE en función a todos los transformadores de potencia analizados en esta investigación, y se han trazado 6 curvas correspondientes para cada uno de los modelos de Aprendizaje Automático.

De la figura 4.28 y la figura 4.29 para la evaluación de los modelos con los datos de ENTRENAMIENTO y de PRUEBA respectivamente, se puede observar los mejores resultados con la regresión de Procesos Gaussianos (Rational Quadratic) y la regresión por Árboles de Decisión (Fine Tree).

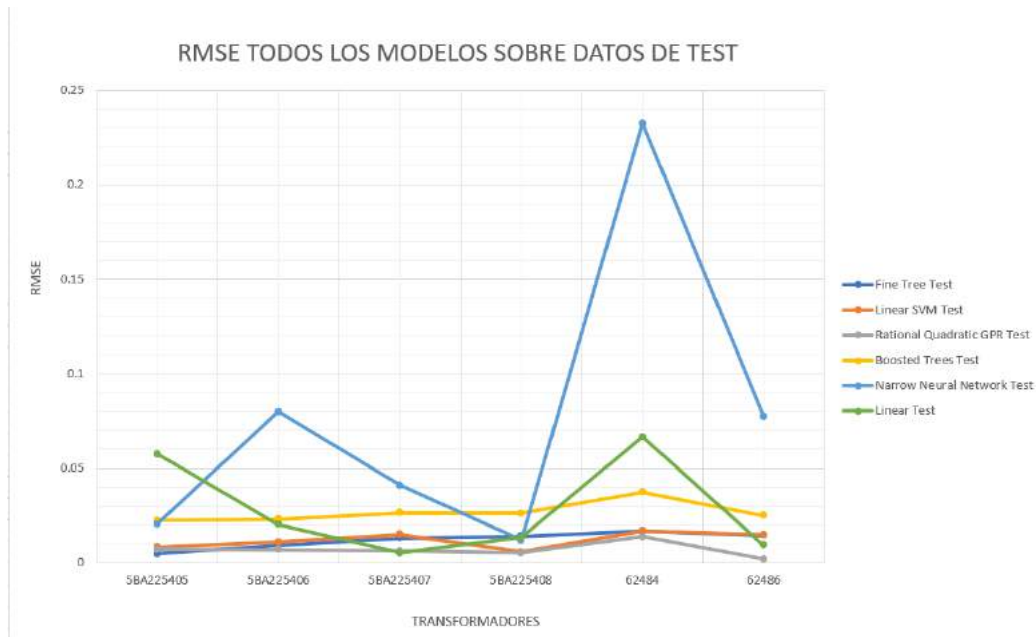


Figura 4.29: INDICADOR RMSE: Gráfico del RMSE respecto a cada Transformador sobre los datos de PRUEBA para todos los Modelos de Aprendizaje Automático. Fuente: Autor.

Se debe indicar que para obtener estos resultados fue necesario realizar muchas simulaciones y hacer varias modificaciones de los parámetros del modelo, afinar el modelo hasta alcanzar un nivel de indicador de evaluación satisfactorio es un trabajo lento y de mucha paciencia, así mismo estimar los valores de las funciones de membresía y las ponderaciones del sistemas de Inferencias requiere tener un alto grado de conocimiento del estado de los transformadores y de las pruebas eléctricas que se realiza. Una vez ya ajustado, entrenado y validado el modelo, el siguiente paso que es asignar la base de datos para realizar las predicciones requeridas es otro trabajo fino y coordinado con el personal técnico del Departamento de Mantenimiento de la subestación, pues es de su conocimiento el estimar valores futuros. De estos resultados se puede decir que los transformadores son robustos y los modelos de Regresión por Procesos Gaussianos y Arboles de Decisión son muy satisfactorios, así mismo el peor de todos los modelos es el Redes Neuronales Reducidas, debido a la escasa cantidad de datos que se cuenta para este modelo.

# Capítulo 5

## Conclusiones

- Esta investigación despierta e inicia una nueva tendencia de analizar los datos con técnicas que se vienen desarrollando en otros lugares, el modelamiento matemático es el alma escondida de estas herramientas pero más simple es comprender como utilizarla y como definirla en beneficio de mejorar un resultado, 27 años de datos correspondientes al elemento primario más importante de la subestación ha permitido elaborar una metodología que colabora en estimar la –condición– de cada uno de los transformadores de potencia. Con una antigüedad entre 32 y 41 años de servicio y mantenerse con una Condición de Trabajo entre 42% y 56% afirma el diseño robusto que tienen estos valiosos Transformadores de potencia, y que en los próximos 5 años pueden bajar 2.5% es un aporte que esta herramienta establece.
- A partir del método planteado y de los modelos de Aprendizaje Automático aplicados, analizados y comparados se concluye la efectividad del modelo lógico binario llamado Árboles de Decisión (Fine Tree) y el modelo probabilístico de Procesos Gaussianos (Rational Quadratic) y de bajo rendimiento que proporcionó el modelo funcional de red neuronal artificial reducida (Narrow Neural Network). Se debe indicar el delicado proceso iterativo que se debe realizar para alcanzar el afinamiento de cada uno de los modelos, aunque la cantidad de datos permite convergencias en poco tiempo (desde fracciones de segundo hasta los 2.12 segundos) la cantidad de repeticiones con diferentes parametrizaciones es lo que representa un trabajo laborioso hasta que el indicador de la evaluación del modelo de Aprendizaje Automático se establezca en un valor adecuado.



Si se expande este trabajo a otros equipos primarios de la misma subestación se pueden tener mejores resultados ya que las predicciones aplicadas solo a los Transformadores de Potencia limitan el resultado, el análisis de una predicción de todos los equipos primarios del patio 230kV estimará una probable falla que afecte más a un equipo que a otro. Mucho mejor si el proyecto se expande a la interconexión de las subestaciones de la zona pues no sólo se estaría analizando el árbol sino el bosque de la zona sur occidental.

- La inevitable actualización de tecnologías obliga a tener nuevos equipos que generan mediciones en línea y con mayor continuidad, por lo tanto, es mejor aprovechar esta tendencia y diseñar un sistema de almacenamiento, control y tratamiento de la información histórica, actual y futura. De esta manera se puede seguir analizando este tipo de estudios que pueden aprovechar todo este recurso que muy pronto sólo será digital y mejor aún con las tecnologías "Internet de las cosas" (IoT) pueden estar a nivel de todos y en cualquier lugar, tanto los datos como las predicciones.
- La subestación eléctrica cuenta con un nuevo transformador de potencia adquirido en 2013 su nombre en los registros de las pruebas AGD y AFQ es 1ZDB300000P842, el mismo que ha sido utilizado para comprobar valores de la –condición– obtenida partir del SID, en 9 años de operación no ha sido considerado para realizar las pruebas de generación de los modelos de Aprendizaje Automático por contar con muy pocos datos lo que puede presentar resultados no confiables.

# Capítulo 6

## Glosario

**2FAL** Los furanos son indicadores muy confiables de la degradación de la celulosa. El 2 Furfuraldehído es el compuesto más estable y de mayor cantidad de los 5 furanos formado a partir de la descomposición del papel por sobrecalentamiento general de la celulosa.

**CO<sub>2</sub>/CO** Mide la relación o tasa que tiene el Dióxido de Carbono respecto al Monóxido de Carbono y en el apartado D8 de la norma IEEE C57.104-2019 se detallan valores y acciones que se debe tomar.

**Acid** Es la cantidad de hidróxido de potasio (mg) que se requiere para neutralizar la acidez de un gramo del aceite aislante, se define en mg KOH/gr.

**AFQ** El análisis Físico Químico del aceite de los transformadores de potencia, es una de las pruebas más eficientes para determinar el desgaste de los componentes internos.

**AGD** Análisis de Gases Disueltos, es el nombre de la mejor técnica para diagnosticar fallas de los transformadores.

**AGE** Esta es una de las variables del conjunto difuso utilizado en el SID y se refiere al tiempo de operación que tiene el transformador de potencia en estudio.

**ANSI** Es una organización norteamericana que certifica normas desarrolladas para varios tipos de industrias y no reciben la influencia de intereses de un grupo o compañía.

- ASTM** American Society Testing Materials antes conocida como Sociedad Americana para Pruebas de Materiales, ahora es una organización mundial para el desarrollo y entrega de normas internacionales de modo voluntario.
- BDV** Breakdown Voltage es la prueba de rigidez dieléctrica del aceite, mide la capacidad que tiene el líquido aislante para soportar la tensión eléctrica (en kV) sin crear un arco.
- CBM** Este tipo de mantenimiento se fundamenta en la monitorización de las condiciones de estado o de operación de los diferentes elementos que tiene un activo, y de esta manera predecir el instante más idóneo para realizar el mantenimiento.
- CELEC** En la Corporación Eléctrica del Ecuador CELEC-EP TRANSELECTRIC Pascuales, se refiere al nombre completo que tiene la subestación eléctrica en estudio PASCUALES, EP se refiere a empresa pública y una subdivisión que se encarga de la transmisión de energía eléctrica es TRANSELECTRIC.
- CIGRE** Del francés, “Conseil International des Grands Réseaux Électriques”, es decir, “Consejo Internacional en Grandes Redes Eléctricas”, es una sociedad internacional no gubernamental que opera desde 1921, lidera aspectos económicos, técnicos, medioambientales y regulatorios de sistemas eléctricos de potencia.
- Color** Se refiere a la prueba que se aplica al aceite del transformador para reconocer su apariencia y el oscurecimiento que se producen en las descargas.
- CT** Se refiere a la –condición– que posee el transformador de potencia para la operación de funcionamiento o de trabajo.
- DGA** Es el resultado total de las magnitudes de cada una de las pruebas realizadas.
- EP** Equipos Primarios también denominados elementos primarios, en una subestación eléctrica existen una variedad de equipos, que se caracterizan según sea el tipo de la subestación, los que se clasifican en primarios y

secundarios, los primarios son todos aquellos que se conectan directamente a los circuitos de alta tensión.

- FEM** Es un método numérico para la aproximación de soluciones de ecuaciones diferenciales muy complejas utilizado en varios problemas de ingeniería y ciencias, basados en las geometrías, modelos y condiciones de los objetos de estudio.
- GPR** La regresión del proceso gaussiano (GPR) es un enfoque bayesiano no paramétrico de la regresión que se está usando en el área del aprendizaje automático. GPR tiene varios beneficios, funciona bien en pequeños conjuntos de datos y tiene la capacidad de proporcionar mediciones de incertidumbre en las predicciones.
- HI** Es un indicador de condición, es muy utilizado que combina varios resultados de pruebas eléctricas que se realizan al transformador, todo esto para identificar cuando debe atenderse con mayor prioridad.
- IEC** International Electrotechnical Commission es la organización mundial que se fundó en 1906, normaliza tecnologías eléctricas y electrónicas, y otras relacionadas.
- IEEE** Es un organismo profesional en los campos de ingeniería eléctrica y electrónica, que promueven la innovación tecnológica y la creación de estándares.
- IFT** Es una medida indirecta de la cantidad de compuestos polares en el aceite (en mN/m).
- MAE** Este indicador de aproximación es la medida del promedio de la diferencia absoluta entre el valor medido y el valor predicho.
- MATLAB** Es el programa principal de MathWorks, y se ha utilizado en este trabajo de investigación, posee muchas ventajas y se aplica en ciencias aplicadas e ingenierías.
- MRDA** Prueba eléctrica que se aplica al aceite de los transformadores de potencia y corresponde al Análisis de Gases Disueltos.

- MSE** El error medio cuadrático es un indicador de aproximación mide el promedio de las diferencias al cuadrado de un valor medido y un valor estimado.
- NETA** Es la asociación norteamericana de más alto nivel en la industria eléctrica, con la integración de la IEEE, una certificación NETA es comparable con una ISO para pruebas eléctricas.
- PE** Prueba Eléctrica realizadas en las subestaciones eléctricas se refieren a todos los procedimientos, ensayos, mediciones, diagnósticos y pruebas de funcionalidad que se deben realizar a los equipos primarios o secundarios, que informan las condiciones de trabajo de los mismos.
- R-Squared** Este indicador de aproximación es la porción de la varianza total de una variable de la regresión.
- RMSE** Root mean square error es la raíz del error cuadrático medio indica la diferencia entre 2 conjuntos de datos, compara un valor predicho y un valor observado o medido.
- SID** Sistemas de Inferencias Difusos se clasifican en la categoría de los sistemas expertos, corresponden al método basado en los conjuntos borrosos o no exactos y donde los datos guardan mucha incertidumbre y no hay posibilidad o es muy complejo de establecer relaciones lógicas o matemáticas entre las variables, por lo tanto se pondera la experiencia y subjetividad que posee el supervisor o experto.
- SNI** Sistema Nacional Interconectado, se refiere a todo el sistema conformado por los elementos de generación, transmisión y distribución de energía eléctrica en el Ecuador.
- SVM** Las máquinas de vector de soporte son los vectores que separan los márgenes máximos que definen hiperplanos para la separación de objetos en el espacio, representa una técnica empleada la clasificación o para la regresión en métodos de Aprendizaje Automático.
- TTR** La prueba eléctrica medición de la relación de transformación se realiza a los transformadores de potencia.

**Water** Se refiere a la cantidad de partículas de agua (en ppm) que hay en el aceite, si es considerable el contenido puede provocar burbujeo en caso de presión total de los gases exceda la temperatura ambiente del transformador.

**ZOSX** CELEC ha realizado una distribución geográfica de todo el SNI en donde la zona correspondiente a esta subestación es la Sur Occidental.

# Bibliografía

- [1] M. Statistics and M. L. Toolbox, “The mathworks,” *Inc., Natick, Massachusetts, United States.*[Google Scholar], 2019.
- [2] S. Raschka, *Python machine learning*. Packt publishing ltd, 2015.
- [3] M. Mathworks, “Fuzzy logic toolbox,” *User’s Guide, The Mathworks, Massachusetts*, p. 2014, 2014.
- [4] R. Santana, M. Betancourt, L. Rejon-Garcia, N. Rafael, C. Sosol, and R. Fernández, “Una propuesta para estimación de la condición de transformadores de potencia,” 12 2013.
- [5] R. A. Prasojo, Suwarno, and A. Abu-Siada, “Dealing with data uncertainty for transformer insulation system health index,” *IEEE Access*, vol. 9, pp. 74 703–74 712, 2021.
- [6] L. R. Alvarado Sigüenza, B. F. Zúñiga Santillán, and J. Layana Chancay, “Análisis de confiabilidad de la subestación pascuales vista desde los elementos primarios,” 2012.
- [7] R. Murugan and R. Raju, “Understanding the power transformer component failures for health index-based maintenance planning in electric utilities,” *Engineering Failure Analysis*, vol. 96, 10 2018.
- [8] A. Setayeshmehr, A. Akbari, H. Borsi, and E. Gockenbach, “A procedure for diagnosis and condition based maintenance for power transformers,” in *Conference Record of the 2004 IEEE International Symposium on Electrical Insulation*, 2004, pp. 504–507.
- [9] H. A. Aldhubaib and M. M. A. Salama, “A novel approach to investigate the effect of maintenance on the replacement time for transformers,” *IEEE Transactions on Power Delivery*, vol. 29, no. 4, pp. 1603–1612, 2014.

- [10] M. Duval, "Dissolved gas analysis: It can save your transformer," *IEEE Electrical Insulation Magazine*, vol. 5, no. 6, pp. 22–27, 1989.
- [11] B. K. Morocho Ochoa and K. J. Negrete Durazno, "Aplicación para el análisis de tendencias de las pruebas eléctricas en los equipos primarios en las subestaciones eléctricas." B.S. thesis, 2019.
- [12] M. R. Hussain and S. S. Refaat, "Dielectric behaviour of defects in power transformer insulation using finite element method," in *2019 2nd International Conference on Smart Grid and Renewable Energy (SGRE)*, 2019, pp. 1–6.
- [13] —, "Improvement in three-dimensional finite element modeling for high voltage power transformer in time domain," in *2021 IEEE 19th International Power Electronics and Motion Control Conference (PEMC)*, 2021, pp. 460–466.
- [14] J. McCarthy, M. L. Minsky, N. Rochester, and C. E. Shannon, "A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955," *AI magazine*, vol. 27, no. 4, pp. 12–12, 2006.
- [15] A. W. Mahrukh, G. X. Lian, and S. S. Bin, "Prediction of power transformer oil chromatography based on lstm and rf model," in *2020 IEEE International Conference on High Voltage Engineering and Application (ICHVE)*, 2020, pp. 1–4.
- [16] A. Naderian, S. Cress, R. Piercy, F. Wang, and J. Service, "An approach to determine the health index of power transformers," in *Conference Record of the 2008 IEEE International Symposium on Electrical Insulation*, 2008, pp. 192–196.
- [17] K. Leauprasert, T. Suwanasri, C. Suwanasri, and N. Poonnoy, "Intelligent machine learning techniques for condition assessment of power transformers," in *2020 International Conference on Power, Energy and Innovations (ICPEI)*, 2020, pp. 65–68.
- [18] R. Arias Velásquez, J. Lara, and A. Melgar, "Converting data into knowledge for preventing failures in power transformers," *Engineering Failure Analysis*, vol. 101, 03 2019.



- [19] L. Kong, L. Luan, K. Zhou, C. Chen, J. Chen, and Z. Wang, "Running state prediction and evaluation of power transformers," in *2019 IEEE 4th International Conference on Advanced Robotics and Mechatronics (ICARM)*, 2019, pp. 639–642.
- [20] D. Wu-liang, "Analysis of life cycle characteristics of power transformer based on linear regression," *IOP Conference Series: Earth and Environmental Science*, vol. 223, p. 012029, 01 2019.
- [21] J. Haema and R. Phadungthin, "A prediction technique of power transformer condition assessment via dga parameters," in *2013 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, 2013, pp. 1–4.