



UNIVERSIDAD TÉCNICA DE COTOPAXI

DIRECCIÓN DE POSGRADO

MAESTRÍA EN ELECTRICIDAD

MODALIDAD: PROYECTO DE INVESTIGACIÓN

Título:

Desarrollo de un código de programación para el mantenimiento preventivo de transformadores de potencia

Trabajo de titulación previo a la obtención del título de magister en Electricidad
mención sistemas eléctricos de potencia

Autor:

Ing. Walter Paúl Rueda Flores

Tutor:

PhD. Secundino Marrero Ramírez

LATACUNGA –ECUADOR

2022


AVAL DEL TUTOR

En mi calidad de Tutor del Trabajo de Titulación “DESARROLLO DE UN CÓDIGO DE PROGRAMACIÓN PARA EL MANTENIMIENTO PREVENTIVO DE TRANSFORMADORES DE POTENCIA” presentado por Rueda Flores Walter Paul, para optar por el título magíster en Electricidad mención sistemas eléctricos de potencia.

CERTIFICO

Que dicho trabajo de investigación ha sido revisado en todas sus partes y se considera que reúne los requisitos y méritos suficientes para ser sometido a la presentación para la valoración por parte del Tribunal de Lectores que se designe y su exposición y defensa pública.


Latacunga, noviembre, 10, 2022


.....
PhD. Secundino Marrero Ramírez
1757107907

AVAL DEL TRIBUNAL

El trabajo de Titulación: “DESARROLLO DE UN CÓDIGO DE PROGRAMACIÓN PARA EL MANTENIMIENTO PREVENTIVO DE TRANSFORMADORES DE POTENCIA”, ha sido revisado, aprobado y autorizado su impresión y empastado, previo a la obtención del título de magíster en Electricidad mención sistemas eléctricos de potencia; el presente trabajo reúne los requisitos de fondo y forma para que el estudiante pueda presentarse a la exposición y defensa.

Latacunga, noviembre, 10, 2022



.....
MSc. Pesantez Palacios Gabriel Napoleón
0301893889
Presidente del tribunal



.....
MSc. Salazar Achig Edgar Roberto
0502847619
Lector 2



.....
MSc. Vásquez Tencda Franklin Hernán
1710434497
Lector 3

DEDICATORIA

A mis padres Rene y Targelia quienes con su apoyo y amor me han permitido llegar a cumplir todas las metas que me he propuesto, inculcando en mí el ejemplo del esfuerzo, honestidad y perseverancia.

A mis hermanos Fabian, Mayra y William que de una u otra manera me han apoyado a lo largo de mi vida en muchas adversidades, a mis sobrinos Cristofer, Mateo, Alejandro y Jazmín, y en general a toda mi familia.

A Karina mi novia quien me ha acompañado más que nadie en esta etapa de mi vida, gracias a su apoyo y cariño desinteresado y el de su familia he podido culminar este sueño.

Finalmente dedico esta investigación a todas las personas que creen en mí y me dan sus muestras de cariño y aprecio día a día.

Paul Rueda

AGRADECIMIENTO

A los fundadores de la Universidad Técnica de Cotopaxi que edificaron una Institución de Educación Superior diferente, con una profunda visión humanista.

A la PhD Iliana González por ser la promotora en la creación de la Maestría en Electricidad, Mención Sistemas Eléctricos de Potencia y al PhD Secundino Marrero por su humildad y entrega, para el desarrollo de esta investigación.

A mis compañeros y amigos, en especial Edwin y Víctor con quienes de una u otra manera compartimos experiencias de carácter profesional, pero sobre todo humano.

A mis maestros por su profesionalismo y por su entrega, ya que sin egoísmo nos transmitieron su conocimiento, adquirido durante varios años de su experiencia.

A la empresa SSEI cia. Ltda. por la experiencia que puede adquirir en la misma para posteriormente poder plasmarlo en este trabajo de investigación.

Walter Paul Rueda Flores

RESPONSABILIDAD DE AUTORÍA

Quien suscribe, declara que asume la autoría de los contenidos y los resultados obtenidos en el presente trabajo de titulación.

Latacunga, noviembre, 10, 2022

.....
Rueda Flores Walter Paul
0503689895

RENUNCIA DE DERECHOS

Quien suscribe, cede los derechos de autoría intelectual total y/o parcial del presente trabajo de titulación a la Universidad Técnica de Cotopaxi.

Latacunga, noviembre, 10, 2022

.....
Rueda Flores Walter Paul
0503689895

AVAL DEL PRESIDENTE DEL TRIBUNAL

Quien suscribe, declara que el presente Trabajo de Titulación: “DESARROLLO DE UN CÓDIGO DE PROGRAMACIÓN PARA EL MANTENIMIENTO PREVENTIVO DE TRANSFORMADORES DE POTENCIA” contiene las correcciones a las observaciones realizadas por los lectores en sesión científica del tribunal.

Latacunga, noviembre, 10, 2022



.....
MSc. Pesantez Palacios Gabriel Napoleón
0301893889

UNIVERSIDAD TÉCNICA DE COTOPAXI
DIRECCIÓN DE POSGRADO

MAESTRÍA EN ELECTRICIDAD
MENCIÓN SISTEMAS ELÉCTRICOS DE POTENCIA

Título: “DESARROLLO DE UN CÓDIGO DE PROGRAMACIÓN PARA EL MANTENIMIENTO PREVENTIVO DE TRANSFORMADORES DE POTENCIA”

Autor: Rueda Flores Walter Paul
Tutor: Secundino Marrero Ramírez

RESUMEN

Los transformadores de potencia son los equipos más importantes y por ende costosos al interior de una subestación de potencia, ya sea de elevación en una central generadora, transmisión o subtransmisión en subestaciones de paso, o de reducción tanto para empresas públicas de comercialización como para empresas privadas que alimentan sus procesos productivos, de acuerdo con estos distintos tipos de usos los equipos están sujetos a diferentes condiciones ambientales como grado de contaminación, salinidad, altura, humedad relativa, entre otros, a eso se le suma factores de demanda y calidad de energía, lo que provoca diferentes esfuerzos eléctricos y térmicos al interior del transformador. Consecuentemente resulta necesario implementar diferentes técnicas de diagnóstico de acuerdo con las etapas del plan de mantenimiento dependiendo de las condiciones propias, sobre este contexto, el propósito del siguiente proyecto es implementar un código de programación basado en el algoritmo de aprendizaje supervisado Support Vector Machine (SVM) para el procesamiento de los niveles de concentración de gases contenidos en el aceite dieléctrico mineral, obtenidos del Análisis de Gases Disueltos (DGA) y para la interpretación se utiliza el método de Duval expuesto en la norma IEEE C57.104™-2019, de tal forma que sirva para verificación y comparación con métodos estandarizados y no estandarizados como las Redes neuronales Artificiales (RNA), contribuyendo en las decisiones que se tomen en el programa de mantenimiento preventivo que se implementen a futuro en los distintos transformadores de potencia.

PALABRAS CLAVE: Transformador, SVM, Fallas, Algoritmos, Diagnostico, Duval.

UNIVERSIDAD TECNICA DE COTOPAXI
DIRECCION DE POSGRADO
MAESTRÍA EN ELECTRICIDAD
MENCIÓN SISTEMAS ELÉCTRICOS DE POTENCIA

Title: “DEVELOPMENT OF A PROGRAMMING CODE FOR THE PREVENTIVE MAINTENANCE OF POWER TRANSFORMERS”

Autor: Rueda Flores Walter Paul
Tutor: Secundino Marrero Ramírez

ABSTRACT

Power transformers are the most important and, therefore, costly equipment inside a power substation, whether it is the elevation-power in a generating plant, transmission or sub-transmission in pass-through substations, or reduction-power for both public marketing companies and private companies that feed their production processes, according to these different types of uses, the equipment is subject to different environmental conditions such as degree of contamination, salinity, height, and relative humidity, among others, as well as factors of demand and quality of energy, which causes different electrical efforts and thermal situations inside the transformer. Consequently, it is necessary to implement different diagnostic techniques according to the stages of the maintenance plan, depending on the conditions. Hence, the following project aims to execute a programming code based on the Support Vector Machine (SVM) supervised learning algorithm to process the concentrations of gases in the mineral dielectric oil obtained from the Dissolved Gas Analysis (DGA). To interpret the data, the Duval method exposed in the IEEE C57.104™-2019 standard is used in such a way that form that serves for verification and comparison with standardized and non-standardized methods such as Artificial Neural Networks (ANN), contributing to the decisions made in the preventive maintenance program to be implemented in the future in the different power transformers.

KEYWORD: Transformer, SVM, Faults, Algorithms, Diagnostic, Duval.

Wilmer Patricio Collaguazo Vega con cédula de identidad número: 1722417571 Licenciado en: Ciencias de la Educación especialidad Inglés, con número de registro de la SENESCYT: 1020-13-1198178 ; **CERTIFICO** haber revisado y aprobado la traducción al idioma inglés del resumen del trabajo de investigación con el título: “DESARROLLO DE UN CÓDIGO DE PROGRAMACIÓN PARA EL MANTENIMIENTO PREVENTIVO DE TRANSFORMADORES DE POTENCIA”; de Walter Paul Rueda Flores, aspirante a Magister en Electricidad mención Sistemas Eléctricos de Potencia.

Latacunga, noviembre, 10, 2022



Firmado electrónicamente por:
**WILMER PATRICIO
COLLAGUAZO VEGA**

Wilmer Patricio Collaguazo Vega
DOCENTE CENTRO DE IDIOMAS UTC
CC: 1722417571



CENTRO
DE IDIOMAS

ÍNDICE

AVAL DEL TUTOR.....	II
AVAL DEL TRIBUNAL.....	III
DEDICATORIA	IV
AGRADECIMIENTO	V
RESPONSABILIDAD DE AUTORÍA	VI
RENUNCIA DE DERECHOS.....	VII
AVAL DEL PRESIDENTE DEL TRIBUNAL	VIII
RESUMEN.....	IX
ABSTRACT.....	X
INTRODUCCIÓN	1
CAPÍTULO I FUNDAMENTACIÓN TEORICA METODOLOGICA	6
1.1 Antecedentes de la investigación.	6
1.2 Fundamentación Teórica.	10
1.2.1 El mantenimiento Predictivo.....	10
1.2.2 El Mantenimiento Preventivo	11
1.2.3 El Mantenimiento Correctivo.....	11
1.2.4 El mantenimiento detectivo.....	11
1.2.5 Programas de mantenimiento.....	12
1.2.6 El transformador de potencia	13
1.2.7 Pruebas eléctricas	14
1.2.8 Termografía.....	17
1.2.9 Pruebas al aceite aislante.....	19
1.2.10 Algoritmos de clasificación.....	28
1.3 Fundamentación Metodológica.....	31
1.3.1 Tipo de investigación	31
1.3.2 Técnicas de recolección de la información.	32
1.4 Conclusiones Capítulo I.....	34
CAPITULO II. PROPUESTA	35

2.1	Título de la propuesta.....	35
2.2	Objetivo de la propuesta.....	35
2.3	Justificación de la propuesta.	35
2.4	Fundamentación de la propuesta.....	36
2.5	Desarrollo de la metodología	37
2.5.1	Estrategia metodológica	37
2.5.2	Procesamiento de datos DGA	39
2.5.3	Diagnostico con SVM1	41
2.5.4	Diagnostico con SVM2	50
2.5.5	Diagnostico con SVM3	56
2.5.6	Acciones recomendadas de acuerdo al diagnóstico.	64
2.6	Conclusiones	69
CAPITULO III APLICACIÓN Y VALIDACIÓN DE LA PROPUESTA		70
3.1	Análisis de resultados.....	70
3.2	Validación técnica.....	85
3.3	Validación económica.....	86
3.4	Conclusiones del III capitulo. -	89
Conclusiones Generales		89
Recomendaciones.....		90
Referencias bibliográficas.....		91
Anexos		96

ÍNDICE DE FIGURAS

Figura 1. Curva de riesgo de fallo de un transformador en función de su edad [2].	13
Figura 2. Transformador de potencia marca Weg [12].	14
Figura 3. Fotografía termográfica de un transformador [10].	18
Figura 4. Prueba DGA a una muestra de aceite mineral [15].	20
Figura 5. Porcentaje relativo de concentraciones de gas disuelto en aceite mineral en función de la temperatura y el tipo de falla [17].	22
Figura 6. Diagrama conceptual de la aplicabilidad del DGA [19].	23

Figura 7. Triangulo de Duval 1 [17].	27
Figura 8. Triangulo de Duval 4 [17].	28
Figura 9. Triangulo de Duval 5 [17].	28
Figura 10. Ejemplo de hiperplano y vectores de soporte [26].	29
Figura 11. Máquina de soporte vectorial con arquitectura DTA	30
Figura 12. Diagrama de flujo de las fases de la metodología para el código de programación.....	38
Figura 13. Diagrama de flujo para clasificación de fallas con SVM1.	43
Figura 14. Vectores de soporte para SVM1.	46
Figura 15. Áreas de falla para clasificación de SVM1.....	48
Figura 16. Ejemplo de clasificación de fallas con SVM1.....	49
Figura 17. Diagrama de flujo para clasificación de fallas con SVM2.	51
Figura 18. Vectores de soporte para SVM2.	53
Figura 19. Áreas de falla para clasificación de SVM2.....	55
Figura 20. Ejemplo de clasificación de fallas con SVM2.....	56
Figura 21. Diagrama de flujo para clasificación de fallas con SVM3.	58
Figura 22. Vectores de soporte para SVM3.	60
Figura 23. Áreas de falla para clasificación de SVM3.....	62
Figura 24. Ejemplo de clasificación de fallas con SVM3.....	64
Figura 25. Árbol de decisiones para fallas eléctricas	67
Figura 26. Árbol de decisiones para fallas eléctricas.	68
Figura 27. Parámetros de la SVM.	78
Figura 28. Reporte visual con los datos de validación de la SVM1.	81
Figura 29. Reporte visual con los datos de validación de la SVM2.	82
Figura 30. Reporte visual con los datos de validación de la SVM3.	84
Figura 31. Resumen resultados obtenidos.....	85

ÍNDICE DE TABLAS

Tabla 1. Posibles diagnósticos a partir de los gases disueltos	22
Tabla 2. Método de relaciones de Roger.....	25
Tabla 3. Límite de concentraciones de gases disueltos.....	26
Tabla 4. Relación para gases claves según Doernenburg	26

Tabla 5. Porcentaje de concentración de gases en función del coeficiente O ₂ /N ₂ y años en µL/L (ppm).....	39
Tabla 6. Límites de la zona de falla para el triángulo de Duval 1.....	42
Tabla 7. Valores rectangulares normalizados para entrenamiento de SVM1	44
Tabla 8. Coordenadas rectangulares de los vectores de soporte para SVM1.....	46
Tabla 9. Diagnostico sugerido de acuerdo al tipo de falla	48
Tabla 10. Límites de la zona de falla para el triángulo de Duval 4.....	50
Tabla 11. Valores rectangulares normalizados para entrenamiento de SVM2	52
Tabla 12. Coordenadas rectangulares de los vectores de soporte para SVM2.....	54
Tabla 13. Diagnostico sugerido de acuerdo al tipo de falla para SVM2.....	55
Tabla 14. Límites de la zona de falla para el triángulo de Duval 5.....	57
Tabla 15. Valores rectangulares normalizados para entrenamiento de SVM3	59
Tabla 16. Coordenadas rectangulares de los vectores de soporte para SVM3.....	61
Tabla 17. Diagnostico sugerido de acuerdo al tipo de falla para SVM3.....	63
Tabla 18. Datos obtenidos para validación.	70
Tabla 19. Datos normalizados para la validación.	76
Tabla 20. Resultados de las SVM	78
Tabla 21. Resultados pronosticados por la SVM1	79
Tabla 22. Resultados pronosticados por la SVM2.	81
Tabla 23. Resultados pronosticados por la SVM3.	83
Tabla 24. Ejemplo de diagnóstico para la validación económica.	86
Tabla 25. Costo de mano de obra.....	87
Tabla 26. Costo de transporte y varios.....	87
Tabla 27. Costo de equipos.	87
Tabla 28. Costo total.	88
Tabla 29. Costo de energía no facturada.	88
Tabla 30. Costo beneficio del mantenimiento.....	88

INTRODUCCIÓN

Antecedentes: el presente trabajo toma como base la línea de investigación proporcionada por la Universidad Técnica de Cotopaxi para el programa de maestría en Electricidad, menciona sistemas eléctricos de potencia que consiste en: Energías alternativas y renovables, eficiencia energética y protección ambiental, y de forma particular se enfoca en la explotación y diseño de sistemas de potencia, considerando la continuidad como uno de los parámetros principales en el análisis de calidad de energía, para asegurar la misma se aplican técnicas de diagnóstico predictivo y mantenimiento preventivo a los transformadores de potencia.

El Ecuador, durante los últimos años ha realizado una importante inversión en todo el sector eléctrico, a nivel de generación se cuenta con 9 centrales hidroeléctricas nuevas como: Coca Codo Sinclair, Delsitanisagua, Mandariacu, Mazar Dudas, Minas San Francisco, Quijos, Sopladora, Toachi Pilatón y Villanaco, en el sistema de transmisión y subtransmisión se repotenció y construyó subestaciones, del conjunto mencionado el transformador es el equipo más importante por su funcionamiento y costo, de este dependerá la continuidad del servicio eléctrico, por lo tanto es necesario contar con un plan de mantenimiento preventivo adecuado acorde a las condiciones particulares de operación del equipo.

El sistema eléctrico en todas sus etapas es propenso a sufrir alteraciones en sus condiciones normales de operación, las mismas pueden ser producidas por maniobras o la presencia de alguna falla, esto provoca que el transformador opere en condiciones diferentes a las que fueron diseñados, lo que provoca un deterioro progresivo en las componentes del equipo que en las etapas iniciales son imperceptibles hasta cierto punto, el mantenimiento predictivo tiene por objeto ubicar las posibles causas de la falla, identificar el grado de afectación e implementar las medidas necesarias para asegurar que el tiempo de vida útil no se vea afectado de forma brusca.

Planteamiento del problema. El diagnóstico predictivo es una de las técnicas más importantes utilizadas en transformadores de potencia sumergidos en aceite, consiste en el análisis periódico de las condiciones mecánicas y eléctricas del equipo, ya que estas se van deteriorando en principio por las condiciones

ambientales bajo las cuales opera el equipo, estas pueden provocar corrosión, oxidación e incluso fugas de aceite en diferentes puntos del transformador como pernos, radiadores y tanque conservador.

En el caso de los parámetros eléctricos estos se ven afectados por sobrevoltajes de maniobra o de falla que se presentan en el sistema o por un comportamiento inusual en las cargas, esto produce arcos eléctricos al interior del transformador que son extinguidos por el aceite dieléctrico, sin embargo, puede provocar efectos residuales como el deterioro en una bobina que afectara los parámetros eléctricos y produce la presencia de gases al interior del equipo.

El mantenimiento es una herramienta importante que se divide en cuatro tipos, los cuales se aplican de acuerdo a las etapas de la vida útil del transformador para preservar este tiempo teórico, la frecuencia de estos mantenimientos cada vez se ve más reducida, esto se debe al desarrollo natural de la ciencia y la tecnología, por ende los nuevos equipos tienden a tener menores posibilidades de falla o deterioro, por lo cual esta área de la ingeniería ha sido desplazada restándole la importancia que debería tener, evitando de este modo realizar estudios que permitan optimizar su diagnóstico, aplicación y seguimiento.

Los avances en informática han sido implementados en distintos campos de la ingeniería eléctrica y el mantenimiento no puede ser la excepción, un código de programación podría almacenar los parámetros externos e internos del transformador, procesar y comparar estos datos con los registros históricos del equipo, sus datos de fábrica, y con los resultados obtenidos de transformadores en similares condiciones de operación, presentando como resultado un plan de mantenimiento integral que considere la mejor solución técnico – económica y que a la vez permita tener un seguimiento en la evolución de su vida útil.

Formulación del problema. Cada año el sector industrial y por ende el sector eléctrico crece, esto significa la incorporación de varios transformadores de potencia, los cuales necesitan contar con un plan de mantenimiento predictivo, sin embargo, las empresas y expertos que se dedican a esta actividad no pueden cubrir esa demanda por la amplitud que significa cada plan al realizarlo de forma tradicional.

Objetivo General.

Implementar un código de programación basado en un algoritmo de clasificación mediante el método de Duval de acuerdo con la norma IEEE Std c57.104 que permita diagnosticar el estado actual del transformador de potencia.

Objetivos Específicos:

- Recopilar información sobre el estado del arte del mantenimiento predictivo y la aplicación de algoritmos de aprendizaje supervisado en procesos de clasificación.
- Desarrollar un código de programación que almacene procese y compare los reportes de los análisis de gases disueltos del aceite dieléctrico.
- Comprobar y optimizar el código para que emita el diagnóstico y el tipo de falla presente en el transformador.
- Validar la herramienta informática y el efecto técnico económico.

Sistemas de tareas en relación a los objetivos específicos:

Objetivos específicos	Actividad (tareas)	Resultado de la actividad	Descripción de la actividad (técnicas e instrumentos)
1	Búsqueda en fuentes bibliográficas sobre la técnica y aplicación de mantenimiento preventivo. Análisis del proceso de optimización y restricciones que utilizan los algoritmos de aprendizaje supervisado.	Obtener una base técnica y económica sólida sobre el mantenimiento. Comprender el comportamiento del proceso de optimización con algoritmos de aprendizaje supervisado.	Búsqueda de información. Entrevista a expertos sobre el tema.

2	Recopilación de reportes históricos de transformadores de potencia. Desarrollo de un código de programación para almacenar y procesar la base de datos obtenida.	Contar con una base de datos del análisis de gases disueltos y el diagnóstico real del equipo para cada caso. Código que procese la información histórica y compare con la condición actual del transformador.	Recolección de datos. Programación del código.
3	Aplicación de algoritmos de clasificación. Implementación de restricciones técnicas al algoritmo.	Código de programación optimizado. Obtener posibles diagnósticos confiables de acuerdo a las necesidades del equipo o el sistema.	Diseño de un algoritmo de diagnóstico
4	Validación del mantenimiento. Valoración del reporte económico.	Transformador operando de forma óptima. Se podrá visualizar el ahorro económico a medio y largo plazo.	Definir las acciones recomendadas para el próximo plan de mantenimiento sugerido.

Justificación y/o importancia de la investigación:

La siguiente investigación tiene por objeto el desarrollo de un código de programación que procese y almacene los reportes de los análisis al aceite como:

rigidez dieléctrica, análisis físico químico, cromatografía de gases, contenido de Furanos, contenido de inhibidor y factor de potencia, además de los resultados de las pruebas eléctricas de: relación de transformación, resistencia de bobinado, resistencia de aislamiento y factor de potencia de aislamiento, y los compare con sus datos de fábrica y los estándares establecidos en normas internacionales para obtener el mejor plan de mantenimiento de acuerdo criterios técnicos y económicos deseados.

Mediante la aplicación de algoritmos genéticos se puede optimizar el diagnóstico predictivo, para ello se considerará a cada parámetro del transformador como un miembro de una población, los cuales al atravesar un proceso de cruce y selección irán mutando (mejorando), estas técnicas pueden arrojar una gran cantidad de posibles soluciones, por lo que es necesario tener criterios de restricción que permitirá evaluar las mejores soluciones considerando: la confiabilidad, continuidad, tiempo de vida útil y el aspecto económico.

Este código de programación permitirá que los responsables de mantenimiento y las empresas que brindan este servicio puedan contar con un diagnóstico predictivo confiable y varias posibles soluciones óptimas a aplicar, con las cuales podrán planificar y dar seguimiento a los planes de mantenimiento preventivo y a la evolución de la vida útil del transformador de potencia tras cada intervención, en general será un soporte tecnológico para que los especialistas de esta área puedan valorar de forma integral el equipo y así tomar la mejor decisión técnica – económica.

Hipótesis:

¿Es posible determinar el estado actual de un transformador de potencia analizando sus informes históricos y diagnosticar el mantenimiento predictivo necesario para que el equipo opere en condiciones óptimas?

CAPÍTULO I FUNDAMENTACIÓN TEORICA METODOLOGICA

1.1 Antecedentes de la investigación.

El programa de mantenimiento preventivo sigue una secuencia lógica desde que se detecta un problema, se estudia, se encuentra su causa, y finalmente se decide la posibilidad de corregirlo en el momento oportuno con la máxima eficiencia [1]. Esto puede definirse en los siguientes pasos: detección, análisis y corrección, por lo que el mantenimiento se basa en la medición, monitoreo y seguimiento de variables físicas que puedan llegar a afectar el debido funcionamiento de un equipo, por lo que relaciona una variable física con el desgaste o estado de la máquina [2].

El mantenimiento preventivo corresponde a la unión entre mantenimiento sistemático y predictivo. Se puede definir como la realización de cualquier tarea programada, de acuerdo con un plan previamente establecido cuyo objetivo consiste en reducir el potencial de ocurrencia de fallos que tendrán un efecto adverso sobre la confiabilidad, la disponibilidad o la seguridad del equipo para que cumpla con su tiempo de vida útil y optimizar su funcionamiento [3].

Las principales ventajas que podemos encontrar al contar con un plan de mantenimiento preventivo:

- Disminuir la frecuencia de las paradas.
- Aprovechar la intervención para efectuar varias reparaciones.
- Disminuir el trabajo de mantenimiento evitando exceso o bajas en las tareas del servicio.
- Evita que las averías se aumenten.
- Disminuye los riesgos para los sistemas de seguridad

Por esta razón, es importante evitar estos problemas a través de un programa de mantenimiento preventivo que puede ser realizado por medio de pruebas diagnósticos confiables que se aplican en el transformador, las mismas que tratan de ubicar el desarrollo de un problema antes que llegue a ser decisivo y poder tomar medidas correctivas.

Para garantizar que este servicio se preste de una manera oportuna, es necesario identificar, atender y prevenir las posibles fallas que puedan presentarse en los

sistemas eléctricos. Específicamente, las fallas en los transformadores de potencia podrían costar enormes cantidades de dinero, principalmente debido a las detenciones inesperadas y el mantenimiento correctivo no programado [4].

Uno de los componentes del esquema de mantenimiento preventivo y puesta en servicio de estos activos son las pruebas primarias; las cuales permiten determinar el estado de un transformador de potencia [5], este análisis permite interpretar como se encuentra el transformador, comparando con la curva de tiempo de vida del transformador, debido a que los mantenimientos tienen como objetivo prolongar o asegurarse que este tiempo de vida útil se cumpla.

El transformador de potencia está sometido a una operación continua para la prestación del servicio de la energía eléctrica y una falla por factores internos generaría: el lucro cesante del activo, la energía no suministrada y la compensación a los usuarios por la interrupción del servicio; por lo cual la inversión en el mantenimiento y la conservación es una responsabilidad de los propietarios u operadores de la red [6].

El régimen de operación permanente de un transformador se encuentra sometido a los siguientes fenómenos eléctricos y mecánicos, para los cuales es importante el estudio y análisis de este comportamiento en la aplicación de las pruebas primarias de un programa de mantenimiento preventivo [7].

El mantenimiento predictivo de la máquina se realiza a partir de la Inspección y Diagnóstico basado en las diversas pruebas a las que se le somete a lo largo de su ciclo de vida. El objetivo es obtener información sobre el estado de los distintos elementos que constituyen el transformador. Podemos destacar las pruebas siguientes:

Diagnóstico del aceite: Dissolved Gas Analysis (DGA).

Diagnóstico del aislante: factor de potencia, resistencia de aislamiento, medida de PD en servicio, espectroscopia dieléctrica y FDS.

Diagnóstico de arrollamientos y/o cambiador de tomas en carga: resistencia de arrollamientos, relación de transformación, reactancia de dispersión o impedancia de cortocircuito y frequency response analysis.

Los programas de mantenimiento están diseñados para realizar una parada técnica y poder medir los niveles o rangos eléctricos del transformador, la instauración de un programa de mantenimiento sistemático requiere un análisis detallado de las actividades que se realizarán, frecuencias de ejecución, recursos, costos y del conocimiento del equipo productivo y sus componentes. No se puede caer en ninguno de los dos extremos: tener el equipo funcionando hasta su destrucción o desmontarlo continuamente para revisión incurriendo en costos excesivos de mantenimiento [3] por lo que es necesario encontrar el equilibrio entre mantenimiento predictivo y no necesitar en futuro un mantenimiento correctivo o ya sea el cambio del equipo.

Existen distintos métodos y pruebas complementarias para analizar el estado de un transformador, entre ellos las más fiables son las pruebas eléctricas para determinar en qué grado los parámetros eléctricos corresponden al diseño del mismo, las pruebas más comunes son las siguientes:

- Resistencia de aislamiento
- Resistencia óhmica de bobinado
- Relación de transformación
- Factor de potencia de aislamiento
- Análisis de respuesta al barrido de frecuencia SFRA

Los ensayos de aislamiento son pruebas periódicas realizadas para determinar la condición del aislamiento de motores y transformadores. Normalmente son pruebas de resistencia convencionales y reflejan la presencia de humedad y suciedad [3]. Son ensayos que se realizan aplicando una tensión alterna y que se han venido mostrando durante años como herramientas muy valiosas para determinar, tanto la calidad en la fabricación de devanados, como el estado de éstos en máquinas ya en funcionamiento [3].

Otro parámetro a considerar en el diagnóstico de un transformador es el aceite aislante, ya que este a la vez de enfriar y funcionar como aislamiento, su flujo dentro del transformador sumado a las condiciones de operación puede provocar problemas internos y reducir el tiempo de vida útil del equipo, para conocer el

estado del transformador se realizan análisis físicos químicos del estado del aceite, entre las pruebas más comunes encontramos las siguientes:

- Rigidez dieléctrica
- Propiedades del aceite
- Contenido de gases disueltos
- Análisis de gases disueltos

Desde hace tiempo se consideraba al transformador como una maquina estática, sin embargo, aunque sus componentes físicos cumplen esta condición, el aceite dieléctrico se encuentra en movimiento debido a la variación de temperaturas producidas por el esfuerzo eléctrico del transformador. Esta circulación del aceite provoca el desgaste interno de los componentes del transformador y debido al nivel de voltaje y el desgaste de los componentes internos se producen gases. Los gases emitidos son principalmente hidrógeno H₂, monóxido de carbono (CO), dióxido de carbono (CO₂), metano (CH₄), acetileno (C₂H₂), etano (C₂H₆) y etileno (C₂H₄) [3]. Existen diferentes técnicas para el análisis y diagnóstico de estos gases, la norma IEE recoge los principales criterios.

La detección de algunos tipos de fallas o eventos como por ejemplo arcos eléctricos en las guías; falsos contactos, descargas parciales, u otra y su localización constituían un problema anteriormente. Actualmente, la información obtenida de un sistema de adquisición de datos, con el monitoreo, permite detectar fallas tanto de rápido, como de lento desarrollo, lo que supera los métodos convencionales de las pruebas eléctricas realizadas sólo fuera de servicio, no pueden detectar las fallas de rápido desarrollo, por estar basados en mediciones espaciadas en el tiempo [8].

La Confiabilidad Operacional como estrategia esencial de la Gestión de Activos, permite definir el desarrollo de procesos de mejora continua que incorporan en forma sistémica y sistemática avanzadas herramientas de diagnóstico, metodologías de análisis y nuevas tecnologías de mantenimiento, para optimizar la planeación, ejecución y control de la producción industrial [9].

Anteriormente CONELEC, en la actualidad ARCONEL “Agencia de Regulación y Control de Electricidad”, determinó regulaciones referentes a la calidad del servicio eléctrico de distribución, dictaminando así la regulación 004/01 que hace mención

a la “Calidad del servicio eléctrico de distribución” esta regulación establece que: Las Empresas Distribuidoras tienen la responsabilidad de brindar el servicio eléctrico a los consumidores ubicados en su zona de concesión, dentro de los niveles de calidad establecidos, en virtud de lo que señala la Ley Orgánica del Servicio Público de Energía Eléctrica, los reglamentos aplicables, el contrato de concesión y las regulaciones correspondientes [10].

La gestión de activos es de gran relevancia para las industrias; con la creciente oferta de productos y servicios y la automatización de los procesos, es de suma importancia optimizar los recursos al máximo; el mantenimiento predictivo se basa en técnicas y metodologías que permiten a un activo sea útil durante el 100% de su vida, sin hacer cambios del mismo o paradas innecesarias; por tal motivo se presenta el análisis de criticidad y el árbol de diagnóstico para transformadores de potencia como modelos para incrementar la confiabilidad operacional [9].

La inteligencia artificial en la detección de fallas de transformadores presenta estudios basados en el uso de la medición de temperatura infrarroja para detectar fallas incipientes en transformadores a través del análisis de gas disuelto del aceite aislante. La metodología de este estudio utiliza sistemas inteligentes para analizar las temperaturas del transformador y detectar fallas incipientes. Los resultados obtenidos en este trabajo presentan un 86 y 83% de corrección de clasificación utilizando redes neuronales artificiales y lógica difusa, respectivamente [11].

1.2 Fundamentación Teórica.

Cuando se hablaba de mantenimiento hasta hace algunos años solo se lo clasificaba en tres etapas: predictivo, preventivo y correctivo. Sin embargo, con los avances de estudios dedicados a este campo su visión ahora es más amplia, de modo que existen cuatro tipos de mantenimiento: predictivo, preventivo, correctivo y detectivo, incluso se han definido subcategorías para algunas de estas etapas, lo que permite enfocarse en planes de mantenimiento completos para cada una de estas etapas con el fin de garantizar que los equipos en la actualidad cumplan con su tiempo de vida, incluso que este tiempo pueda ser prolongado [12].

1.2.1 El mantenimiento Predictivo .- También conocido como mantenimiento a condición consiste en la búsqueda de indicios o síntomas que permitan identificar

una falla antes de que ocurra [12], pero más que un tipo de mantenimiento, se refiere a las técnicas de detección precoz de síntomas para ordenar la intervención antes de la aparición del fallo [13], definiremos que es toda actividad de mantenimiento y diagnóstico destinada a mantener un activo en un estado de funcionamiento pleno sin necesidad de detener el proceso productivo, el cual se enfoca en las estadísticas de los historiales de falla en los sistemas productivos de los mantenimientos anteriores [1], [14].

1.2.2 El Mantenimiento Preventivo .- Es efectuado con intención de reducir la probabilidad de fallo, del que existen dos modalidades: sistemático y condicional [13]. El sistemático se aplica en intervalos iguales de tiempo, de acuerdo al programa de mantenimiento considerando la posibilidad de falla y de contar con una reserva y el condicional que se aplica cuando suscite un acontecimiento no planificado, por otro lado esta etapa del mantenimiento responde a las tareas de sustitución o reacondicionamiento hechas en intervalos de tiempos definidos en el plan de mantenimiento que se realizaran sin importar el estado del equipo, estas acciones son aplicables si existe un patrón de desgaste, por ejemplo con las propiedades físico-químicas del aceite aislante [12].

1.2.3 El Mantenimiento Correctivo .- Se realiza después de que ocurre la falla, en este caso se trata de reparar averías o cambiar componentes importantes del equipo [13], si se decide o no existe la posibilidad de realizar tareas predictivas o preventivas para manejar una falla, el mantenimiento correctivo planificará la reparación una vez que ocurra la falla, este mantenimiento es aceptable cuando el costo de las actividades de prevención son mayores a esta y cuando la falla no produzca consecuencias adversas sobre la seguridad del sistema o el medio ambiente [12]. De otro modo es una obligación tomar las medidas para reducir o eliminar las consecuencias de la falla.

1.2.4 El mantenimiento detectivo .- También llamado de búsqueda de fallas, consiste en la prueba de dispositivos de protección bajo condiciones controladas [12]. En esta etapa en especial no existen acciones orientadas a reparar un elemento que falló (mantenimiento correctivo), tampoco se aplica acciones en ciclos definidos con el fin de reemplazar o reacondicionar un componente (mantenimiento

preventivo), ni se apoya en pruebas no invasivas que den como resultado síntomas de que una falla está en el proceso de ocurrir (mantenimiento predictivo).

A este mantenimiento también se le llama búsqueda de fallas o prueba funcional, y el intervalo en el cual se realiza esta tarea se le llama intervalo de búsqueda de fallas, o FFI, por sus siglas en inglés (failure finding interval). Por ejemplo, arrojar humo a un detector contra incendios es una tarea de mantenimiento detectivo.

1.2.5 Programas de mantenimiento.-Los programas de mantenimiento en especial el predictivo debe seguir una secuencia lógica desde la detección de una condición anormal, su análisis minucioso, la ubicación de la causa, y la toma de acciones de acuerdo a la posibilidad de corregirlo en el momento adecuado para aprovechar su máxima eficiencia [1]. Esto se resume en lo siguiente: detección, análisis y corrección, por otro lado se refiere a la búsqueda de diferentes estrategias para encontrar un mecanismo eficaz con el cual se pueda ubicar la existencia de fallas al interior del transformador [6], se debe utilizar todos los medios, incluso los estadísticos que permitan determinar la frecuencia de las inspecciones, sustitución de piezas claves, portabilidad de aparición de averías, vida útil y otras [14].

Para diseñar un plan de mantenimiento predictivo a un transformador de potencia hay que entender primero el comportamiento del equipo en función de su tiempo de vida útil, la probabilidad de que se presente una falla en un transformador se puede analizar en la Figura 1 [15]. Esta curva ubica 2 escenarios en donde existe un mayor nivel de riesgo de falla que se observa en los primeros y últimos años de vida del equipo, el primer caso responde a que es posible encontrar fallas debido a la calidad de fabricación del transformador o al método de transporte y conservación que fue sometido el equipo desde la fábrica hasta su lugar de funcionamiento, y en el caso de los últimos años, se produce por el deterioro natural y envejecimiento que puede provocar una falla de funcionamiento.




Figura 1. Curva de riesgo de fallo de un transformador en función de su edad [2].

1.2.6 El transformador de potencia.- Para muchos analistas este equipo es básicamente un dispositivo eléctrico pasivo electromagnético estático muy simple que funciona en base a la Ley de inducción de Faraday al convertir de un valor a otro el nivel de voltaje y corriente [11], pero pese a ser una máquina eléctrica que no posee partes móviles, lo único que cambia en relación con otros tipos de máquinas eléctricas es que esta no requiere tanta frecuencia en sus maniobras de mantenimiento; se debe poner atención a que en la mayoría de los casos las fallas en los transformadores no son hechos espontáneos, estos se desarrollan de manera progresiva dejando a su paso una serie de eventos o sucesos intermedios; mediante varios tipos de diagnóstico se puede determinar las posibles causas [9].

Uno de los elementos importantes de un transformador es el aislamiento el cual está compuesto por dos clases de material aislante: Sólido y líquido. El material sólido el cual se utiliza como aislante es la celulosa o papel que recubre a los devanados de alta y baja tensión, y el aislante líquido es el aceite que tiene también como función principal la refrigeración [15]. En condiciones anormales puede producirse una falla térmica, puede ser por sobrecargas prolongas al transformador, fallas exteriores producidas por una mala alimentación del sistema o deficiencia en el sistema de enfriamiento del equipo como ventiladores, entre otros [12]. Para detectar el origen se utiliza termografía o análisis de gases disueltos en el aceite.



Figura 2. Transformador de potencia marca Weg [12].

1.2.7 Pruebas eléctricas. - Otro de los eventos principales que genera la salida de operación de un transformador es las fallas a tierra, las cuales se generan por bujes fallados o pérdidas de rigidez dieléctrica asociada a sobrecargas que dan inicio a arcos eléctricos hacia las partes aterrizadas del transformador. Un buje o bushing puede resultar fallado debido a puntos calientes ocasionados por malos ajustes en labores de mantenimiento, por disminución del aislamiento interno del buje, por presencia de plantas o animales sobre el buje, por deformación del buje por impactos, por vandalismo o por sobreajustes en maniobras de mantenimiento [9].

De acuerdo a [9] una falla en el cambiador de tomas sin carga puede producirse debido a la mala operación del mismo, deformaciones del mecanismo debido a sobreajustes en la operación, fugas de aceites o por puntos calientes generados por falsos contactos producidos al no quedar el tap en la posición correcta en el momento de un ajuste o mantenimiento, como evidencia se forma carboncillo al rededor del contacto. Por lo cual es necesario realizar pruebas eléctricas a las distintas componentes del transformador para garantizar que se encuentren operando en condiciones óptimas o ubicar el grado de deterioro.

Prueba de SFRA.- Los tipos de fallas que se puede detectar con la técnica FRA son: el movimiento del núcleo, las fallas a tierra del núcleo, la deformación de los bobinados, el desplazamiento de los bobinados, el colapso parcial de los bobinados, el arrollamiento de los bobinados y las espiras en corto circuito o ruptura del bobinado [6]. La técnica para alizar ese barrido es el Análisis de respuesta al barrido de la frecuencia, por sus siglas en inglés (SFRA), este comportamiento puede ser

representado eléctricamente por componentes R, L y C. Estos componentes forman una función de transferencia que queda caracterizada por una gráfica que suele considerarse como su huella digital [12].

En la gráfica se puede comparar lo siguiente:

- Deformación del núcleo Circuito abierto
- Espiras en cortocircuito y magnetismo residual
- Movimiento de cables de salida de devanados
- Desplazamiento de un devanado respecto a otro
- Deformación de devanados principales o regulador

Factor de potencia. - Es un método tradicional para evaluar la condición del aislamiento y detectar fracturas o perforaciones en el sistema de aislamiento de los transformadores a través de la medición de las pérdidas dieléctricas. Los resultados de esta prueba pueden verse afectados por la humedad que genera la circulación de corrientes a tierra a través de las superficies [6]. El factor de potencia del aislamiento es una medida de las pérdidas de potencia a través del sistema de aislamiento y tierra producidos por una corriente de fuga. Los resultados de factor de potencia del aislamiento ayudan a detectar humedad, carbonización, pasa-tapas defectuosos, contaminación del aceite con materiales disueltos o partículas conductivas, núcleos no puestos a tierra, entre otros [12].

Resistencia de aislamiento. - Es una prueba no destructiva que ayuda para diagnosticar el estado del aislamiento. La resistencia de aislamiento de un aislante eléctrico se define como la resistencia en megaohmios ($M\Omega$), que ofrece el aislante a la aplicación de una tensión directa. La medición de la resistencia de aislamiento en el caso de los transformadores de potencia, se realiza entre devanados y entre devanados y tierra, esto en intervalos de tiempo aproximados de un minuto a diez minutos [12]. Se realiza a transformadores que se preparan para su puesta en servicio, con el objeto de verificar la resistencia de aislamiento del núcleo y su correcto soterramiento en un solo punto, comprobando al mismo tiempo la adecuada geometría del núcleo y asegurando que no haya existido desplazamiento del mismo durante las maniobras de transporte. La prueba es aplicable también a

transformadores en operación que presenten sobrecalentamiento sin llegar a su capacidad nominal [6].

Prueba de corriente de excitación. - Este diagnóstico no es sensible para detectar deformaciones en los componentes internos del transformador, sin embargo, puede ser útil para detectar averías en el núcleo. Las mediciones de corriente de excitación se llevan a cabo para evaluar el aislamiento entre espiras del devanado el transformador, el circuito magnético del transformador y el cambiador de tomas OLTC, las desviaciones en su medidas indican un desgaste en sus contactos o una posible avería en el cableado del OLTC [6]. Esta prueba permite detectar fallas en el circuito magnético y devanados como cortocircuitos entre espiras, fallas en el aislamiento de los pernos de sujeción del núcleo, mal contacto en el cambiador de taps, fallas en el aislamiento entre laminas del núcleo, mal contacto entre laminaciones sueltas, sobrecalentamiento, mala puesta a tierra, entre otras. Normalmente, en campo se recomienda hacer la prueba en todos los taps para graficar los resultados [12].

Prueba de relación de transformación.- Esta prueba asegura que las bobinas del transformador mantengan las vueltas correctas para producir los niveles de tensión adecuados, de esta manera se asegura que la tensión suministrada pueda ser transformada al nivel de tensión deseada [6]. En el análisis de los resultados obtenidos en esta prueba se pueden detectar defectos en el transformador. Dentro de los defectos que se pueden detectar está: vueltas cortocircuitadas en sus devanados, errores en el número de espiras, espiras abiertas, fallas entre contactos del tap, entre otros [12].

Prueba de resistencia (DC) de devanados. - Esta prueba indicará un cambio en la resistencia DC de los devanados en el caso de que existiesen vueltas cortocircuitadas, empalmes sueltos o malos contactos. Los resultados obtenidos al realizar esta prueba deberán ser comparados con los proporcionados por el fabricante del equipo o con los resultados obtenidos en pruebas anteriores [12]. La medición de la resistencia de los devanados de los transformadores se utiliza para chequear conexiones y determinar si hay conexiones de circuito abierto o la existencia de una conexión de alta resistencia [6].

Pruebas de reactancia de fuga o corriente de cortocircuito. - El comportamiento capacitivo de las partes activas permite conducir corrientes eléctricas a través de los conductores de los devanados primarios y secundarios; los cuales forman capacitancias. La capacitancia representa el almacenamiento de un campo eléctrico y el valor es uniforme cuando el transformador está acorde a su diseño y trabajando dentro de su capacidad nominal de operación [6].

1.2.8 Termografía. - Para entender el diagnostico basado en termografía partamos por el calor, es la forma de la energía que se puede transferir de un sistema a otro como resultado de la diferencia en la temperatura. Se ve claramente reflejado en la primera ley de la termodinámica o el principio de conservación de la energía esta ley permite definir el calor como la energía necesaria que debe intercambiar el sistema para compensar las diferencias entre trabajo y energía interna [10], sin embargo el ojo humano no puede visualizar la energía térmica, por lo tanto las imágenes térmicas de la superficie de un objeto solo son posibles mediante termografía infrarroja, en la cual la energía invisible del calor se convierte en energía térmica visual, que muestra la imagen del objeto [11].

Con la finalidad de minimizar las potenciales fallas que puedan ocasionar un grave daño y que puedan sacar de servicio a los equipos de las unidades anteriormente mencionadas. Las fallas en las subestaciones y alimentadores son a menudo precedidas por una anomalía térmica del componente eléctrico [10], la energía térmica juega un papel importante ya que todos los objetos eléctricos con temperatura superior a cero emiten radiación infrarroja que aumenta la temperatura interna de los equipos eléctricos en la subestación de energía eléctrica. La corriente que pasa a través del equipo eléctrico en la subestación causa calor en los dispositivos eléctricos tales como relés, capacitores y transformadores [11].

La termografía es una técnica que permite medir temperatura a distancia y sin necesidad de contacto físico con el objeto a estudiar. Mediante la captación de la radiación infrarroja del espectro electromagnético [10]. Utilizando cámaras termográficas podremos convertir la energía radiada en información sobre temperatura, como un método de diagnóstico avanzado para la supervisión de la temperatura del transformador. El sobrecalentamiento de los transformadores de

potencia de superficie puede ocurrir debido a pérdidas de energía o condiciones operacionales que podrían tratarse como fallas [11]. Un sobrecalentamiento atípico de la superficie del transformador o una distribución atípica de la temperatura en la superficie podría evidenciar el deterioro progresivo de los elementos de la maquinaria (núcleo, bobinado, conexiones y abrazaderas) y/o el deterioro del aislamiento eléctrico (papel, aceite).

El análisis de termografía se puede dividir en 3 etapas, la etapa inicial que permite tener una visión general de todos los componentes del equipo en función de las condiciones de operación normal a plena carga, la etapa comparativa se presenta cuando un termógrafo utiliza imágenes de componentes similares en condiciones similares para evaluar el estado del equipo sujeto a inspección y finalmente la tendencia térmica, en esta etapa el experto compara los resultados obtenidos del mismo equipo bajo las mismas condiciones de operación, pero tiene que hacerlo en función del tiempo entre una medida y otra, y considerando las condiciones climáticas como la velocidad del viento, la presencia de humedad o componentes que presenten mucha emisividad [10].



Figura 3. Fotografía termográfica de un transformador [10].

Las ventajas de la termografía.- Podemos encontrar las siguientes ventajas por las cuales nos invita a utilizar este método de diagnóstico en transformadores [11].

- Es un método de inspección sin contacto.
- Se puede usar para inspeccionar piezas muy grandes.
- La duración de la inspección es corta y se puede usar para inspeccionar diferentes materiales, incluidos los materiales compuestos.

- Se puede utilizar para inspeccionar geometrías complejas de piezas, componentes de menor accesibilidad y aplicaciones en tiempo real como ciclos de producción.
- Es fácil de instalar, usar y mantener en una línea de producción.

Las limitaciones de la termografía.- Podemos encontrar las siguientes limitaciones al momento de diagnosticar un transformador utilizando una cámara termográfica [11].

- Depende en gran medida de la naturaleza de la fuente de calefacción, la duración del calentamiento y la ubicación de la fuente de calor.
- Es difícil inspeccionar muestras gruesas.
- La duración de la captura debe estudiarse según la naturaleza del material que se prueba.
- El rendimiento de la cámara infrarroja utilizada tiene un gran impacto en la calidad de captura.
- El entorno de la muestra que se prueba puede afectar la imagen capturada. Hay una necesidad constante de calentar la muestra de manera uniforme.
- Cada aplicación requiere una técnica de excitación específica.
- Algunas técnicas requieren que se conozca el espesor de la muestra y la naturaleza, la ubicación del defecto.

1.2.9 Pruebas al aceite aislante.- Otra de las técnicas de diagnóstico más utilizadas en transformadores de potencia son las pruebas al aceite, donde se evalúa las propiedades física y químicas del aceite, se analiza la aparición de gases al interior del equipo, los tres componentes principales sujetos a la deterioración y contaminación son: el papel usado para el aislamiento de los conductores, el cartón que es usado para el aislamiento principal y para los soportes de los arrollamientos y el aceite dieléctrico [15], también es necesario tomar en cuenta la contaminación producida por fugas de aceite por el deterioro de los empaques o por maniobras de mantenimiento mal ejecutadas dejando puntos desajustados [9].



Figura 4. Prueba DGA a una muestra de aceite mineral [15].

Dentro del sistema de aislamiento se encuentra el aceite dieléctrico el cual además de funcionar como barrera dieléctrica entre los componentes del transformador y ser refrigerante, brinda gran información del estado de funcionamiento del transformador. Con el deterioro de los materiales aislantes se forman diferentes tipos de gases que se van diluyendo en el aceite aislante y que pueden evidenciar la presencia de una falla dentro del transformador, a través de una buena interpretación se puede llegar a detectar fallas incipientes y actuar en forma correctiva, evitando así la generación de fallas mayores y la interrupción del suministro eléctrico [16]

Factores que afectan en el deterioro del aislamiento. - La humedad especialmente en presencia del oxígeno es extremadamente peligrosa para el aislamiento de un transformador. Cada vez que la cantidad de humedad en el transformador aumenta el doble, la vida del aislamiento se reduce a la mitad. La humedad puede ingresar si existiese alguna fuga en el tanque o en las tuberías del sistema de ventilación. El agua puede estar presente en forma disuelta, como emulsión, libre en el fondo del tanque o en forma de hielo, cuando se eleva la temperatura al interior del transformador el agua comienza a migrar a la parte que es más fría y que presenta el mayor esfuerzo eléctrico [15].

El oxígeno es otro de los potenciales enemigos del aislamiento de un transformador, ya que este reacciona con el aceite para formar ácidos orgánicos, agua y lodo. El oxígeno proviene de la atmósfera o es liberado por la celulosa como resultado de aplicarle calor. La oxidación del aceite comienza cuando el oxígeno se combina con las impurezas de hidrocarburos inestables existentes en el aceite bajo el efecto.

Dentro de los catalizadores tenemos a la humedad y al cobre; dentro de los aceleradores tenemos al calor, la vibración, los sobre voltajes y a los elevados esfuerzos eléctricos debidos a fallas eléctricas internas. Como se expresó anteriormente la etapa final de la oxidación es la formación de lodos en el interior del transformador, es decir, la presencia de lodo en un transformador es una muestra de que el proceso de oxidación lleva mucho tiempo existiendo [15].

Tipos de fallas presentes en el aceite dieléctrico. - El 90% del deterioro de la celulosa es de origen térmico, la degradación térmica del aislamiento es función del tiempo, de la temperatura y de cuan seco está el aislamiento. Las elevadas temperaturas causan un envejecimiento acelerado de la celulosa empleada como aislamiento, reduciéndose la rigidez mecánica y eléctrica de la misma, produciéndose la de polimerización o destrucción del papel; otros efectos debidos a las elevadas temperaturas son la generación de agua, materiales ácidos y gases (CO₂, CO). Existen evidencias que muestran que, si se sobrecarga un transformador con temperaturas superiores a los 140°C en el punto más caliente, se formaran burbujas de gas, mismas que disminuyen la rigidez dieléctrica del aislamiento [15].

La detección de algunos tipos de fallas o eventos como por ejemplo arcos eléctricos en las guías; falsos contactos, descargas parciales, u otra y su localización constituían un problema anteriormente. Actualmente, la información obtenida de un sistema de adquisición de datos, con el monitoreo, permite detectar fallas tanto de rápido, como de lento desarrollo, lo que supera los métodos convencionales de las pruebas eléctricas con el equipo fuera de servicio, que no pueden detectar fallas de rápido desarrollo, por usar mediciones espaciadas en el tiempo [8].

En la gráfica 2.2 se muestra la relación que existe entre las distintas tasas de concentración de gases en porcentaje, en función del aumento de temperatura determinada por su tipo de falla. Esta gráfica es proporcionada por la IEEE en su guía para la interpretación de fallas del año 2019 [17], desarrollada sobre la base de una recopilación histórica de cientos de miles de transformadores de distintas partes del mundo con un diagnóstico comprobado [18].




Figura 5. Porcentaje relativo de concentraciones de gas disuelto en aceite mineral en función de la temperatura y el tipo de falla [17].

Tabla 1. Posibles diagnósticos a partir de los gases disueltos

Productos de la degradación	Diagnóstico posible
Presencia del acetileno.	Falla eléctrica
C ₂ H ₂ acompañado solamente de CH ₄ y de H ₂ .	Arco eléctrico de duración limitada en el aceite.
C ₂ H ₂ , CH ₄ e H ₂ , acompañados de CO y CO ₂	Este arco eléctrico compromete el aislamiento sólido.
C ₂ H ₂ , CH ₄ e H ₂ , sin CO ni CO ₂ , pero acompañados de C ₂ H ₆ , C ₃ H ₈ , C ₂ H ₄ y C ₃ H ₆	Descargas parciales fuertes o arcos eléctricos en el aceite.
C ₂ H ₂ , CH ₄ e H ₂ , sin CO ₂ acompañados de C ₂ H ₆ , C ₃ H ₈ , C ₂ H ₄ y C ₃ H ₆ y, además, se observa CO.	Las descargas parciales se producen en un aislamiento sólido. (Si las descargas parciales son realmente de gran magnitud, los hidrocarburos no saturados, predominan sobre los saturados) En el caso de pequeñas descargas parciales, estas son más erosionantes para el aislamiento sólido cuanto más grande es la relación CO/CO ₂ .
C ₂ H ₄ + CH ₄ + H ₂ + Hidrocarburos saturados (C ₂ H ₆ , C ₃ H ₈ , C ₃ H ₆).	Puntos Calientes en el aceite. <500°C predomina el CH ₄ . >500°C predomina el C ₂ H ₄ (a veces pequeñas cantidades de C ₂ H ₂)
C ₂ H ₄ + CH ₄ + H ₂ + Hidrocarburos saturados (C ₂ H ₆ , C ₃ H ₈ , C ₃ H ₆). + CO + CO ₂ .	>130°C predomina el CO ₂ .
Dióxido de carbono CO ₂ ; CO ₂ + CH ₄ ; CO ₂ + CO	Envejecimiento térmico normal del papel.

Predominio del H ₂ + Hidrocarburos saturados (C ₂ H ₆ , C ₃ H ₈ y C ₃ H ₆); CO + CO ₂ (CO/CO ₂ >0,1)	Pequeñas descargas parciales que erosionan por largo tiempo el aislamiento sólido (Papel impregnado)
H ₂	Pequeñas descargas parciales (Gasificación del aceite).
H ₂ + CH ₄	Primera manifestación de una falla eléctrica más grave.
N ₂ + O ₂	Introducción de aire (Si la proporción de O ₂ , N ₂ es similar a la del aire)

Fuente: [15]

Análisis de gases disueltos (DGA). - Existen varias técnicas para el mantenimiento y el diagnóstico de averías en transformadores de potencia en funcionamiento, entre ellas, el análisis de gases disueltos (DGA). El DGA es un método popular para diagnosticar e interpretar los diferentes tipos de averías en transformadores de potencia; para refinar las interpretaciones en el proceso de diagnóstico, actualmente se cuenta con técnicas como sistemas expertos y análisis de datos utilizando redes neuronales artificiales [19].




Figura 6. Diagrama conceptual de la aplicabilidad del DGA [19].

Es necesario determinar las condiciones en que se encuentra el aceite aislante mediante un análisis cromatográfico, el cual debe estar contemplado en el programa de mantenimiento preventivo anual del transformador; con el objetivo de recolectar información acerca de la cantidad de gases disueltos y análisis físico químicos. para las unidades observadas, estos análisis son efectuados por un laboratorio externo, con la periodicidad mencionada, excepto en una condición anormal [16].

El uso de análisis de gases disueltos en el aceite aislante para detectar fallas incipientes en los transformadores está basado en el fenómeno físico de rompimiento, tanto en las moléculas de los aceites aislantes como de los aislamientos de celulosa, al ser sometidos a esfuerzos térmicos y eléctricos excesivos, produciendo compuestos complejos y gases volátiles [20]. Para analizar los resultados de una prueba cromatográfica se necesita una vasta experiencia, ya que la mala interpretación de la misma puede conllevar a sacar un equipo de servicio cuando este aun no lo requiera o bien dejar en servicio un equipo que esté a punto de colapsar poniendo en riesgo la vida del sistema interconectado [21].

Existen dos maneras de representar los resultados de gases disueltos: A partir de las concentraciones individuales y por las relaciones entre gases, existen diferentes técnicas para evaluar la detección de una condición anormal, requiere de una evaluación de la concentración del gas generado y de la tendencia de generación [8]. La Cromatografía de Gases es una técnica que puede detectar fenómenos internos de disturbio como son: Arco, descargas parciales, sobrecarga excesiva, puntos calientes y sobrecalentamiento del aislamiento [22].

Los gases típicos generados por algunas fallas incipientes en transformadores de fuerza son: Hidrógeno (H_2), Oxígeno (O_2), Nitrógeno (N_2), Metano (CH_4) Monóxido de carbono (CO), Etano (C_2H_6), Dióxido de carbono (CO_2), Etileno (C_2H_4) y Acetileno (C_2H_2) [15]. El Hidrógeno, Metano, Monóxido de carbono, Etano, Etileno y Acetileno son gases combustibles. Cuando se detectan gases en cantidad suficiente como para suponer la existencia de una falla, es necesario conocer la severidad de ella, se determina en base a la tasa de crecimiento por día de cada gas en particular, o del total de gases disueltos en el aceite [8].

Procedimiento para obtener muestras para DGA. - El proceso para la detección de gases de falla comienza por la extracción de una muestra de aceite siguiendo las recomendaciones de ASTM D923, donde se indica que el procedimiento de muestreo debe garantizar siempre que las muestras se obtengan de forma segura, sin comprometer el nivel de aceite, evitando contaminar la muestra con aire e impidiendo que ingrese aire en el transformador [18].

En ciertas condiciones de fallas, algunas fracciones del aceite pueden contener gases disueltos en concentraciones más altas durante un periodo de tiempo en el día, antes de que se produzca la mezcla completa con la mayor parte del líquido aislante. Por esta razón, las muestras deben obtenerse en varios puntos del transformador y también obtener una muestra al día siguiente [18].

Métodos de interpretación del DGA. - Una vez que se hayan abordado los problemas de calidad y confirmación de los datos, se puede realizar la interpretación de los datos DGA. Los resultados de DGA anteriores deben utilizarse para caracterizar incrementos y tasas. Si se encuentran resultados anormales de DGA, se debe consultar cualquier información adicional disponible, como registros de prueba y mantenimiento, datos de carga, condiciones ambientales, etc., para obtener posibles pistas sobre el origen y la naturaleza de las anomalías. La comparación de datos DGA de unidades hermana; es decir, transformadores construidos con especificaciones similares, es útil para detectar resultados inusuales y revelar patrones comunes, que proporcionar una mejor comprensión de los datos [18].

Método de Relaciones de Rogers. - En 1978, Rogers observa que la concentración de cada gas varía con la temperatura de la avería, e introduce una nueva relación entre las concentraciones de los gases (Etileno y Acetileno) que requieren una temperatura más elevada para generarse [19]. Además, propone la utilización de tres relaciones entre gases. Las relaciones involucran los siguientes pares de gases: acetileno/etileno, metano/hidrógeno, y etileno/etano [20].

Tabla 2. Método de relaciones de Roger

Caso	C2H2/C2H4	CH4/H2	C2H4/C2H6	Diagnóstico de falla
0	< 0.1	0.1 to 1.0	< 1.0	Unidad normal
1	< 0.1	< 0.1	< 1.0	Descarga parcial de baja energía
2	0.1 to 3.0	0.1 to 1.0	> 3.0	Arco – Descarga de alta energía
3	< 0.1	0.1 to 1.0	1.0 to 3.0	Falla de baja temperatura
4	< 0.1	> 1.0	1.0 to 3.0	Falla térmica < 700 °C
5	< 0.1	> 1.0	> 3.0	Falla térmica > 700 °C

Fuente: [17]

Método de Relaciones de Doernenburg.- El método de relaciones de Doernenburg, tal y como es definido en el estándar IEEE C57.104-1991 usa cuatro relaciones de gases, a saber: metano/hidrógeno; acetileno/metano y etano/acetileno

con el propósito de diagnosticar descomposición térmica, descarga parcial o arqueo [20]. El valor de los gases en un primer momento debe superar la concentración de L1 a determinar si realmente hay un problema con la unidad y luego si hay suficiente generación de cada gas para la relación análisis que se aplica. La tabla 3 muestra los gases principales y su concentración L1 [23].

Tabla 3. Límite de concentraciones de gases disueltos

Key gas	Concentración L1 ($\mu\text{L/L}$ (ppm v/v))
Hidrogeno (H_2)	100
Metano (CH_4)	120
Monóxido de carbono (CO)	350
Acetileno (C_2H_2)	1
Etileno (C_2H_4)	50
Etano (C_2H_6)	65

Fuente: [17].

Tabla 4. Relación para gases claves según Doernenburg

Tipo de falla Diagnostico	Ratio 1 (R1) CH_4/H_2		Ratio 2 (R2) $\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$		Ratio 3 (R3) $\text{C}_2\text{H}_2/\text{CH}_4$		Ratio 4 (R4) $\text{C}_2\text{H}_6/\text{C}_2\text{H}_2$	
	Aceite Gas		Aceite Gas		Aceite Gas		Aceite Gas	
	Aceite	Gas	Aceite	Gas	Aceite	Gas	Aceite	Gas
1 - Descomposición térmica	>1.0	>0.1	<0.75	<1.0	<0.3	<0.1	>0.4	>0.2
2 - Descarga parcial (Corona)	<0.1	<0.01	No relevante		<0.3	<0.1	>0.4	>0.2
3 - Arco (alta intensidad PD)	>1.0 <1.0	>0.01 <0.1	>0.75	>1.0	>0.3	>0.1	<0.4	<0.2

Fuente: [17].

Método de Duval.- Michael Duval propuso nuevas versiones de su triángulo clásico, utilizando triángulo 1 para aceite mineral, triángulo 2 para cambiadores de toma en carga, triángulo 3 para aceites no minerales (esteres naturales o sintéticos) y, finalmente, triángulos 4 y 5 para averías de baja temperatura, donde la gasificación de dispersión de aceites puede interferir con el diagnóstico [19]. En la década de los 80, Michael Duval implementó su teoría a través de la presencia de seis gases para clasificar estados o averías en los transformadores, donde resalta que el H_2 se mezcla más rápido que un metal [17].

Se basa en las concentraciones de metano, etano y acetileno. Para cada gas se calcula la proporción de éste en la suma de los tres gases. La aplicación de un conjunto de reglas en que se considera cada par de proporciones de los gases por

separado permite la detección de problemas de tipo térmico, de descarga parcial o de arqueo. El uso de los tres gases utilizados en este método tiene su origen en un aparato de monitorear los gases disueltos en aceite utilizado en Hydro Quebec [20].

El método desarrollado por Duval propone la utilización de tres gases que representan en base a sus concentraciones un aumento del contenido de energía o temperatura tales que: Metano (CH_4) para fallas de baja energía o temperatura, etileno (C_2H_4) para fallas de alta temperatura y el acetileno (C_2H_2) para fallas de temperatura / energías muy altas / arco eléctrico. En cada lado del triángulo equilátero se grafican los porcentajes relativos de estos tres gases [17].




Figura 7. Triángulo de Duval 1 [17].

Método de Duval (triángulo 4 y 5) Los triángulos de Duval 4 y 5 se construyen y utilizan de la misma forma que el triángulo 1 pero empleando diferentes gases y zonas. El método del triángulo de Duval 4 usa H_2 , CH_4 y C_2H_6 y el triángulo de Duval 5 usa CH_4 , C_2H_4 y C_2H_6 [19].

Los triángulos de Duval 4 y 5 se pueden aplicar para obtener más información sobre los subtipos de fallas térmicas descritas en 2.1.4. Cuando se identifican fallas de baja energía o baja temperatura utilizando el triángulo de Duval 1 con PD, T1 o T2 como fallas se puede obtener más información con el triángulo de Duval 4. Cuando se han identificado fallas de temperatura muy alta con el triángulo de Duval 1 (T1 o T3), se puede obtener más información utilizando el triángulo de Duval 5 [18].




Figura 8. Triángulo de Duval 4 [17].




Figura 9. Triángulo de Duval 5 [17].

1.2.10 Algoritmos de clasificación. El algoritmo de clasificación es un programa informático desarrollado con el objetivo de agrupar tipos similares de objetos en una clase definida. Son modelos matemáticos que son capaces de identificar las similitudes en base a restricciones y discriminar los otros objetos que no cumplen las condiciones de clase. Los tres algoritmos de clasificación empleados en este estudio se enumeran a continuación [24].

Support Vector Machine. - La máquina de vectores de soporte (SVM) es un enfoque de aprendizaje que implementa el principio de minimización de riesgos estructurales (SRM). Básicamente, SVM encuentra un hiperplano que maximiza el margen entre dos o varias clase. SVM fue diseñado originalmente por Vapnik (1995) para clasificación binaria. Sin embargo, muchas aplicaciones tienen más de dos categorías. Hay dos formas de extender las SVM a problemas de clases múltiples: pueden encontrar investigaciones relacionadas, o construir varios clasificadores binarios [25].




Figura 10. Ejemplo de hiperplano y vectores de soporte [26].

SVM es un algoritmo de clasificación que se basa en el modelo de aprendizaje supervisado. Este algoritmo mapea los predictores en un plano n -dimensional y la discriminación entre las clases se identifica mediante un hiperplano. Un hiperplano es un plano que separa un espacio n -dimensional en dos subespacios. Cuando se proporcionan nuevos datos al algoritmo, identifica los datos como un punto en el espacio n -dimensional. SVM se esfuerza por maximizar el margen alrededor del hiperplano. El margen está definido por vectores a cada lado del hiperplano [24].

Support Vector Machine Multi - class. - Básicamente, hay dos tipos de enfoques para SVM multiclase. Uno está considerando todos los datos en una optimización. El otro es descomponer multiclase en una serie de SVM binarias, como "One Against All" (OVA), "One Against One" (OVO) y DTA. Aunque existen enfoques más sofisticados para SVM multiclase, extensos experimentos han demostrado que OVA, OVO y DTA se encuentran entre los métodos más adecuados para uso práctico [27]. Entre estos tres métodos, el algoritmo del árbol de decisión tiene buena comprensibilidad, la tasa de precisión es mayor, el costo de capacitación es menor, el costo de aprendizaje es normal, las muestras entrenadas repetidamente son menores [28].

Support Vector Machine DTA. - Como se muestra en la Figura 12, el SVM-DTA resuelve un problema de reconocimiento de patrones de clase N utilizando un árbol binario, en el que cada nodo toma una decisión binaria utilizando un SVM. La jerarquía de las subtarefas de decisión binaria debe diseñarse cuidadosamente antes del entrenamiento de cada clasificador SVM [29].




Figura 11. Máquina de soporte vectorial con arquitectura DTA [30]

Precisión de SVM. - Para obtener rendimientos de precisión más representativos, dividimos los grandes conjuntos de datos (Modis, SmallModis y Segment) en tres partes: la primera parte de datos para entrenamiento, la segunda como conjunto de validación para encontrar los núcleos y parámetro(s) correspondiente(s) y la última parte se utiliza como datos de prueba. Para los datos que tienen pocas muestras, utilizamos una validación cruzada de diez veces. Seleccionamos los mejores núcleos entre funciones de base lineales, polinómicas y radiales. Para los parámetros del núcleo polinomial (δ), limitamos nuestros experimentos de dos a cinco y para RBF (δ) de 2 – 3 a 25. Otra variable, que tiene un papel en la precisión de las SVM, es el parámetro de costo (C). Repetimos nuestro experimento para varios valores de C que van desde 28 hasta 212 e infinito [25].

Entrenamiento SVM. - A lo largo de la fase de entrenamiento, SVM toma una matriz de datos como datos de entrada y etiqueta cada una de las muestras como pertenecientes a una clase determinada (positiva) o no (negativa). SVM trata cada muestra en la matriz como una fila en un espacio de entrada o espacio de características de alta dimensión, donde el número de atributos identifica la dimensionalidad del espacio. El algoritmo de aprendizaje SVM determina el mejor hiperplano que separa cada muestra de entrenamiento positiva y negativa. La SVM entrenada se puede implementar para realizar predicciones sobre muestras de prueba (nuevas) en la clase [31].

Clasificación SVM. - Ahora que los parámetros y las características de datos óptimos para cada SVM del árbol se han establecido utilizando datos de entrenamiento, la clasificación se puede probar entrenando el clasificador SVM multiclase del árbol de decisión y probándolo en el conjunto de prueba. Esta validación cruzada general se repitió tres veces. Toda la base de datos se divide en pliegues determinados aleatoriamente. Cada pliegue se divide en entrenamiento y conjuntos de prueba. El proceso de clasificación se realiza varias veces en cada pliegue por robustez. Se calcula una matriz de confusión cada vez y se deriva una matriz de confusión general promediando todas las matrices de confusión [32].

Optimización de parámetros SVM. - El rendimiento de la clasificación de SVM se puede mejorar significativamente ajustando sus hiper parámetros. Un parámetro SVM relevante es el factor de penalización C, que determina el equilibrio entre la complejidad y la proporción de muestras no separables. Otra optimización crítica de SVM es la cuidadosa selección del kernel y sus parámetros. Seleccionamos, para cada SVM del dendrograma, el kernel con mejor rendimiento (es decir, kernel lineal: $k(x, y) = x^T y + c$, o una función de base radial RBF-kernel: de sobreajustar los datos, la identificación del mejor kernel y su $k(x, y) = \exp(x - y/22)$ [32]. El preprocesamiento de datos es otra técnica de minería de datos que ayuda a mejorar el rendimiento de los algoritmos. Para obtener resultados fieles, es necesario asegurarse de que los datos en bruto sean de buena calidad. El preprocesamiento de datos se ocupa de la transformación de los datos sin procesar mediante relaciones matemáticas que ayudan a extraer mejor la información [24].

1.3 Fundamentación Metodológica.

Se refiere al conjunto de procedimientos, métodos y técnicas para realizar la investigación de manera sistemática. Su importancia radica en que a través del estudio de las muestras y del análisis de los gráficos o estadísticos se logra que los resultados obtenidos tengan un grado máximo de exactitud y confiabilidad [10].

1.3.1 Tipo de investigación. - Para el desarrollo de este proyecto, el tipo de investigación que se utilizó fue de tipo bibliográfica, propositiva, tecnológica, y de campo las mismas que fueron aplicadas en el desarrollo del trabajo de grado.

Investigación bibliográfica. La investigación bibliográfica permitió recabar información para estudiar los parámetros de medición termográfica, parámetros eléctricos y químicos de las componentes del transformador, los procesos para desarrollar un plan de mantenimiento preventivo y realizar reportes de mantenimiento predictivo con el propósito de ampliar y profundizar el conocimiento de su naturaleza, con el apoyo principalmente en trabajos previos, información y datos divulgados por medios impresos, audiovisuales o electrónicos. La originalidad del estudio se reflejó en el enfoque, criterios, conceptualizaciones, reflexiones, conclusiones, recomendaciones y en general el pensamiento del autor.

Para conseguir los datos requeridos en la investigación se consultaron historiales, informes, reportes y otro tipo de publicaciones asociadas a las labores de mantenimiento predictivo y detección de anomalías incipientes. Así como también se consultaron manuales técnicos que permitieron establecer criterios para identificar los niveles de severidad de las anomalías y los parámetros críticos asociados con las mismas; a la par se consulto acerca de las normas de seguridad industrial las cuales fueron de obligatorio cumplimiento a la hora de realizar el análisis al aislamiento líquido del transformador de potencia.

Investigación tecnológica. Para el análisis del estado actual de cualquier transformador que es evaluado por la empresa SSEI.Ltd se emplea equipos de última tecnológica para medir los parámetros necesarios en aceite dieléctrico lo cual permite predecir el estado actual del equipo.

Investigación de campo. Para fortalecer la investigación de campo se tomó muy en cuenta los conocimientos y criterios vertidos por los técnicos de la empresa SSEI, cuyos testimonios fueron recopilados como parte del trabajo tratando de interpretar de la mejor manera la realidad existente en el diagnóstico de transformadores de potencia.

1.3.2 Técnicas de recolección de la información..- Para realizar una investigación con un sustento solido la información utilizada es muy importante, por ello se determinan las técnicas para la correcta adquisición de la información, ya sea vertida por los técnicos e ingenieros inmiscuidos en el tema eléctrico o por los reportes de equipos de prueba, dicha información se hace efectiva para tener una

idea clara de cómo realizar un análisis predictivo considerando todos los parámetros, estas técnicas entonces se constituyen en el pilar fundamental para el desarrollo del trabajo de grado.

Consulta a especialistas. Con la finalidad de disponer de información actualizada y confiable, se contó con la asesoría de especialistas en el tema tratado, para ello se realizaron consultas que permitieron aclarar dudas, las mismas que surgieron durante el desarrollo de la investigación; así como también se establecieron criterios de trabajo para emitir opiniones que atestiguaron el desarrollo eficaz del tema de investigación.

Observación directa. La observación directa se llevó a cabo de manera visual a los equipos que la empresa SSEI realizó mantenimiento predictivo y consistió en obtener información de las posibles causas de las anomalías encontradas haciendo énfasis en los componentes y elementos de los transformadores de potencia que fueron objetos de estudio en el presente trabajo.

Método deductivo. El método deductivo se aplicó en base a la construcción del marco teórico, mediante la elaboración de resúmenes y publicaciones de autores de quienes se les realizó las citas correspondientes para entender de mejor manera las causas de las anomalías en los sistemas eléctricos en base a un análisis general de la información.

Método de simulación. La simulación es una técnica que a través de modelos permite representar un evento cualquiera, a fin de investigarlo de manera detallada. La simulación como técnica aplicada a las investigaciones permite emplear modelos simplificados de un sistema, evento, proceso, situación y comportamiento, en estudio, sin necesidad de afectar el original. Ayuda a que el investigador construya descripciones cuando no puede tener acceso de forma directa al evento. Además, le permite examinar potenciales decisiones, así como también reducir el tiempo de prueba... La técnica de simulación permite también generar escenarios bajo condiciones posibles y probables, como predicción, formular propuestas a partir de tales predicciones y elegir cursos de acción más favorables.

Método orientado a objetos. Los métodos orientados a objetos reducen drásticamente los tiempos de desarrollo de los modelos en el sentido de que no será

preciso volver a construirlo desde la base, se puede utilizar una plantilla versátil y reutilizarla. El propósito de la simulación y modelización orientada a objetos es facilitar la posibilidad de crear complejos submodelos que maximicen su ciclo de vida y permitan su integración en otros modelos. Este método permite incorporar las técnicas anteriormente tratadas, tanto analíticas como continuas y discretas, ya que para modelizar los flujos intermedios entre los objetos; se puede recurrir a submodelos que utilicen dichas herramientas.

Software. Colaboratory, o "Colab" para abreviar, es un producto de Google Research. Permite a cualquier usuario escribir y ejecutar código arbitrario de Python en el navegador. Es especialmente adecuado para tareas de aprendizaje automático, análisis de datos y educación. Desde un punto de vista más técnico, Colab es un servicio de cuaderno alojado de Jupyter que no requiere configuración y que ofrece acceso sin coste adicional a recursos informáticos, como GPUs.

1.4 Conclusiones Capítulo I.

- El mantenimiento eléctrico es un área de la ingeniería en pleno desarrollo y específicamente el mantenimiento preventivo como primera etapa cuenta ahora con técnicas de diagnóstico muy diversas como la termografía y las pruebas eléctricas al aislamiento físico y líquido del transformador que permite detectar de manera integral el funcionamiento anormal del equipo y garantizar su tiempo de vida útil.
- Los algoritmos de aprendizaje supervisado se derivan del machine learning, son técnicas de clasificación basadas en los principios de la evolución de Darwin, permiten realizar una clasificación más óptima de la obtenida por los métodos tradicionales, además sujeta a restricciones de carácter económico, técnico o de confiabilidad, dependiendo de la necesidad.

CAPITULO II. PROPUESTA

2.1 Título de la propuesta.

Desarrollo de un código de programación basado en lenguaje Python para el procesamiento, análisis y diagnóstico de fallas mediante el reporte de análisis de gases disueltos.

2.2 Objetivo de la propuesta.

Desarrollar un código de programación basado en los triángulos 1, 4 y 5 del método de Duval, que detecte fallas incipientes de origen térmico y eléctrico al interior del transformador de potencia, con el fin de establecer el diagnóstico correcto y las acciones a tomar en el mantenimiento preventivo del equipo a través de análisis técnicos, económicos y bajo un árbol de decisiones, optimizando el tiempo de vida útil del equipo.

2.3 Justificación de la propuesta.

A partir del año 2013 con la propuesta del cambio de matriz productiva y por ende la matriz energética, el sector eléctrico ha sufrido una inyección de capital tanto de la empresa pública como privada, sufriendo así un crecimiento y mejoramiento sustancial, por un lado está el fortalecimiento estructural del anillo existente de 230kV, la creación de un nuevo anillo a nivel de 500kV, y por otro lado el desarrollo propio de la industria ecuatoriana principalmente del sector petrolero, la industria metalúrgica, de alimentos y el sector textil, entre otros, lo que ha significado la incorporación de una importante cantidad de transformadores de potencia a nivel de media y alta tensión, que dependiendo de su función y las cargas conectadas a ellos, estarán sujetos a esfuerzos eléctricos los mismos que los pueden ir deteriorándolos por dentro.

Existe mecanismos de protecciones para prevenir que el transformador falle, pero estos en su mayoría están orientados a fallas externas producidas en el entorno del sistema eléctrico, sin embargo existen fallas incipientes al interior del equipo, mismas que podrían provocar que salga de servicio parcial o totalmente, reduciendo de manera sustancial por un lado la calidad y continuidad del servicio de suministro eléctrico y por otro lado deteniendo uno o varios procesos industriales, en

cualquiera de los 2 casos la duración de este tiempo de interrupción implica pérdidas económicas y considerando que el transformador de potencia son equipos contruidos bajo demanda, estos tiempos se pueden prolongar.

Por todo lo mencionado anteriormente se vuelve necesario mejorar el análisis de este tipo de fallas, que si bien en el país se lo sigue realizando de manera tradicional mediante el Análisis de Gases Disueltos o DGA para su respectivo diagnóstico, con la incorporación de un código de programación que permita combinar técnicas heurísticas y lógica difusa para que por medio de un algoritmo de aprendizaje supervisado pueda clasificar y diagnosticar el tipo de fallas, señalando las acciones recomendadas a tomar para el plan de mantenimiento preventivo, que prevenga a tiempo posibles problemas a futuro y la degradación acelerada del sistema aislante del transformador, manteniendo su vida útil lo más cercana a la diseñada.

2.4 Fundamentación de la propuesta.

En el presente trabajo se desarrolla la metodología que consiste en el diseño de un código de programación que permita el diagnóstico correcto para el mantenimiento predictivo enfocado en la detección de fallas insipientes que se produzcan al interior del transformador de potencia, el código de programación se basa en el algoritmo de aprendizaje supervisado Support Vector Machine (SVM) para la clasificación y detección de fallas, las mismas que pueden ser de origen térmico o eléctrico, en base a los resultados del Análisis de Gases disueltos (DGA) usando los rangos establecidos en la norma IEEE c57.104 de Duval para la clasificación de fallas.

La primera fase se encarga de comparar los datos obtenidos del Análisis de Gases Disueltos al interior de la muestra de aceite, si los datos se encuentran dentro de los límites establecidos en la norma IEEE c57.104 se considera que el equipo se encuentra funcionando normalmente, sin embargo, si algún valor este por encima de lo establecido se procede al cálculo de porcentajes y la normalización de datos pasando de 3 dimensiones del triángulo 1, triángulo 4 y triángulo 5 de Duval a coordenadas rectangulares considerando únicamente 2 gases para facilitar el manejo y procesamiento de datos.

En la segunda fase se establecen los coeficientes para el diseño de la máquina vectorial de soporte SVM 1, SVM 2 y SVM 3, las mismas que analizarán las fallas

de origen eléctrico y subtipo de fallas de origen térmico de baja intensidad y térmico de alta intensidad respectivamente, cada maquina contara con datos históricos de los distintos tipos y subtipos de fallas para su entrenamiento, vectores de soporte que dividirán por áreas de falla que permitirán posteriormente la predicción de los valores de validación, los mismos que se presentaran con un porcentaje de aciertos y una matriz de resultados con todos los valores clasificados de acuerdo a su condición, finalmente se procede al diagnóstico del estado del transformador y la posible acción a tomar en el respectivo mantenimiento.

2.5 Desarrollo de la metodología

En esta sección se detalla la metodología general sobre el desarrollo del código de programación para la clasificación de fallas insipientes basados en el método de Duval de acuerdo con la norma IEEE C57.104™-2019 y posteriormente la metodología empleada para las acciones recomendadas para el mantenimiento preventivo en el transformador de potencia.

2.5.1 Estrategia metodológica




Figura 12. Diagrama de flujo de las fases de la metodología para el código de programación.

2.5.2 Procesamiento de datos DGA

El transformador eléctrico en su funcionamiento normal se encuentra bajo tensiones eléctricas, térmicas y mecánicas, por lo que se considera normal la degradación paulatina en el sistema de aislamiento tanto sólido como líquido de acuerdo principalmente a sus años de funcionamiento, cabe mencionar que el nivel de voltaje y la potencia del mismo no guardan mayor relación en este fenómeno, así que dichos valores no serán considerados para el diagnóstico, una de las técnicas más utilizadas para el diagnóstico de fallas en transformadores es el Análisis de Gases Disueltos (DGA), midiendo al interior del aceite la concentración en partículas por millón (ppm) del hidrógeno (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4), acetileno (C_2H_2), monóxido de carbono (CO) y dióxido de Carbono (CO_2), hay que considerar que los valores normales varían de acuerdo a la concentración de gases libres como el Oxígeno (O_2) y Nitrógeno (N_2).

Tabla 5. Porcentaje de concentración de gases en función del coeficiente O_2/N_2 y años en $\mu L/L$ (ppm)

	O_2/N_2 Ratio ≤ 0.2				O_2/N_2 Ratio > 0.2			
	Transformer Age in Years				Transformer Age in Years			
	UNK	1–9	10–30	>30	UNK	1–9	10–30	>30
Gas								
Hydrogen (H_2)	80	75		100	40		40	
Methane (CH_4)	90	45	90	110	20		20	
Ethane (C_2H_6)	90	30	90	150	15		15	
Ethylene (C_2H_4)	50	20	50	90	50	25		60
Acetylene (C_2H_2)	1		1		2		2	
Carbon monoxide (CO)	900		900		500		500	
Carbon dioxide (CO_2)	9000	5000	10000		5000	3500		5500

Fuente: [17].

En caso de que uno o varios gases se encuentren fuera de los valores mencionados en la tabla anterior se considera que el transformador podría estar siendo sometido a un mayor esfuerzo eléctrico, térmico o mecánico, reduciendo de manera acelerada su tiempo de vida útil, para identificar la naturaleza de la falla y el origen de la misma, se utilizara la metodología de Duval como técnica de procesamiento de

datos del DGA, la misma que históricamente ha presentado un mayor índice de aciertos en relación al diagnóstico y la condición real del equipo, que consiste en analizar mediante 3 triángulos las concentraciones relativas entre el metano (CH_4), etileno (C_2H_4), acetileno (C_2H_2) para fallas eléctricas e hidrogeno (H_2), metano (CH_4), etano (C_2H_6) y etileno (C_2H_4) para fallas de origen térmico de alta y baja intensidad.

Cálculo de porcentajes para gases del triángulo 1

$$\%C_2H_2 = \frac{C_2H_2}{C_2H_2 + C_2H_4 + CH_4}$$

$$\%C_2H_4 = \frac{C_2H_4}{C_2H_2 + C_2H_4 + CH_4}$$

$$\%CH_4 = \frac{CH_4}{C_2H_2 + C_2H_4 + CH_4}$$

Cálculo de porcentajes para gases del triángulo 4

$$\%H_2 = \frac{H_2}{H_2 + CH_4 + C_2H_6}$$

$$\%CH_4 = \frac{CH_4}{H_2 + CH_4 + C_2H_6}$$

$$\%C_2H_6 = \frac{C_2H_6}{H_2 + CH_4 + C_2H_6}$$

Cálculo de porcentajes para gases del triángulo 5

$$\%CH_4 = \frac{CH_4}{CH_4 + C_2H_4 + C_2H_6}$$

$$\%C_2H_4 = \frac{C_2H_4}{CH_4 + C_2H_4 + C_2H_6}$$

$$\%C_2H_6 = \frac{C_2H_6}{CH_4 + C_2H_4 + C_2H_6}$$

Los triángulos de Duval son equiláteros y tienen como ejes la concentración relativa de los gases entre 0 a 100 puntos, dentro de los cuales existen divisiones por áreas, el origen y el tipo de la falla se define de acuerdo al área en la que se sitúa el punto analizado, para facilitar la ubicación del punto en una interfaz gráfica es

conveniente convertir las coordenadas triangulares en rectangulares (x, y), considerando que las concentraciones relativas suma la unidad se pueden transformar los puntos por medio de la siguiente matriz:

$$V = U \cdot A^T$$

$$V = [x' \quad y' \quad 1] \cdot \begin{bmatrix} k & k \cdot \cos(60^\circ) & \Delta x \\ 0 & k \cdot \sin(60^\circ) & \Delta y \\ 0 & 0 & 1 \end{bmatrix}^T$$

Donde:

A es una matriz de transformación que considera ejes con ángulos de 60 grados, con una amplitud k y desplazados de Δx y Δy .

TD1 U es un vector fila de coordenadas triangulares $\%C_2H_4$ (x') y $\%CH_4$ (y').

V es un vector fila de coordenadas rectangulares $C_2H_2(x)$ y $CH_4(y)$.

TD2 U es un vector fila de coordenadas triangulares $\%CH_4$ (x') y $\%H_2$ (y').

V es un vector fila de coordenadas rectangulares $C_2H_6(x)$ y $H_2(y)$.

TD3 U es un vector fila de coordenadas triangulares $\%C_2H_4$ (x') y $\%CH_4$ (y').

V es un vector fila de coordenadas rectangulares $C_2H_6(x)$ y $CH_4(y)$.

2.5.3 Diagnostico con SVM1

Para la clasificación de fallas insipientes del transformador mediante SVM1 se utiliza los límites de las regiones establecidas en el triángulo de Duval 1, el cual consiste en utiliza tres gases correspondientes al contenido de energía o temperatura creciente de las fallas: metano (CH_4) para fallas de baja energía/temperatura, etileno (C_2H_4) para fallas de alta temperatura y acetileno (C_2H_2) para fallas de muy alta temperatura, energía o fallas de arco. Las fallas que principalmente analizaremos en esta máquina vectorial son de origen eléctrico, las cuales pueden ser descargas parciales o tipo corona (PD), descargas de baja energía (D1) y descargas de alta energía (D2), en el caso de las fallas T1, T2 y T3 que son de origen térmico cuentan con subcategorías de fallas, en tal virtud serán analizadas a profundidad en el SVM2 y SVM3.

Tabla 6. Límites de la zona de falla para el triángulo de Duval 1.

Gas% / Fault	%CH ₄	%C ₂ H ₄	%C ₂ H ₂
PD	≥ 98	—	—
T1	< 98	< 20	< 4
T2	—	≥ 20 and < 50	< 4
T3	—	≥ 50	< 15
	—	< 50	≥ 4 and < 13
DT	—	≥ 40 and < 50	≥ 13 and < 29
	—	≥ 50	≥ 15 and < 29
D1	—	< 23	≥ 13
	—	≥ 23	≥ 29
D2	—	≥ 23 and < 40	≥ 13 and < 29

Fuente: [17].

2.5.3.1 Selección de Kernel y numero de clases

La función de Kernel lineal para SVM es óptima en estudios que no superen decenas de miles de muestras y sobre todo que puedan ser separados de manera lineal como es el caso del Triángulo 1 de Duval, la función de decisión seleccionada para la clasificación multiclase es one vs one (OVO) que permitirá analizar por separado las áreas de las distintas fallas de origen eléctrico, térmico o fallas combinadas, para mejorar el índice de aciertos previo a la clasificación de las fallas se procede a dividir en subgrupos las áreas con mayor irregularidad geométrica como D2 y DT, dando un total de 9 clases entre fallas eléctricas y térmicas, la metodología para la definición del hiperplano y la división de las áreas para SVM1 viene dada en el diagrama de flujo de la figura 14.




Figura 13. Diagrama de flujo para clasificación de fallas con SVM1.

2.5.3.2 Conjunto de entrenamiento SVM1.

Normalmente al entrenar un modelo de SVM se utiliza la función `sklearn.model_selection.train_test_split`, que divide de manera aleatoria el conjunto de datos totales en 80% para entrenamiento y el 20% restante para probar el mismo, sin embargo para que la evaluación de este modelo sea lo más imparcial y considerando que al dejar al azar los datos de entrenamiento se pueden perder datos muy importantes de las franjas críticas que dividen las áreas de PD, D1, D2.1, D2.2, DT.1, DT.2, T1, T2 y T3, por lo cual como datos de entrenamiento se ha tomado 20 valores para cada área y sub área, por otro lado para el conjunto de prueba se usara 119 datos históricos [33] [34] [35].

Tabla 7. Valores rectangulares normalizados para entrenamiento de SVM1

C2H2 (x)	CH4 (y)	Estado	C2H2 (x)	CH4 (y)	Estado
35.972	18.691	1	56.300	75.659	5
19.277	12.521	0	71.978	48.535	6
48.612	31.273	1	75.316	42.535	7
10.218	7.300	0	54.140	77.915	5
47.475	27.118	1	70.759	50.407	6
59.091	15.746	1	66.053	48.352	4
28.777	17.445	0	53.321	76.190	5
36.769	13.920	1	61.425	48.195	4
14.941	17.691	0	71.361	24.732	7
56.404	2.812	1	59.786	51.726	4
46.448	15.270	1	59.438	66.055	6
28.354	32.212	0	57.754	69.799	5
48.693	36.792	1	73.221	46.163	6
39.157	21.911	1	46.340	76.220	4
9.746	7.444	0	64.683	32.816	3
63.699	62.876	6	53.129	81.024	5
54.965	69.098	4	55.279	75.543	5
41.457	15.328	1	59.311	67.212	6
66.786	57.529	6	44.755	20.591	1
50.714	30.929	1	43.310	18.853	1
68.663	45.741	4	42.784	19.106	1
85.188	23.323	7	59.091	15.746	1
85.698	21.900	7	6.825	8.310	0
88.348	19.025	7	53.192	27.639	1
78.999	26.699	7	59.234	15.994	1
84.256	24.947	7	36.320	13.660	1
66.977	44.308	4	80.025	33.068	7
81.290	31.024	7	82.849	29.391	7
81.197	32.569	7	83.122	28.990	7
86.095	18.674	7	63.821	38.724	2

81.197	32.569	7	55.185	7.056	1
78.616	36.649	7	50.000	72.168	4
72.553	47.353	6	71.205	49.100	6
76.876	39.945	7	73.470	42.418	6
83.261	25.892	7	56.395	73.512	5
77.938	35.305	7	56.395	73.512	5
76.220	33.444	7	58.333	43.301	2
93.453	10.220	7	59.616	63.287	6
75.200	42.774	7	85.417	18.042	7
78.185	37.785	7	64.436	60.378	6
73.938	41.843	6	85.749	20.919	7
80.646	32.867	7	74.493	43.594	6
84.849	21.994	7	74.254	43.947	6
77.643	38.296	7	54.639	77.972	5
73.126	46.548	6	93.843	3.274	7
86.146	22.133	7	69.678	50.286	6
75.048	41.816	7	76.758	39.580	7
72.263	47.996	6	75.642	42.069	7
78.320	37.542	7	79.231	33.309	7
65.585	59.531	6	55.319	73.704	5
89.184	9.615	7	84.469	25.793	7
67.919	55.553	6			

Fuente: Autor.

2.5.3.3 Vectores de soporte para SVM1.

Los vectores de soporte son un subconjunto de entrenamiento de la máquina de soporte vectorial, son puntos utilizados en función de las decisiones a tomar, estos a su vez optimizan el uso de la memoria y los recursos utilizados por el código, sirven como puntos de soporte limite que separan las áreas de acuerdo al número de clases seleccionadas, para el caso del triángulo de Duval 1 son 9 clases para los distintos tipos de fallas, mediante el conjunto de datos usados para el entrenamiento se obtiene un total de 47 vectores de soporte (VS) como se puede observar en la figura 15 de manera gráfica y sus respectivas coordenadas rectangulares

presentadas en la tabla 8, los mismos que son distribuidos de la siguiente manera: 3 para D1, 3 para D2.1, 6 para D2.2, 7 para DT.1, 7 para DT.2, 4 para T1, 9 para T2 y 8 para T3




Figura 14. Vectores de soporte para SVM1.

Tabla 8. Coordenadas rectangulares de los vectores de soporte para SVM1

C2H4vs (x')	%CH4vs (y')	Estado	C2H4vs (x')	%CH4vs (y')	Estado
43.500	71.880	0	71.500	40.703	4
52.995	55.434	0	68.500	35.507	4
21.990	1.732	0	59.000	69.282	5
25.990	1.732	1	58.000	67.550	5
46.995	38.114	1	52.600	76.903	5
68.000	1.732	1	50.800	80.021	5
48.995	41.578	2	59.400	66.511	6
54.995	51.970	2	59.600	66.857	6
58.895	45.215	2	60.000	67.550	6
61.495	40.712	2	72.700	42.782	6

59.095	36.555	2	72.500	42.435	6
55.495	30.320	2	67.100	51.788	6
72.000	1.732	3	64.400	56.465	6
69.100	6.755	3	61.700	61.141	6
66.200	11.778	3	59.000	65.818	6
57.500	26.847	3	85.000	3.464	7
58.500	28.579	3	81.900	8.833	7
62.500	35.507	3	75.700	19.572	7
82.000	1.732	3	72.600	24.942	7
63.900	43.474	4	69.500	30.311	7
59.300	51.442	4	70.700	32.389	7
54.700	59.409	4	71.900	34.468	7
50.100	67.377	4	75.500	40.703	7
48.500	80.540	4			

Fuente: Autor.

2.5.3.4 Precisión y matriz de confusión.

La precisión del modelo planteado para el triángulo 1 con SVC se mide entre los 50 elementos del conjunto de prueba y viene dada por el coeficiente de porcentaje entre las fallas clasificadas y el estado real del transformador mediante la función `predict(x)`, estos resultados se pueden apreciar de manera visual en la figura 16 y mediante la función `confusion_matrix()` se observa un resumen de resultados presentados en la matriz de confusión, la cual refleja en su diagonal principal los aciertos y los que están fuera de la diagonal reflejan un error en la detección de la falla.

$$confusion_matrix = \begin{bmatrix} D1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & D2.1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & D2.2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & DT.1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & DT.2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & T1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & T2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & T3 \end{bmatrix}$$




Figura 15. Áreas de falla para clasificación de SVM1.

2.5.3.5 Presentación de resultados

En la figura 17 se puede observar de manera visual los resultados obtenidos posterior a la clasificación de los datos de prueba, de acuerdo a la clase predicha mediante la tabla 9 se realiza el diagnóstico del tipo de falla, su origen y la gravedad de la misma, donde posteriormente se puede sugerir acciones recomendadas a tomar para el mantenimiento del transformador de potencia, sin embargo para las fallas que son de origen térmico, tanto T1, T2 y T3 se procede a clasificar el subtipo de falla por medio de la SVM2 y SVM3 utilizando las zonas definidas en el triángulo de Duval 4 y 5, respectivamente.

Tabla 9. Diagnostico sugerido de acuerdo al tipo de falla

Símbolo	Falla	Descripción	Clase
PD	Descargas Parciales	Descargas corona formando burbujas de gas y posible formación de lodos en el papel aislante.	8

D1	Descargas de baja energía	Descargas parciales tipo chispas, produciendo agujeros, pinchazos carbonizados en el papel. Arco de baja energía induciendo perforación carbonizada o la formación de partículas de carbón en el aceite. Originadas por malas conexiones, o diferencias de potencial. Descargas en el papel o aceite, flashovers que resultan en daño extensivo en el papel o gran formación de partículas de carbón en el aceite. Producidas por Cortocircuitos internos.	0
D2	Descargas de alta energía		1 y 2
DT	Fallas térmicas y eléctricas	Combinación de fallas térmicas y eléctricas.	3 y 4

Fuente: [17].




Figura 16. Ejemplo de clasificación de fallas con SVM1.

2.5.4 Diagnostico con SVM2

Para la clasificación de fallas insipientes del transformador mediante SVM2 se utiliza los límites de las regiones establecidas en el triángulo de Duval 4, el cual consiste en utiliza tres gases correspondientes al contenido de energía o temperatura creciente de las fallas: hidrogeno (H₂) para fallas sobre descargas parciales de baja energía, etano (C₂H₄) para fallas de sobrecalentamiento con o sin degradación del papel aislante y metano (CH₄) para fallas con presencia de gasificación o carbonización del papel. Las fallas que principalmente analizaremos en este segundo algoritmo son de origen térmico de baja y media intensidad, las cuales pueden ser: gasificación dispersa a temperaturas menores a 200 °C (S), posible carbonización del papel (C) y sobrecalentamiento menor a 250 °C sin carbonización del papel (O).

Tabla 10. Límites de la zona de falla para el triángulo de Duval 4

Gas% / Fault	%H ₂	%CH ₄	%C ₂ H ₆
PD	—	≥ 2 and < 15	< 1
	≥ 9	—	≥ 30 and < 46
	≥ 15	—	≥ 24 and < 30
S	—	< 36	≥ 1 and < 24
	—	< 36 and ≥ 15	< 1
	—	< 2	< 1
O	< 9	—	≥ 30
	—	≥ 36	≥ 24
C	< 15	—	≥ 24 and < 30
ND	≥ 9	—	≥ 46

Fuente: [17]

2.5.4.1 Selección de Kernel y numero de clases

La función de Kernel lineal para SVM es óptima en estudios que no superen decenas de miles de muestras y sobre todo que puedan ser separados de manera lineal como es el caso del Triángulo 4 de Duval, la función de decisión seleccionada para la clasificación multiclase es one vs one (OVO) que permitirá analizar por separado las áreas de las distintas fallas de origen térmico de baja y media intensidad, para mejorar el índice de aciertos previo a la clasificación de las fallas se procede a

dividir en subgrupos las áreas con mayor irregularidad geométrica como S, dando un total de 6 clases entre fallas eléctricas y térmicas, la metodología para la definición del hiperplano y la división de las áreas SVM2 se puede observar en el diagrama de la figura .




Figura 17. Diagrama de flujo para clasificación de fallas con SVM2.

2.5.4.2 Conjunto de entrenamiento para SVM2

Normalmente al entrenar un modelo de SVM se utiliza la función `sklearn.model_selection.train_test_split`, que divide de manera aleatoria el conjunto de datos totales en 80% para entrenamiento y el 20% restante para probar el mismo, sin embargo para que la evaluación de este modelo sea lo más imparcial y considerando que al dejar al azar los datos de entrenamiento se pueden perder datos muy importantes de las franjas críticas que dividen las áreas de ND, S, O y C, por lo cual como datos de entrenamiento se ha tomado 15 valores para cada área y sub

área, por otro lado para el conjunto de prueba se usaran los valores clasificados como T1 y T2 de los datos de prueba de SVM1.

Tabla 11. Valores rectangulares normalizados para entrenamiento de SVM2

C2H6 (x)	H2 (y)	Estado
51.289	76.379	4
51.743	80.102	4
82.550	10.772	2
71.924	25.516	2
67.106	10.045	2
84.824	5.113	2
83.837	15.594	2
61.441	9.020	3
33.007	3.677	0
55.227	6.034	0
87.737	10.610	2
70.571	17.847	2
62.250	65.366	4
51.721	79.702	4
53.221	77.823	4
57.655	67.144	4
53.153	79.729	4
53.019	77.241	4
52.088	79.692	4
64.623	42.757	2
7.143	2.133	0
50.676	76.391	4
50.676	76.391	4
45.748	74.412	4
54.595	1.872	0
32.372	28.497	1
23.655	3.700	0
72.831	32.387	2
65.095	14.706	2
52.041	19.441	3

Fuente: Autor.

2.5.4.3 Vectores de soporte para SVM2

Los vectores de soporte son un subconjunto de entrenamiento de la máquina de soporte vectorial, son puntos utilizados en función de las decisiones a tomar, estos a su vez optimizan el uso de la memoria y los recursos utilizados por el código, sirven como puntos de soporte limite que separan las áreas de acuerdo al número de clases seleccionadas, para el caso del triángulo de Duval 4 son 5 clases para los distintos tipos de fallas, mediante el conjunto de datos usados para el entrenamiento se obtiene un total de 31 vectores de soporte (VS) como se puede observar en la figura 19 de manera gráfica y sus respectivas coordenadas rectangulares presentadas en la tabla 12, los mismos que son distribuidos de la siguiente manera: 4 para O, 4 para ND, 6 para C, 10 para S.1 y 7 para S.2.




Figura 18. Vectores de soporte para SVM2.

Tabla 12. Coordenadas rectangulares de los vectores de soporte para SVM2

C2H6vs (x')	%H2vs (y')	Estado	C2H6vs (x')	%H2vs (y')	Estado
5.000	6.928	0	36.500	32.043	3
65.000	6.928	0	50.000	8.660	3
68.200	1.386	0	55.600	8.660	3
69.000	0.000	0	64.000	8.660	3
6.000	8.660	1	58.100	18.879	3
48.000	8.660	1	52.200	29.098	3
35.100	31.004	1	40.400	49.537	3
26.500	45.899	1	34.500	59.756	3
71.000	0.000	2	35.500	61.488	4
67.600	5.889	2	39.000	55.426	4
60.800	17.667	2	42.500	49.363	4
57.400	23.556	2	49.500	37.239	4
54.000	29.445	2	53.000	31.177	4
68.000	53.694	2	64.200	50.576	4
27.500	47.631	3	67.000	55.426	4
32.000	39.837	3			

Fuente: Autor.

2.5.4.4 Precisión y matriz de confusión.

La precisión del modelo planteado para el triángulo 4 con SVM2 se mide entre los 30 elementos que presentan fallas de tipo T1 y T2 del conjunto de pruebas de SVM1 y viene dada por el coeficiente de porcentaje entre las fallas clasificadas y el estado real del transformador mediante la función predict(x), estos resultados se pueden apreciar de manera visual en la figura 20 y mediante la función `confusion_matrix()` se observa un resumen de resultados presentados en la matriz de confusión, la cual refleja en su diagonal principal los aciertos y los que están fuera de la diagonal reflejan un error en la detección de la falla.

$$confusion_matrix = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & ND & 0 & 0 & 0 \\ 0 & 0 & C & 0 & 0 \\ 0 & 0 & 0 & S.1 & 0 \\ 0 & 0 & 0 & 0 & S.2 \end{bmatrix}$$




Figura 19. Áreas de falla para clasificación de SVM2.

2.5.4.5 Presentación de resultados

En la figura 21 se puede observar de manera visual los resultados obtenidos posterior a la clasificación de los datos de prueba, de acuerdo a la clase predicha mediante la tabla 13 se realiza el diagnóstico del tipo de falla, su origen y la gravedad de la misma, donde posteriormente se puede sugerir acciones recomendadas a tomar para el mantenimiento del transformador de potencia, sin embargo para las fallas que son de origen térmico de media y alta intensidad tipo T2 y T3 se procede a clasificar el subtipo de fallas por medio de SVM3 utilizando las zonas definidas en el triángulo de Duval 5.

Tabla 13. Diagnostico sugerido de acuerdo al tipo de falla para SVM2

Símbolo	Falla	Descripción	Clase
O	Falla térmica de baja intensidad	Sobrecalentamiento < 250 °C sin carbonización del papel.	0
ND	No definida	Se trata de un tipo de falla que tiene que ser comprobada con pruebas eléctricas.	1
C	Falla térmica de media intensidad	Posible carbonización del papel.	2
S	Falla térmica de baja intensidad	Gasificación dispersa a temperaturas < 200 °C	3 y 4

Fuente: [17].




Figura 20. Ejemplo de clasificación de fallas con SVM2.

2.5.5 Diagnostico con SVM3

Para la clasificación de fallas insipientes del transformador mediante SVM3 se utiliza los límites de las regiones establecidas en el triángulo de Duval 5, el cual consiste en utilizar tres gases correspondientes al contenido de energía o temperatura creciente de las fallas: etano (C_2H_6) que se crea a partir del calentamiento del aceite o del papel, etano (C_2H_4) para fallas de sobrecalentamiento con o sin degradación del papel aislante y metano (CH_4) para fallas con presencia de gasificación o carbonización del papel. Las fallas que principalmente analizaremos en este tercer algoritmo son de origen térmico de media y alta intensidad, las cuales pueden ser: gasificación dispersa a temperaturas menores a $200\text{ }^{\circ}\text{C}$ (S), posible carbonización del papel (C), sobrecalentamiento menor a $250\text{ }^{\circ}\text{C}$ sin carbonización del papel (O), fallas térmicas de media intensidad (T2) y fallas térmicas de alta intensidad (T3).

Tabla 14. Límites de la zona de falla para el triángulo de Duval 5

Gas% / Fault	%CH ₄	% C ₂ H ₄	%C ₂ H ₆
PD	—	< 1	≥ 2 and < 14
	—	≥ 1 and < 10	≥ 2 and < 14
O	—	< 1	< 2
	—	< 10	≥ 54
S	—	< 10	≥ 14 and < 54
T2	—	≥ 10 and < 35	< 12
	—	≥ 35	< 12
T3	—	≥ 50	≥ 12 and < 14
	—	≥ 70	≥ 14
	—	≥ 35	≥ 30
C	—	≥ 10 and < 50	≥ 12 and < 14
	—	≥ 10 and < 70	≥ 14 and < 30
ND	—	≥ 10 and < 35	≥ 30

Fuente: [17].

2.5.5.1 Selección de Kernel y numero de clases

La función de Kernel lineal para SVM es óptima en estudios que no superen decenas de miles de muestras y sobre todo que puedan ser separados de manera lineal como es el caso del Triángulo 5 de Duval, la función de decisión seleccionada para la clasificación multiclase es one vs one (OVO) que permitirá analizar por separado las áreas de las distintas fallas de origen térmico de media y alta intensidad, dando un total de 8 clases entre los distintos tipos de fallas térmicas, la metodología para la definición del hiperplano y la división de las áreas SVM3 se puede observar en el diagrama de la figura 22.




Figura 21. Diagrama de flujo para clasificación de fallas con SVM3.

2.5.5.2 Conjunto de entrenamiento SVM3

Normalmente al entrenar un modelo de SVM se utiliza la función `sklearn.model_selection.train_test_split`, que divide de manera aleatoria el conjunto de datos totales en 80% para entrenamiento y el 20% restante para probar el mismo, sin embargo para que la evaluación de este modelo sea lo más imparcial y considerando que al dejar al azar los datos de entrenamiento se pueden perder datos muy importantes de las franjas críticas que dividen las áreas de O, S, T2, T3, C y ND por lo cual como datos de entrenamiento se ha tomado 15 valores para cada

área y sub área, por otro lado para el conjunto de prueba se usaran los valores clasificados como T2 y T3 de los datos de prueba de SVM1.

Tabla 15. Valores rectangulares normalizados para entrenamiento de SVM3

C2H6 (x)	CH4 (y)	Estado	C2H6 (x)	CH4 (y)	Estado
43.459	42.897	3	76.527	36.683	7
53.735	46.287	5	61.563	55.881	6
81.547	22.326	7	86.270	9.301	7
82.881	21.180	7	49.203	40.245	5
77.084	16.599	7	49.736	33.537	3
75.368	25.472	7	56.283	31.786	5
75.887	22.468	7	59.797	42.598	5
67.972	25.941	5	46.499	51.675	5
70.371	28.226	7	66.581	41.976	7
81.268	17.627	7	48.455	54.909	5
70.371	28.226	7	71.853	29.692	7
70.487	32.860	7	66.545	23.607	5
67.217	43.871	7	73.655	25.688	7
70.822	36.800	7	62.062	42.796	7
78.323	24.356	7	8.571	4.948	0
75.406	34.159	7	15.196	16.131	0
75.000	32.909	7	7.977	1.685	0
84.365	9.226	7	41.032	38.447	3
66.056	37.573	7	77.851	18.992	7
66.993	32.375	5	28.489	16.672	3
67.604	38.258	7	27.038	16.002	3
76.148	31.033	7	96.072	3.352	7
69.834	18.103	5	55.385	39.971	5
69.908	34.481	7	28.192	14.537	3
59.089	37.613	5	64.497	35.871	5
68.201	17.522	5	62.048	26.085	5
53.236	29.662	5	31.707	42.245	1
66.756	44.339	7	78.111	23.852	7

Fuente: Autor.

2.5.5.3 Vectores de soporte para SVM3

Los vectores de soporte son un subconjunto de entrenamiento de la máquina de soporte vectorial, son puntos utilizados en función de las decisiones a tomar, estos a su vez optimizan el uso de la memoria y los recursos utilizados por el código, sirven como puntos de soporte limite que separan las áreas de acuerdo al número de clases seleccionadas, para el caso del triángulo de Duval 5 son 8 clases para los distintos tipos de fallas, mediante el conjunto de datos usados para el entrenamiento se obtiene un total de 58 vectores de soporte (VS) como se puede observar en la figura 23 de manera gráfica y sus respectivas coordenadas rectangulares presentadas en la tabla 16, los mismos que son distribuidos de la siguiente manera: 4 para O.1, 6 para S, 5 para O.2, 9 para ND, 9 para T3.1, 9 para C, 10 para T2 y 6 para T3.2.




Figura 22. Vectores de soporte para SVM3.

Tabla 16. Coordenadas rectangulares de los vectores de soporte para SVM3

C2H6vs (x')	%CH4vs (y')	Estado	C2H6vs (x')	%CH4vs (y')	Estado
9.500	0.866	0	52.500	28.579	4
27.000	31.177	0	59.100	17.147	4
26.100	32.736	0	65.700	5.716	4
22.500	38.971	0	69.000	0.000	4
24.400	39.144	1	71.000	0.000	5
26.200	36.027	1	65.000	10.392	5
28.000	32.909	1	59.000	20.785	5
47.000	65.818	1	53.000	31.177	5
47.000	65.818	1	47.000	41.569	5
42.500	73.612	1	41.000	51.962	5
44.400	73.785	2	45.200	59.236	5
46.200	70.668	2	48.000	64.086	5
47.100	69.109	2	85.000	0.000	5
48.000	67.550	2	55.000	76.210	6
54.000	77.942	2	53.800	74.132	6
11.000	0.000	3	50.200	67.896	6
22.600	20.092	3	49.000	65.818	6
28.400	30.138	3	51.300	61.834	6
34.200	40.184	3	53.600	57.850	6
40.000	50.229	3	55.900	53.867	6
40.000	50.229	3	58.200	49.883	6
51.500	30.311	3	60.500	45.899	6
44.900	18.879	3	67.000	57.158	6
35.000	1.732	3	67.500	54.560	7
36.000	0.000	4	62.700	46.246	7
39.300	5.716	4	61.500	44.167	7
42.600	11.432	4	71.300	27.193	7
45.900	17.147	4	81.100	10.219	7
49.200	22.863	4	86.000	1.732	7

Fuente: Autor.

2.5.5.4 Precisión y matriz de confusión

La precisión del modelo planteado para el triángulo 5 con SVM3 se mide entre los 56 elementos que presentan fallas de tipo T2 y T3 del conjunto de pruebas de SVM1 y viene dada por el coeficiente de porcentaje entre las fallas clasificadas y el estado real del transformador mediante la función $\text{predict}(x)$, estos resultados se pueden apreciar de manera visual en la figura 24 y mediante la función $\text{confusion_matrix}()$ se observa un resumen de resultados presentados en la matriz de confusión, la cual refleja en su diagonal principal los aciertos y los que están fuera de la diagonal reflejan un error en la detección de la falla.

$$\text{confusion_matrix} = \begin{bmatrix} 0.1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & S & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & ND & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & T3.1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & C & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & T2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & T3.2 \end{bmatrix}$$




Figura 23. Áreas de falla para clasificación de SVM3.

2.5.5.5 Presentación de resultados de SVM3

En la figura 25 se puede observar de manera visual los resultados obtenidos posterior a la clasificación de los datos de prueba, de acuerdo a la clase predicha mediante la tabla 17 se realiza el diagnóstico del tipo de falla, su origen y la gravedad de la misma, donde posteriormente se puede sugerir acciones recomendadas a tomar para el mantenimiento del transformador de potencia, con el procesamiento de información en la SVM3 finaliza el código analizando todos los tipos y sub tipos de fallas de origen eléctrico y térmico al interior de transformadores de potencia.

Tabla 17. Diagnostico sugerido de acuerdo al tipo de falla para SVM3

Símbolo	Falla	Descripción	Clase
O	Falla térmica de baja intensidad	Sobrecalentamiento < 250 °C sin carbonización del papel.	0 y 2
ND	No definida	Se trata de un tipo de falla que tiene que ser comprobada con pruebas eléctricas.	3
C	Falla térmica de media intensidad	Posible carbonización del papel.	5
S	Falla térmica de baja intensidad	Gasificación dispersa a temperaturas < 200 °C	1
T2	Falla térmica de media intensidad	Falla térmica de media intensidad entre 300 °C y 700 °C que requiere ser comprobada con pruebas eléctricas complementarias para su diagnóstico.	6
T3	Falla térmica de alta intensidad	Falla térmica de media intensidad entre 300 °C y 700 °C que requiere ser comprobada con pruebas eléctricas complementarias para su diagnóstico.	4 y 7

Fuente: [17].




Figura 24. Ejemplo de clasificación de fallas con SVM3.

2.5.6 Acciones recomendadas de acuerdo al diagnóstico.

Descargas Disruptivas

Descargas eléctricas donde la corriente logra atravesar el aislante. Dependiendo de la cantidad de energía contenida en la descarga y el daño observado en el equipo, se definen como de alta o baja energía.

Descarga de Baja Potencia (D1):

Descargas a través del aceite en puntos de diferente potencial, descargas de baja energía entre: abrazaderas; bujes y tanque; alta tensión y tierra dentro de los devanados, en las paredes del tanque.

Causas: Pérdida de rigidez dieléctrica, humedad y contaminación que acelera el proceso de degradación del papel, el aceite o la cerámica.

Consecuencias: Perforaciones significativas en el papel, surcos en la superficie de los bloques de madera, cartón prensado o espaciadores de devanados y partículas de carbón en el aceite.

Descarga de Alta Potencia (D2).

Arqueo de alta energía, cortocircuitos: entre baja tensión y tierra, conectores, devanados, bujes y tanque, barras de cobre y tanque, bobinados y núcleo, conductos del aceite, torretas, pernos aislados del núcleo, y anillos metálicos del bastidor.

Causas: Pérdida de rigidez dieléctrica, humedad y contaminación que acelera el proceso de degradación del papel y el aceite, o descargas atmosféricas.

Consecuencias: Excesivo daño y carbonización del papel, fusión de partes metálicas y gran formación de partículas de carbono en el aceite.

Fallas Térmicas Alto crecimiento de la temperatura en el transformador.

Gasificación Inesperada o Stray Gassing.

La formación de gases de aceites minerales aislantes calentados a temperaturas relativamente bajas (90 ° a 200 ° C) "y sin la influencia de otros materiales provenientes de aparatos eléctricos o estrés eléctrico.

Causas: Algunos informes previos han implicado el proceso de refinado, específicamente hidrotratamiento severo, mientras que otros informes han implicado aditivos.

Consecuencias: Problemas potenciales con el Análisis DGA.

Falla de Baja Temperatura menor a 300°C (T1).

Causas: Sobrecarga del transformador en situaciones de emergencia, elemento que bloquea los ductos de flujo del aceite, enfriamiento deficiente.

Consecuencias: Oscurecimiento del papel.

Falla de Media Temperatura entre 300°C y 700°C (T2).

Causas: Corrientes de circulación entre abrazaderas y pernos de sujeción, abrazaderas y laminaciones, cableado de tierra, cables defectuosos o abrazaderas en

escudos magnéticos; contactos internos defectuosos o entre barras de aluminio y conexiones con los bujes que generan puntos calientes.

Consecuencias: Aislamiento desgastado entre conductores paralelos adyacentes en los devanados, carbonización del papel.

Falla de Alta Temperatura mayor a 700°C (T3).

Causas: Excesiva circulación de corriente en partes metálicas, tanque y núcleo (corrientes de Eddy) como resultado un considerable flujo de dispersión del núcleo y cortocircuitos en laminaciones del núcleo.

Consecuencias: Gran formación de partículas de carbono en el aceite, coloración del metal (800°C) o fusión de partes metálicas (>1000°C). Aunque los daños ocasionados por fallas eléctricas o térmicas son parecidos y en servicio unas pueden ser causa de las otras y viceversa, se los puede diferenciar por los surcos o caminos presentes en el aislamiento como evidencia única de una descarga o por gases específicos que se forman a partir de una falla u otra.




Figura 25. Árbol de decisiones para fallas eléctricas




Figura 26. Árbol de decisiones para fallas eléctricas.

2.6 Conclusiones

- La base de datos obtenida para el entrenamiento de la SVM1, SVM2 y SVM3, consta de 119 casos reales con los valores en parte por millón (ppm) del Análisis de Gases Disueltos (DGA) de todas las muestras, los mismos que cuentan con un diagnóstico real de los distintos tipos de fallas, tanto eléctricas como térmicas, esto permite contar con un nivel alto de confiabilidad en los diagnósticos obtenidos por el algoritmo.
- Los datos utilizados en el método de Duval consisten en coordenadas triangulares, para procesar esta información mediante la función lineal del kernel se aplica una transformación matemática obteniendo como resultado coordenadas rectangulares, lo que permite optimizar el tiempo del procesamiento de los datos y a la vez contar con una representación gráfica de los resultados más sencilla.
- Las máquinas de soporte vectorial son algoritmos de aprendizaje supervisado, que una vez entrenada con la base de datos obtenida será probada y validada con datos diferentes a los ya usados, para comprobar su nivel de precisión en el diagnóstico de fallas insipientes al interior del transformador de potencia.
- Los resultados obtenidos del estado actual del transformador se presentan de 3 maneras:
 - Gráfica en el área del triángulo de Duval y su respectivo marcador de acuerdo al tipo de falla.
 - El porcentaje de aciertos de acuerdo a la clasificación de la SVM y la condición real del equipo.
 - La matriz con las coordenadas rectangulares normalizadas y el estado clasificado por la SVM.

CAPITULO III APLICACIÓN Y VALIDACIÓN DE LA PROPUESTA

3.1 Análisis de resultados.

El presente capítulo muestra los resultados obtenidos al aplicar la metodología propuesta, desde el procesamiento de datos, normalización, análisis y diagnóstico mediante las máquinas de soporte vectorial (SVM) 1, 2 y 3 que han sido entrenada previamente con los datos históricos del Análisis de Gases Disueltos (DGA), mediante los cuales se obtendrá el diagnóstico del estado actual de los transformadores.

Selección de datos

Cabe mencionar que las máquinas de soporte vectorial (SVM) cuentan con 3 etapas, las cuales son: entrenamiento, prueba y validación, las 2 primeras han sido abordadas en el Capítulo II, para el caso de la validación se utilizará valores históricos de análisis de gases disueltos diferentes a los datos utilizados para las 2 primeras etapas, los mismos que han sido recopilados de diferentes artículos científicos como [36], [37] y [33] con sus respectivos estados de falla. Los niveles de voltaje y potencia del transformador no son considerados debido que los métodos de diagnóstico no consideran dichos valores y por lo tanto la metodología puede ser aplicada a cualquier transformador de potencia.

Tabla 18. Datos obtenidos para validación.

H2	CH4	C2H6	C2H4	C2H2	Diagnostico	Estado
24	13	43	5	319	Descarga de baja energía	0
127	24	32	0	81	Descarga de baja energía	0
9474	4066	6552	353	12997	Descarga de baja energía	0
441	207	224	43	261	Descarga de baja energía	0
212	38	47	15	78	Descarga de baja energía	0
800	1393	2817	304	3000	Descarga de baja energía	0
4906	8784	9924	1404	9671	Descarga de baja energía	0
858	1324	2793	208	7672	Descarga de baja energía	0
274	27	33	5	97	Descarga de baja energía	0
1249	370	606	56	1371	Descarga de baja energía	0
307	22	33	2	109	Descarga de baja energía	0

127	107	154	11	224	Descarga de baja energía	0
1076	95	71	4	231	Descarga de baja energía	0
240	20	28	5	96	Descarga de baja energía	0
160	10	1	3	1	Descarga de alta energía	4
199	770	1508	217	72	Falla térmica	4
33	79	215	30	5	Falla térmica	4
60	144	449	67	9	Falla térmica	4
16	87	395	75	30	Falla térmica	5
416	695	867	74	0	Falla térmica	5
244	754	1281	172	27	Falla térmica	5
266	584	862	328	1	Falla térmica	6
65	61	143	16	3	Falla térmica	6
425	17424	37043	7299	158	Falla térmica	6
117	167	481	48	7	Falla térmica	6
137	369	1242	144	16	Falla térmica	6
2004	9739	5113	2750	0	Falla térmica	6
231	3997	5584	1726	0	Falla térmica	6
507	1053	1440	297	17	Falla térmica	6
80	619	2480	326	0	Falla térmica	6
345	112.3	27.5	51.5	58.8	Descarga de baja energía	0
127	107	11	154	224	Descarga de alta energía	1
60	40	6.9	110	70	Descarga de alta energía	1
200	48	14	117	131	Descarga de alta energía	1
32.4	5.5	1.4	12.6	13.2	Descarga de alta energía	1
300	490	180	360	95	Falla térmica	4
181	262	41	28	0	Falla térmica	5
980	73	58	12	0	Falla térmica	5
160	130	33	96	0	Falla térmica	6
95	110	160	50	0	Falla térmica	6
27	90	42	63	0.2	Falla térmica	6
650	53	34	20	0	Falla térmica	6
565	53	34	47	0	Falla térmica	6
200	700	250	740	1	Falla térmica	7

173	334	172	812.5	37.7	Falla térmica	7
220	340	42	480	14	Falla térmica	7
170	320	53	520	3.2	Falla térmica	7
56	286	96	928	7	Falla térmica	7
78	161	86	353	10	Falla térmica	7
176.0	206.0	47.7	75.7	68.7	Descarga de baja energía	0
35.0	25.0	0.0	23.0	22.0	Descarga de baja energía	0
293.0	50.0	13.0	115.0	120.0	Descarga de alta energía	1
443.0	85.0	9.5	103.0	174.0	Descarga de alta energía	1
160.0	90.0	27.0	17.0	5.0	Descarga de baja energía	4
980.0	73.0	58.0	12.0	0.0	Descarga de baja energía	4
565.0	93.0	34.0	47.0	0.0	Descarga de baja energía	4
150.0	53.0	34.0	20.0	0.0	Descarga de baja energía	4
766.0	993.0	116.0	665.0	4.0	Falla térmica	6
120.0	120.0	33.0	84.0	0.6	Falla térmica	6
0.0	434.0	226.0	387.0	0.0	Falla térmica	6
86.0	110.0	18.0	92.0	7.4	Falla térmica	6
73.0	520.0	140.0	1200.0	6.0	Falla térmica	7
42.0	97.0	157.0	600.0	0.0	Falla térmica	7
16.0	237.0	92.0	470.0	0.0	Falla térmica	7
15.0	125.0	29.0	574.0	7.0	Falla térmica	7
5.0	217.0	69.0	523.0	6.0	Falla térmica	7
2844.0	8517.0	4422.0	10196.0	39.0	Falla térmica	7
117.0	357.0	92.0	468.0	4.0	Falla térmica	7
80.0	153.0	42.0	276.0	18.0	Falla térmica	7
8.0	631.0	254.0	2020.0	39.0	Falla térmica	7

Fuente: [36] [37] [33].

Normalización y procesamiento de datos

Las máquinas de soporte vectorial (SVM) cuando utilizan la función lineal de kernel son más eficientes al trabajar con coordenadas rectangulares para poder encontrar los hiperplanos óptimos, que posteriormente serán las clases a clasificar como fallas.

A continuación, se procede a tomar como ejemplo una falla de origen térmico para realizar la transformación de los valores obtenidos en el DGA en valores de entrenamiento para la SVM1, SVM2 y SVM3 respectivamente.

$$Dato_n = H_2, CH_4, C_2H_6, C_2H_4, C_2H_2$$

Datos normalizados para SVM1

$$\%C_2H_4 = \frac{C_2H_4}{C_2H_2 + C_2H_4 + CH_4}$$

$$\%CH_4 = \frac{CH_4}{C_2H_2 + C_2H_4 + CH_4}$$

$$\%C_2H_2 = \frac{C_2H_2}{C_2H_2 + C_2H_4 + CH_4}$$

$$V_{SVM1} = U_{SVM1} \cdot A^T$$

$$V_{SVM1} = [\%C_2H_4 \quad \%CH_4 \quad 1] \cdot \begin{bmatrix} k & k \cdot \cos(60^\circ) & \Delta x \\ 0 & k \cdot \sin(60^\circ) & \Delta y \\ 0 & 0 & 1 \end{bmatrix}^T$$

Datos Normalizados para SVM2

$$\%CH_4 = \frac{CH_4}{H_2 + CH_4 + C_2H_6}$$

$$\%H_2 = \frac{H_2}{H_2 + CH_4 + C_2H_6}$$

$$\%C_2H_6 = \frac{C_2H_6}{H_2 + CH_4 + C_2H_6}$$

$$V_{SVM2} = U_{SVM2} \cdot A^T$$

$$V_{SVM2} = [\%CH_4 \quad \%H_2 \quad 1] \cdot \begin{bmatrix} k & k \cdot \cos(60^\circ) & \Delta x \\ 0 & k \cdot \sin(60^\circ) & \Delta y \\ 0 & 0 & 1 \end{bmatrix}^T$$

Datos Normalizados para SVM3

$$\%C_2H_4 = \frac{C_2H_4}{CH_4 + C_2H_4 + C_2H_6}$$

$$\%CH_4 = \frac{CH_4}{CH_4 + C_2H_4 + C_2H_6}$$

$$\%C_2H_6 = \frac{C_2H_6}{CH_4 + C_2H_4 + C_2H_6}$$

$$V_{SVM3} = U_{SVM3} \cdot A^T$$

$$V_{SVM3} = [\%C_2H_4 \quad \%CH_4 \quad 1] \cdot \begin{bmatrix} k & k \cdot \cos(60^\circ) & \Delta x \\ 0 & k \cdot \sin(60^\circ) & \Delta y \\ 0 & 0 & 1 \end{bmatrix}^T$$

Ejemplo del cálculo para el dato número 30 de los presentados para el entrenamiento.

$$Dato_{30} = 80,619,2480,326,0$$

Datos normalizados para SVM1

$$\%C_2H_4 = \frac{326}{326 + 619 + 0}$$

$$\%C_2H_4 = 34.497$$

$$\%CH_4 = \frac{619}{326 + 619 + 0}$$

$$\%CH_4 = 65.503$$

$$\%C_2H_2 = \frac{0}{326 + 619 + 0}$$

$$\%C_2H_2 = 0$$

$$V_{SVM1} = U_{SVM1} \cdot A^T$$

$$V_{SVM1} = [34.497 \quad 65.503 \quad 1] \cdot \begin{bmatrix} 1 & 1 \cdot \cos(60^\circ) & 0 \\ 0 & 1 \cdot \sin(60^\circ) & 0 \\ 0 & 0 & 1 \end{bmatrix}^T$$

$$V_{SVM1} = [67.249 \quad 56.727 \quad 1]$$

Datos Normalizados para SVM2

$$\%CH_4 = \frac{619}{619 + 80 + 2480}$$

$$\%CH_4 = 19.472$$

$$\%H_2 = \frac{80}{619 + 80 + 2480}$$

$$\%H_2 = 2.517$$

$$\%C_2H_6 = \frac{2480}{619 + 80 + 2480}$$

$$\%C_2H_6 = 78.012$$

$$V_{SVM2} = U_{SVM2} \cdot A^T$$

$$V_{SVM2} = [19.472 \quad 2.517 \quad 1] \cdot \begin{bmatrix} 1 & 1 \cdot \cos(60^\circ) & 0 \\ 0 & 1 \cdot \sin(60^\circ) & 0 \\ 0 & 0 & 1 \end{bmatrix}^T$$

$$V_{SVM2} = [20.731 \quad 2.180 \quad 1]$$

Datos Normalizados para SVM3

$$\%C_2H_4 = \frac{326}{326 + 619 + 2480}$$

$$\%C_2H_4 = 9.518$$

$$\%CH_4 = \frac{619}{326 + 619 + 2480}$$

$$\%CH_4 = 18.073$$

$$\%C_2H_6 = \frac{2480}{326 + 619 + 2480}$$

$$\%C_2H_6 = 72.409$$

$$V_{SVM3} = U_{SVM3} \cdot A^T$$

$$V_{SVM3} = [9.518 \quad 18.073 \quad 1] \cdot \begin{bmatrix} 1 & 1 \cdot \cos(60^\circ) & 0 \\ 0 & 1 \cdot \sin(60^\circ) & 0 \\ 0 & 0 & 1 \end{bmatrix}^T$$

$$V_{SVM3} = [18.555 \quad 15.652 \quad 1]$$

Estas transformaciones a coordenadas rectangulares se realizaron con el conjunto de datos de cada DGA obtenido desde el laboratorio, considerando las tablas de niveles de concentración para SV1M como diagnostico general y especifico de fallas eléctricas, SVM2 y SVM3 para diagnóstico del sub tipo de fallas térmicas, en

la tabla x, z y m se presenta los valores normalizados, los datos usados en el entrenamiento se presenta en los anexos.

Tabla 19. Datos normalizados para la validación.

N.	SVM1		SVM2		SVM3		Estado
	C2H2(x)	CH4(y)	C2H6(x)	H2(y)	C2H6(x)	CH4(y)	
1	3.413	3.341	-	-	-	-	0
2	11.429	19.795	-	-	-	-	0
3	13.700	20.218	-	-	-	-	0
4	28.670	35.082	-	-	-	-	0
5	25.954	25.122	-	-	-	-	0
6	21.301	25.684	-	-	-	-	0
7	29.186	38.306	-	-	-	-	0
8	9.453	12.458	-	-	-	-	0
9	14.341	18.126	-	-	-	-	0
10	13.411	17.831	-	-	-	-	0
11	9.775	14.325	-	-	-	-	0
12	18.860	27.095	-	-	-	-	0
13	15.606	24.931	-	-	-	-	0
14	12.397	14.315	-	-	-	-	0
15	57.144	61.859	-	-	-	-	4
16	56.846	62.969	-	-	-	-	4
17	60.965	60.014	-	-	-	-	4
18	63.183	56.686	-	-	-	-	4
19	61.720	39.242	19.077	2.783	-	-	5
20	54.812	78.269	45.653	18.213	-	-	5
21	57.608	68.519	38.438	9.272	-	-	5
22	67.909	55.395	41.881	13.455	34.949	28.510	6
23	58.125	66.034	34.759	20.927	21.137	24.012	6
24	64.351	60.647	32.129	0.670	25.922	24.431	6
25	59.235	65.147	29.477	13.245	18.894	20.779	6
26	62.098	60.409	25.029	6.788	18.718	18.209	6
27	61.010	67.534	63.723	10.296	43.288	47.916	6
28	65.080	60.484	41.913	2.039	32.940	30.614	6
29	60.241	66.710	43.550	14.636	29.516	32.686	6
30	67.249	56.727	20.731	2.180	18.555	15.652	6
31	48.361	43.690	-	-	-	-	0
32	42.784	19.106	-	-	-	-	1
33	59.091	15.746	-	-	-	-	1

34	47.635	14.043	-	-	-	-	1
35	49.042	15.218	-	-	-	-	1
36	64.021	44.905	-	-	-	-	4
37	54.828	78.241	72.831	32.387	-	-	5
38	57.059	74.376	50.676	76.391	-	-	5
39	71.239	49.816	65.016	42.899	62.163	43.468	6
40	65.625	59.539	43.151	22.540	32.813	29.770	6
41	70.497	50.876	65.095	14.706	55.385	39.971	6
42	63.699	62.876	51.289	76.379	43.459	42.897	6
43	73.500	45.899	51.457	75.046	54.851	34.253	6
44	75.642	42.069	-	-	64.497	35.871	7
45	82.715	24.426	-	-	74.289	21.938	7
46	77.938	35.305	-	-	75.406	34.159	7
47	80.646	32.867	-	-	76.148	31.033	7
48	87.715	20.285	-	-	81.756	18.907	7
49	82.729	26.609	-	-	72.250	23.238	7
50	50.999	50.914	-	-	-	-	0
51	50.714	30.929	-	-	-	-	0
52	49.123	15.194	-	-	-	-	1
53	40.194	20.335	-	-	-	-	1
54	55.358	69.591	-	-	-	-	4
55	57.059	74.376	50.676	76.391	-	-	4
56	66.786	57.529	54.263	70.708	-	-	4
57	63.699	62.876	54.009	54.812	-	-	4
58	69.886	51.742	73.387	35.380	65.474	48.476	6
59	70.399	50.805	65.934	38.067	60.760	43.849	6
60	73.569	45.780	65.758	0.000	57.689	35.898	6
61	70.201	45.493	71.496	34.803	66.818	43.301	6
62	84.589	26.091	-	-	78.495	24.211	7
63	93.042	12.052	-	-	75.937	9.836	7
64	83.239	29.031	-	-	73.655	25.688	7
65	90.156	15.333	-	-	87.431	14.870	7
66	84.651	25.191	-	-	78.060	23.229	7
67	77.083	39.334	-	-	62.479	31.882	7
68	77.986	37.295	-	-	70.502	33.715	7
69	78.859	29.642	-	-	74.841	28.132	7
70	86.822	20.314	-	-	80.396	18.811	7

Fuente: Autor.

Resultados obtenidos de la validación de las SVM

De acuerdo a lo planteado en el Capítulo II para el diagnóstico de las fallas se procede a realizar un análisis general de todos los datos en la SVM1, en donde se separan las fallas de origen eléctrico y las de origen térmico, posteriormente las fallas térmicas son procesadas en la SVM2 y SVM3 para diagnosticar el subtipo de falla térmica para obtener un diagnóstico mucho más confiable del estado real del equipo. Mediante la herramienta informática Google Colab se cargan los datos y se procesa el código diseñado para cada maquina vectorial, estos datos son presentados de manera gráfica y en resumen mediante la función matriz de confusión.

```
[4] #Parametros de regulacion para SVM1
    C_1 = 1 #Regulacion 1 - valor 1
    clf_1 = svm.SVC(kernel='linear', C = C_1, decision_function_shape='ovo')
    modelo_SVM1 = clf_1.fit(TD1x_train,TD1y_train)

    h = 0.1 #Regulacion 2 - valor 0.1
    TD1_xx, TD1_yy = np.meshgrid(np.arange(0, 100, h),
                                np.arange(0, 90, h))
    TD1_z = clf_1.predict(np.c_[TD1_xx.ravel(),
                                TD1_yy.ravel()]).reshape(TD1_xx.shape)
```

Figura 27. Parámetros de la SVM.

Mediante la función `clf_score (x_test, y_test)` de cada máquina de soporte vectorial, se puede observar que, los resultados de precisión para los 70 valores utilizados en la validación, se cuenta con una confiabilidad mayor al 90% en cada SVM, las fallas predichas y los resultados obtenidos del procesamiento de los datos con la SVM1, SVM2 y SVM3 se presentan en las tablas 21, 22 y 23, y en las gráficas 28, 29 y 30.

Tabla 20. Resultados de las SVM

N. SVM	N. Clases	N. de Validación	Porcentaje de aciertos
1	8	70	91.429 %
2	5	26	96.154 %
3	8	35	94.286 %

Fuente: Autor.

Tabla 21. Resultados pronosticados por la SVM1

N.	Diagnostico	Estado Actual	Estado SVM1	Acierto
1	Descarga de baja energía	0	0	SI
2	Descarga de baja energía	0	0	SI
3	Descarga de baja energía	0	0	SI
4	Descarga de baja energía	0	0	SI
5	Descarga de baja energía	0	0	SI
6	Descarga de baja energía	0	0	SI
7	Descarga de baja energía	0	0	SI
8	Descarga de baja energía	0	0	SI
9	Descarga de baja energía	0	0	SI
10	Descarga de baja energía	0	0	SI
11	Descarga de baja energía	0	0	SI
12	Descarga de baja energía	0	0	SI
13	Descarga de baja energía	0	0	SI
14	Descarga de baja energía	0	0	SI
15	Descarga de alta energía	4	4	SI
16	Falla térmica	4	4	SI
17	Falla térmica	4	4	SI
18	Falla térmica	4	4	SI
19	Falla térmica	5	2	NO
20	Falla térmica	5	5	SI
21	Falla térmica	5	5	SI
22	Falla térmica	6	6	SI
23	Falla térmica	6	6	SI
24	Falla térmica	6	6	SI
25	Falla térmica	6	6	SI
26	Falla térmica	6	6	SI
27	Falla térmica	6	6	SI
28	Falla térmica	6	6	SI
29	Falla térmica	6	6	SI
30	Falla térmica	6	6	SI
31	Descarga de baja energía	0	2	NO
32	Descarga de alta energía	1	1	SI
33	Descarga de alta energía	1	1	SI
34	Descarga de alta energía	1	1	SI
35	Descarga de alta energía	1	1	SI
36	Falla térmica	4	4	SI
37	Falla térmica	5	5	SI

38	Falla térmica	5	5	SI
39	Falla térmica	6	6	SI
40	Falla térmica	6	6	SI
41	Falla térmica	6	6	SI
42	Falla térmica	6	6	SI
43	Falla térmica	6	6	SI
44	Falla térmica	7	7	SI
45	Falla térmica	7	7	SI
46	Falla térmica	7	7	SI
47	Falla térmica	7	7	SI
48	Falla térmica	7	7	SI
49	Falla térmica	7	7	SI
50	Descarga de baja energía	0	0	SI
51	Descarga de baja energía	0	1	NO
52	Descarga de alta energía	1	1	SI
53	Descarga de alta energía	1	1	SI
54	Descarga de baja energía	4	4	SI
55	Descarga de baja energía	4	5	NO
56	Descarga de baja energía	4	6	NO
57	Descarga de baja energía	4	6	NO
58	Falla térmica	6	6	SI
59	Falla térmica	6	6	SI
60	Falla térmica	6	6	SI
61	Falla térmica	6	6	SI
62	Falla térmica	7	7	SI
63	Falla térmica	7	7	SI
64	Falla térmica	7	7	SI
65	Falla térmica	7	7	SI
66	Falla térmica	7	7	SI
67	Falla térmica	7	7	SI
68	Falla térmica	7	7	SI
69	Falla térmica	7	7	SI
70	Falla térmica	7	7	SI

Fuente: Autor.

$$c_{m_1} = \begin{bmatrix} 15 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 6 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 6 & 1 & 2 & 0 \\ 0 & 0 & 1 & 0 & 0 & 4 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 18 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 15 \end{bmatrix}$$




Figura 28. Reporte visual con los datos de validación de la SVM1.

En la tabla 21 y la figura 28 se aprecia los resultados numéricos y gráficos de la SVM1 especialmente las fallas de origen eléctrico para las cuales está programada la actual máquina de soporte vectorial, en la presentación de resultados se compara el diagnóstico real de acuerdo a los valores publicados en los artículos científicos que fueron citados, demostrando exactitud en el diagnostico a excepción de los casos 19, 31, 51, 55, 56 y 57. Por otro lado los casos clasificados como fallas de origen térmico T1, T2 y T2, T3 serán procesados por SVM2 y SVM3 respectivamente para identificar la sub categorías de estas fallas.

Tabla 22. Resultados pronosticados por la SVM2.

N.	Diagnostico	Estado Actual	Acierto	SVM2	Sub Tipo
16	Falla térmica	4	SI	-	-
17	Falla térmica	4	SI	-	-
18	Falla térmica	4	SI	-	-
19	Falla térmica	5	NO	O	<250 °C
20	Falla térmica	5	SI	S	Gasificación
21	Falla térmica	5	SI	ND	No definido
22	Falla térmica	6	SI	ND	No definido
23	Falla térmica	6	SI	ND	No definido
24	Falla térmica	6	SI	O	<250 °C
25	Falla térmica	6	SI	ND	No definido
26	Falla térmica	6	SI	O	<250 °C
27	Falla térmica	6	SI	S	Gasificación

28	Falla térmica	6	SI	O	<250 °C
29	Falla térmica	6	SI	ND	No definido
30	Falla térmica	6	SI	O	<250 °C
36	Falla térmica	4	SI	-	-
37	Falla térmica	5	SI	C	Carbonización
38	Falla térmica	5	SI	S	Gasificación
39	Falla térmica	6	SI	C	Carbonización
40	Falla térmica	6	SI	S	Gasificación
41	Falla térmica	6	SI	C	Carbonización
42	Falla térmica	6	SI	S	Gasificación
43	Falla térmica	6	SI	S	Gasificación
55	Descarga de baja energía	4	NO	S	Gasificación
56	Descarga de baja energía	4	NO	S	Gasificación
57	Descarga de baja energía	4	NO	S	Gasificación
58	Falla térmica	6	SI	C	Carbonización
59	Falla térmica	6	SI	C	Carbonización
60	Falla térmica	6	SI	O	<250 °C
61	Falla térmica	6	SI	C	Carbonización

Fuente: Autor.

$$c_{m_2} = \begin{bmatrix} 5 & 0 & 0 & 0 & 0 \\ 1 & 5 & 0 & 0 & 0 \\ 0 & 0 & 6 & 0 & 0 \\ 0 & 0 & 0 & 3 & 0 \\ 0 & 0 & 0 & 0 & 6 \end{bmatrix}$$




Figura 29. Reporte visual con los datos de validación de la SVM2.

En la tabla 22 y la figura 29 se aprecia los resultados numéricos y gráficos de la SVM2 especialmente las fallas de origen térmico T1 y T2 para las cuales está programada la actual máquina de soporte vectorial, en la presentación de resultados se compara el diagnóstico real de acuerdo a los valores publicados en los artículos científicos que fueron citados, demostrando exactitud en el diagnostico a excepción de los casos 19, 55, 56 y 57. Por otro lado los casos clasificados como fallas de origen térmico T2, T3 serán procesados por la SVM3 para identificar la sub categorías de estas fallas.

Tabla 23. Resultados pronosticados por la SVM3.

N.	Diagnostico	Estado Actual	Acierto	Estado SVM3	Sub Tipo
22	Falla térmica	6	SI	ND	No definido
23	Falla térmica	6	SI	O	<250 °C
24	Falla térmica	6	SI	ND	No definido
25	Falla térmica	6	SI	O	<250 °C
26	Falla térmica	6	SI	O	<250 °C
27	Falla térmica	6	SI	C	Carbonización
28	Falla térmica	6	SI	ND	No definido
29	Falla térmica	6	SI	ND	No definido
30	Falla térmica	6	SI	O	<250 °C
39	Falla térmica	6	SI	T3	>700 °C
40	Falla térmica	6	SI	ND	No definido
41	Falla térmica	6	SI	C	Carbonización
42	Falla térmica	6	SI	ND	No definido
43	Falla térmica	6	SI	C	Carbonización
44	Falla térmica	7	SI	C	Carbonización
45	Falla térmica	7	SI	T3	>700 °C
46	Falla térmica	7	SI	T3	>700 °C
47	Falla térmica	7	SI	T3	>700 °C
48	Falla térmica	7	SI	T3	>700 °C
49	Falla térmica	7	SI	C	Carbonización
55	Descarga de baja energía	4	NO	C	Carbonización
56	Descarga de baja energía	4	NO	ND	No definido
57	Descarga de baja energía	4	NO	T3	>700 °C
58	Falla térmica	6	SI	T3	>700 °C
59	Falla térmica	6	SI	C	Carbonización
60	Falla térmica	6	SI	T3	>700 °C

61	Falla térmica	6	SI	T3	>700 °C
62	Falla térmica	7	SI	C	Carbonización
63	Falla térmica	7	SI	T3	>700 °C
64	Falla térmica	7	SI	T3	>700 °C
65	Falla térmica	7	SI	T3	>700 °C
66	Falla térmica	7	SI	C	Carbonización
67	Falla térmica	7	SI	T3	>700 °C
68	Falla térmica	7	SI	T3	>700 °C
69	Falla térmica	7	SI	T3	>700 °C
70	Falla térmica	7	SI	C	Carbonización

Fuente: Autor.

$$c_m_3 = \begin{bmatrix} 4 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 7 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 8 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 14 & 0 \end{bmatrix}$$




Figura 30. Reporte visual con los datos de validación de la SVM3.

En la tabla 23 y la figura 30 se aprecia los resultados numéricos y gráficos de la SVM3 especialmente las fallas de origen térmico T2 y T3 para las cuales está programada la actual máquina de soporte vectorial, en la presentación de resultados

se compara el diagnóstico real de acuerdo a los valores publicados en los artículos científicos que fueron citados, demostrando exactitud en el diagnóstico a excepción de los casos 55, 56 y 57. Permitiendo con la SVM2 y SVM3 reducir los diagnósticos incorrectos de la SVM1 mejorando la confiabilidad en conjunto del algoritmo.

3.2 Validación técnica

Para el respectivo análisis de los resultados presentados en la tabla 21 se realiza un gráfico comparativo de aciertos y errores de acuerdo a cada caso, como se puede observar en la figura 31 la mayor cantidad de errores se encuentra en la falla DT que son falla combinadas con presencia de problemas eléctricos y térmicos, para lo cual se recomienda realizar pruebas eléctricas complementarias para el diagnóstico respectivo.




Figura 31. Resumen resultados obtenidos.

La SVM1 realiza un diagnóstico sobre el origen de la posible falla, dando un 91.429% de aciertos, de la confiabilidad de esta primera máquina de soporte vectorial depende el análisis complementario con la SVM2 y SVM3, por lo cual se toma el porcentaje de aciertos para compararlos en relación a otras técnicas presentadas en artículos científicos o trabajos de titulación, como es el caso de [18] que realiza una propuesta de diagnóstico por medio de Redes Neuronales

Artificiales (RNA) realizada en Matlab que detecta este tipo de fallas con un 82.81%, por lo que se demuestra que las SVM tienen un mejor porcentaje de acierto.

3.3 Validación económica

El mantenimiento preventivo requiere de un correcto diagnóstico y posteriormente realizar acciones que eviten la aparición de nuevas fallas o la agudización de las fallas existentes que puedan reducir el tiempo de vida útil del transformador, mediante la norma IEEE c57.104-2019 para el diagnóstico de fallas insipientes se procede inicialmente con una toma de muestra de aceite, posterior al diagnóstico dependiendo de la condición en la que se encuentre se incurrirán en algunos gastos que en comparación al beneficio recibido es bastante pequeño, por lo cual para mostrar un ejemplo de estos índices económicos se tomará el caso de un transformador de 15MW de potencia perteneciente a la subestación Hidroabanico con los siguientes datos obtenidos por el DGA.

Tabla 24. Ejemplo de diagnóstico para la validación económica.

Gas	Hidrogeno (H ₂)	Metano (CH ₄)	Etano (C ₂ H ₆)	Etileno (C ₂ H ₄)	Acetileno (C ₂ H ₂)
Estado normal	80	90	90	50	1
Lectura actual	95	110	160	50	0
Observaciones	*	*	*	-	-
% TD1	N/A	68.75	N/A	31.25	0
% TD2	26.027	30.137	43.836	N/A	N/A
% TD3	N/A	N/A	N/A	N/A	N/A
Diagnostico	SVM	1	Tipo	Térmica	T2
Diagnostico	SVM	2	Tipo	Térmica	S
Diagnostico	SVM	3	Tipo	N/A	N/A

Fuente: Autor.

Descripción:

- N/A = no aplica
- * = fuera de rango
- - = dentro del rango

En la tabla 25 se detalla la mano de obra que se necesita para realizar el trabajo considerando personal de oficina y personal de campo en donde se caracteriza un factor para cada puesto y su sueldo respectivo obteniendo el primer costo fijo.

Tabla 25. Costo de mano de obra

COSTOS POR MANTENIMIENTO					
COSTOS DE MANO DE OBRA (MO)					
Descripción	N. Personas	Sueldo Mes	Días Fuera	Costo DF	Costo Fijo USD/mes
OFICINA	factor	0.2			
Gerencia General	0.20	\$ 1,300.00	0	0.00	\$ 260.00
Gerencia Técnica	0.20	\$ 1,250.00	0	0.00	\$ 250.00
Gerencia Talento Humano	0.20	\$ 1,200.00	0	0.00	\$ 240.00
Contador	0.20	\$ 700.00	0	0.00	\$ 140.00
Laboratorista	0.20	\$ 800.00	0	0.00	\$ 160.00
Ingeniero senior	0.20	\$ 1,000.00	0	0.00	\$ 200.00
CAMPO	factor	1.00			
Ingeniero inspector	1.00	\$ 800.00	3	10.00	\$ 830.00
Ayudante inspector	1.00	\$ 600.00	3	10.00	\$ 630.00
Conductor	1.00	\$ 600.00	3	10.00	\$ 630.00
Costo total					\$ 3,340.00
Aporte Patronal 11,15%					\$ 372.41
COSTO TOTAL MANO DE OBRA					\$ 3,712.41

Fuente: Autor.

En la tabla 26 se describe el segundo costo fijo asociado a la movilización del personal en este caso se emplea una camioneta para el traslado de personal de equipos y herramientas para realizar los trabajos de mantenimiento.

Tabla 26. Costo de transporte y varios.

TRANSPORTE (TP) VARIOS				
Descripción	Cantidad	Días	Tarifa USD	Costos Fijos USD/mes
Camioneta	1	4	\$60.00	\$240.00
Alojamiento	3	4	\$20.00	\$240.00
Alimentación	3	4	\$10.00	\$120.00
Licencia Matlab	1	1	\$79.00	\$79.00
COSTOS				\$679.00
Imprevistos 2%				\$13.58
COSTO TOTAL DE TRANSPORTE Y VARIOS				\$ 692.58

Fuente: Autor.

Dentro de la tabla 27 se encuentran los equipos con los que se realiza las inspecciones y se determina el costo variable considerando los días laborables del mes y por su puesto la tarifa de alquiler del equipo para encontrar el costo variable.

Tabla 27. Costo de equipos.

EQUIPOS (EQ)				
Descripción	Cantidad	Días	Tarifa USD	Costos Variables USD/mes
Jeringa para muestra	1	1	\$20.00	\$20.00
Cromatografía DGA	1	1	\$200.00	\$200.00
Termo filtrado	1	30	\$1,000.00	\$30,000.00
COSTO TOTAL				\$30,220.00

Fuente: Autor.

En la tabla 28 se suma los costos fijos más los costos variables para encontrar el costo total por día que resulta realizar el mantenimiento predictivo mediante el análisis de gases disueltos.

Tabla 28. Costo total.

DESCRIPCIÓN	USD/MES	USD/DÍA
Total, costos variables	\$30,220.00	\$1007.33
Total, costos fijos	\$4,404.99	\$ 146.83
TOTAL, COSTOS USD/DÍA (MO+TP+EQ)		\$1154.16

Fuente: Autor.

En la tabla 29 se calcula el costo de la energía no facturada considerando una salida de 3 días por fallas internas en el transformador de potencia. Cabe mencionar que estas horas pueden ser superiores ya que dependiendo de la falla se puede tardar mucho más la corrección de la misma para que pueda volver a su funcionamiento.

Tabla 29. Costo de energía no facturada.

COSTO DE ENERGÍA NO FACTURADA POR INTERRUPCIÓN

Potencia del transformador	15000.00	kW
Horas de falla	72	h
Energía no suministrada	1080000.00	kWh
Valor kilovatio	0.09	\$/kWh
Costo de energía no facturada	97200	\$

Fuente: Autor.

Se hace una comparación estimada en la Tabla 32 que finalmente demuestra que el costo del mantenimiento predictivo es mucho menor que el valor del costo por energía no facturada causada por las 72 horas de desconexión, obteniendo un beneficio financiero de \$ 96.183,33 dólares, pero lo más importante para este caso es mejorar la calidad de servicio, ya que las interrupciones no programadas presentan una pérdida económica directa a la economía de los usuarios, que no puede ser cuantificada, y sanciones para la distribuidora.

Tabla 30. Costo beneficio del mantenimiento.

COSTO DE MANTENIMIENTO
PREVENTIVO

Costo de mantenimiento	\$3,462.48
Costo de energía no suministrada	\$97,200.00
BENEFICIO FINANCIERO	\$93,737.52

Fuente: Autor.

3.4 Conclusiones del III capítulo. -

- El código de programación se optimizó mediante el coeficiente de penalización del término de error C, que permite minimizar la distancia entre cada hiperplano de las áreas de falla, de manera que las franjas o zonas críticas no presentan problemas en la predicción de las fallas.
- La programación de las Maquinas de Soporte Vectorial (SVM) están basadas en el lenguaje de código libre Python y la ejecución del mismo se lo realiza mediante Colaboratory (Google Colab) que es un entorno interactivo gratuito que permite el procesamiento de una gran cantidad de datos desde cualquier computadora por más básica que sea, únicamente requiere una conexión estable a internet.
- El código de programación facilita en gran medida al ingeniero eléctrico el procesamiento de varias lecturas obtenidas mediante muestreo o en línea y reduce el tiempo de diagnóstico del estado real del transformador de potencia para posteriormente sugerir las acciones preventivas necesarias para el próximo mantenimiento del equipo.

Conclusiones Generales

- Los algoritmos de aprendizaje supervisado combinado con el acceso libre a las herramientas informática para el desarrollo y procesamiento de los mismos han permitido el avance acelerado en la utilización de los mismos para resolver problemas en los distintos campos de la ingeniería como es el caso del diagnóstico de las fallas insipientes en transformadores de potencia.
- El código de programación está diseñado para que pueda procesar de manera individual el reporte de laboratorio del análisis de gases disueltos o una gran cantidad de reportes, del mismo o de diferentes transformadores lo que permite comparar la evolución histórica del equipo o la condición entre varios transformadores dependiendo los esfuerzos eléctricos a los que estén sometidos.
- Para la optimización del código de programación se aplicó una transformación matemática que reduce el 33% de procesamiento de datos

obtenidos de los reportes históricos de los análisis de gases disueltos con sus respectivos diagnósticos reales, siendo una fuente confiable para las etapas de entrenamiento, prueba y validación de las máquinas de soporte vectorial obteniendo el estado actual del transformador de potencia y el origen de la falla con un 91.429%, 96.154, 94.286% de aciertos para SVM1, SVM2 y SVM3 respectivamente.

- La herramienta informática al realizar un correcto diagnóstico de la presencia de una falla insipiente al interior de los transformadores permite tomar acciones preventivas y evitar salidas no programadas de los mismos, las cuales se pueden traducir en pérdidas económicas por energía no facturada, ahorrando este dinero a la empresa, ya sea pública o privada y manteniendo el tiempo de vida útil para el que fueron diseñados los equipos.

Recomendaciones

- Para poder optimizar o realizar mejoras al código de programación es necesario contar con los conocimientos básicos de programación en el lenguaje Python, la interfaz de la plataforma Google Colab y los fundamentos matemáticos de las máquinas de soporte vectorial y de las transformaciones de coordenadas triangulares en rectangulares.
- En caso de fallas DT diagnosticadas por el SVM1 que son de origen eléctrico y térmico requiere que el profesional que se encuentra analizando los resultados solicite pruebas eléctricas complementarias para corroborar el diagnóstico correcto del estado del equipo.
- En caso de obtener un diagnóstico de fallas con origen térmico T1, T2 o T3 mediante SVM2 y SVM3 apoyarse en un análisis termográfico para ubicar el origen de la falla y planificar reajustes o cambio de piezas, o en su defecto descartar puntos calientes.

Referencias bibliográficas

- [1] J. E. Alvarez Paniagua, «MANTENIMIENTO PREDICTIVO A TRAVÉS DE UN SISTEMA DE MONITOREO DE VIBRACIONES A TURBINAS TIPO FRANCIS (8MW) ACORDE A LA NORMA ISO 10816, EN LA CENTRAL HIDROELÉCTRICA SANTA TERESA», Universidad de San Carlos de Guatemala, 2019.
- [2] A. ALMANZA RODRÍGUEZ y J. C. PEDROZA QUEVEDO, «ESTUDIO ORIENTADO AL MANTENIMIENTO PREDICTIVO DE TRANSFORMADORES TRIFASICOS SUMERGIDOS EN ACEITE A PARTIR DE CINCO (5) ENSAYOS ELÉCTRICOS EN DEVANADOS Y SISTEMA DE AISLAMIENTO», 2019.
- [3] F. Villada, G. Morena, y J. Valencia, «El mantenimiento predictivo y su efecto en la optimización de costos de mantenimiento», *Rev. Fac. Ing. No. 25. pp. 95-105. Abril, 2002*, vol. 25, n.º 25, pp. 95-105, 2002.
- [4] S. Alsuhaibani, Y. Khan, A. Beroual, y N. Malik, «A Review of Frequency Response Analysis Methods for Power Transformer Diagnostics», *Energies*, vol. 9, n.º 879, 2016.
- [5] S. Marrero-ramírez, I. González-palau, y A. A. Legra-lobaina, «Convergence analysis of the variables integration method applied in multiobjective optimization in the reactive power compensation in the electric nets», 2015.
- [6] O. A. ARTEAGA PONCE, «ANÁLISIS DE RESPUESTA EN FRECUENCIA (FRA) PARA LA IDENTIFICACIÓN DEL ESTADO DE UN TRANSFORMADOR DE POTENCIA», Universidad Nacional de Colombia, 2018.
- [7] J. Artero, «“Mantenimiento moderno en transformadores de potencia», *XIII ERIAC*, 2009.
- [8] G. Crespo Sánchez, «Análisis de gases disueltos para monitoreo y diagnóstico de transformadores de fuerza en servicio», *Rev. Científica Ing. Energética*, vol. 36, n.º 2, pp. 180-189, 2015.

- [9] J. E. Salamanca Jaimes, J. A. Velazco Ochoa, y E. A. Acevedo Camacho, «ANÁLISIS DE CRITICIDAD Y ÁRBOLES DE DIAGNÓSTICO DE FALLAS PARA TRANSFORMADORES DE POTENCIA», *Rev. Colomb. Tecnol. Av.*, vol. 1, 2016.
- [10] F. V. YÉPEZ BENNETT, «ANÁLISIS TERMOGRÁFICO DE LA SUBESTACIÓN SAN LORENZO Y SU ALIMENTADOR PRIMARIO PRINCIPAL PARA ELABORAR UN PLAN DE MANTENIMIENTO PREDICTIVO», UNIVERSIDAD TÉCNICA DEL NORTE FACULTAD, 2016.
- [11] S. A. Ortiz Tisalema, «Mantenimiento predictivo en subestación de distribución de UCSG – Facultad Técnica empleando termografía de rayos infrarrojos y Megger Flucker», UNIVERSIDAD CATÓLICA DE SANTIAGO DE GUAYAQUIL, 2018.
- [12] A. D. Muñoz Pérez, «METODOLOGÍA DEL MANTENIMIENTO CENTRADO EN CONFIABILIDAD (RCM) APLICADA A TRANSFORMADORES DE POTENCIA», Universidad de San Carlos de Guatemala, 2018. [En línea]. Disponible en: <http://emecanica.ingenieria.usac.edu.gt/sitio/wp-content/subidas/6ARTÍCULO-III-INDESA-SIE.pdf>
- [13] S. G. CASTREJÓN CHAPPA y C. A. RAMIREZ GUERRA, «GESTIÓN DE ACTIVOS Y MANTENIMIENTO DE SET's: TRANSFORMADORES DE POTENCIA», UNIVERSIDAD NACIONAL DEL CALLAO, 2016.
- [14] V. MERCADO y J. BERNARDO PEÑA, «MODELO DE GESTIÓN DE MANTENIMIENTO ENFOCADO EN LA EFICIENCIA Y OPTIMIZACIÓN DE LA ENERGÍA ELÉCTRICA», *SABER. Rev. Multidiscip. del Cons. Investig. la Univ. Oriente*, vol. 28, n.º 1, pp. 99-105, 2016.
- [15] J. CÁCERES PIZARRO, «ANÁLISIS FÍSICOQUÍMICO Y CROMATÓGRAFO EN TRANSFORMADORES DE POTENCIA Y DE DISTRIBUCIÓN EN LA PLANTA DE LICUEFACCIÓN DE GAS MELCHORITA-PERÚ LNG.», UNIVERSIDAD NACIONAL DEL

ALTIPLANO - PUNO, 2017.

- [16] M. S. Díaz y E. Schmidt, «Diagnóstico del estado de transformadores de potencia mediante el análisis de gases disueltos (DGA)», *Extensionismo, Innovación y Transf. Tecnológica*, vol. 2, p. 62, 2015, doi: 10.30972/eitt.20281.
- [17] IEEE, «IEEE Guide for the Interpretation of Gases Generated in Mineral Oil-Immersed Transformers», vol. 2019, pp. 0-97, 2019.
- [18] A. A. De la Torre Macias, «Análisis de fallas en transformadores de potencia de centrales de generación eléctrica», Universidad Politecnica Salesiana, 2021.
- [19] J. T. Sarria Arias, N. A. Guerrero Bello, y E. Rivas Trujillo, «Estado del arte del análisis de gases disueltos en transformadores de potencia», *Rev. Fac. Ing.*, vol. 23, n.º 36, p. 105, 2014, doi: 10.19053/01211129.2716.
- [20] C. A. Quesada Rios, «ANÁLISIS DEL ACEITE EN EL MANTENIMIENTO PREDICTIVO DE TRANSFORMADORES DE POTENCIA EN EDELNOR S.A.A.», UNIVERSIDAD NACIONAL DE INGENIERIA, 2010.
- [21] L. V. Vallejo Samaniego, «Diagnóstico para el mantenimiento de un transformador de potencia en aceite de 13.8 / 69kV en la Central Hidroeléctrica Manduriacu, provincia de Imbabura», 2015. doi: 10.1017/CBO9781107415324.004.
- [22] E. O. García Vélez y C. Gaspar España, «Diagnóstico y mantenimiento de transformadores de gran potencia en aceite (Aplicado a un transformador de 160MVA, 13,8kV/138kV de la Central Térmica Trinitaria).», Universidad Politécnica Salesiana Sede Guayaquil, 2010.
- [23] A. Carrera Gomez, «ANÁLISIS DE GASES DISUELTOS EN ACEITE PARA EL MANTENIMIENTO PREVENTIVO A TRANSFORMADORES DE POTENCIA MEDIANTE LA IMPLEMENTACIÓN DE SOFTWARE», INSTITUTO POLITÉCNICO NACIONAL, 2013.

- [24] V. Cheemala, A. N. Asokan, y P. Preetha, «Transformer Incipient Fault Diagnosis using Machine Learning Classifiers», *4th Int. Conf. Cond. Assess. Tech. Electr. Syst. CATCON 2019*, 2019, doi: 10.1109/CATCON47128.2019.CN0046.
- [25] V. Vural y J. G. Dy, «A hierarchical method for multi-class support vector machines», *Proceedings, Twenty-First Int. Conf. Mach. Learn. ICML 2004*, n.º 2, pp. 831-838, 2004, doi: 10.1145/1015330.1015427.
- [26] A. Peimankar y A. . Lapthorn, «Condition Assessment of Transformers Load Tap Changers Using Support Vector Machine», *19th Int. Symp. High Volt. Eng.*, pp. 23-28, 2015.
- [27] H. Lei y V. Govindaraju, «Half-Against-Half Multi-class Support Vector Machines», pp. 156-164, 2005.
- [28] H. Hou, P. Han, y D. Cao, «The Application Based on Decision Tree SVM for Multi-class Classification», *2nd Int. Conf. Electr. Comput. Eng. Electron.*, vol. 24, n.º Icecee, pp. 1656-1660, 2015, doi: 10.2991/icecee-15.2015.312.
- [29] G. Madzarov y D. Gjorgjevikj, «MULTI-CLASS CLASSIFICATION USING SUPPORT VECTOR MACHINES IN DECISION TREE ARCHITECTURE», *IEEE*, n.º 2, pp. 288-295, 2009.
- [30] S. Cheong, S. Oh, y S. Lee, «Support vector machines with binary tree architecture for multi-class classification», *Neural Inf. Process. - Lett. Rev.*, vol. 2, n.º 3, pp. 47-51, 2004, [En línea]. Disponible en: <http://logos.mokwon.ac.kr/pub/NIPLR2004.pdf>
- [31] F. F. Chamasemani y Y. P. Singh, «Multi-class Support Vector Machine (SVM) classifiers - An application in hypothyroid detection and classification», *6th Int. Conf. Bio-Inspired Comput. Theor. Appl.*, pp. 351-356, 2011, doi: 10.1109/BIC-TA.2011.51.
- [32] T. Lajnef *et al.*, «Learning machines and sleeping brains: Automatic sleep stage classification using decision-tree multi-class support vector machines», *J. Neurosci. Methods*, vol. 250, pp. 94-105, 2015, doi:

10.1016/j.jneumeth.2015.01.022.

- [33] L. V. Ganyun, C. Haozhong, Z. Haibao, y D. Lixin, «Fault diagnosis of power transformer based on multi-layer SVM classifier», *Electr. Power Syst. Res.*, vol. 74, n.º 1, pp. 1-7, 2005, doi: 10.1016/j.epsr.2004.07.008.
- [34] S. S. M. Ghoneim y I. B. Taha, «Artificial Neural Networks for Power Transformers Fault Diagnosis Based on IEC Code Using Dissolved Gas Analysis», *Int. J. Control. Autom. Syst.*, vol. 4, n.º 2, pp. 18-21, 2015.
- [35] K. Shrivastava y A. Choubey, «A novel association rule mining with IEC ratio based dissolved gas analysis for fault diagnosis of power transformers», *Int. J. Adv. Comput. Res.*, vol. 2, n.º 2, 2012.
- [36] D. V. S. S. S. Sarma y G. N. S. Kalyani, «ANN approach for condition monitoring of power transformers using DGA», *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON*, vol. C, pp. 444-447, 2004, doi: 10.1109/tencon.2004.1414803.
- [37] C. P. Hung y M. H. Wang, «Diagnosis of incipient faults in power transformers using CMAC neural network approach», *Electr. Power Syst. Res.*, vol. 71, n.º 3, pp. 235-244, 2004, doi: 10.1016/j.epsr.2004.01.019.

Anexos

Anexos A1 Base de datos para entrenamiento de SVM1

N	H2	CH4	C2H6	C2H4	C2H2	Estado
1	40.800	3.000	3.600	3.500	7.400	1
2	23.000	12.000	12.000	10.000	61.000	0
3	57.000	13.000	0.100	11.000	12.000	1
4	31.000	6.600	19.000	4.700	67.000	0
5	42.000	62.000	5.000	63.000	73.000	1
6	60.000	40.000	9.900	110.000	70.000	1
7	240.000	28.000	6.000	26.000	85.000	0
8	466.500	148.800	13.000	266.000	511.000	1
9	285.000	36.300	75.000	8.400	133.000	0
10	5283.000	179.000	320.000	3020.000	2314.000	1
11	335.000	67.000	18.000	143.000	170.000	1
12	44.000	12.200	3.400	3.200	17.400	0
13	260.000	130.000	29.000	84.000	92.000	1
14	250.000	63.000	3.800	66.000	120.000	1
15	59.000	7.100	19.000	4.500	71.000	0
16	650.000	53.000	34.000	20.000	0.000	6
17	160.000	90.000	27.000	17.000	5.800	4
18	0.000	5.200	5.120	9.580	14.600	1
19	1565.000	93.000	34.000	47.000	0.000	6
20	35.000	25.000	0.000	23.000	22.000	1
21	280.000	1500.000	150.000	1200.000	140.000	4
22	228.000	380.000	82.000	1012.000	19.000	7
23	50.000	90.000	18.000	260.000	5.900	7
24	48.000	230.000	160.000	810.000	7.000	7
25	90.000	160.000	54.000	330.000	29.000	7
26	168.000	1353.000	581.000	3281.000	63.000	7
27	17000.000	110000.000	84000.000	89000.000	16000.000	4
28	81.000	130.000	74.000	230.000	2.900	7
29	130.000	440.000	180.000	730.000	0.000	7
30	70.000	69.000	29.000	241.000	10.000	7
31	130.000	440.000	180.000	730.000	0.000	7
32	3606.400	1182.000	328.400	1604.800	6.300	7
33	577.000	3541.000	521.000	2928.000	7.000	6
34	1400.000	3000.000	560.000	3500.000	4.000	7
35	47.000	106.000	28.700	242.200	6.350	7
36	220.000	340.000	42.000	480.000	14.000	7
37	380.000	190.000	30.000	280.000	22.000	7
38	30.000	62.000	60.000	460.000	3.400	7

39	770.000	1420.000	401.000	1452.000	3.000	7
40	249.000	726.000	278.000	938.000	0.000	7
41	170.000	330.000	77.000	340.000	13.000	6
42	170.000	320.000	53.000	520.000	3.200	7
43	11.000	88.000	83.000	250.000	8.500	7
44	1000.000	4300.000	1100.000	5400.000	24.000	7
45	613.000	3240.000	1432.000	2788.000	0.000	6
46	4.116	0.898	0.962	2.578	0.038	7
47	1.702	0.241	0.209	0.255	0.004	7
48	0.399	5.526	0.825	4.442	0.003	6
49	6.065	12.025	0.651	15.713	0.001	7
50	0.732	3.044	0.291	1.382	0.002	6
51	4.480	45.470	35.390	342.500	21.562	7
52	4.593	24.797	14.707	13.856	0.003	6
53	2.608	18.971	39.848	2.740	0.004	5
54	0.857	6.367	5.081	4.994	0.000	6
55	1.859	3.108	2.148	3.212	0.008	7
56	0.149	0.991	0.075	0.101	0.010	5
57	3.168	9.265	2.940	6.631	0.022	6
58	1.701	1.197	0.117	0.818	0.129	4
59	1.323	0.430	0.000	0.046	0.013	5
60	2.701	1.187	0.217	0.717	0.229	4
61	8.698	1.064	0.513	2.126	0.535	7
62	1.801	1.231	0.113	0.617	0.213	4
63	29.991	1.859	0.737	0.519	0.059	6
64	30.991	2.859	0.637	0.619	0.069	5
65	4.337	1.057	0.200	0.923	0.003	6
66	0.559	0.155	0.001	0.004	0.017	4
67	7.917	4.317	3.284	5.211	1.865	3
68	5.386	0.417	0.048	0.028	0.000	5
69	5.779	0.546	0.155	0.073	0.007	5
70	31.991	2.113	0.661	0.558	0.051	6
71	21.000	34.000	5.000	47.000	62.000	1
72	1607.000	615.000	80.000	916.000	1294.000	1
73	127.000	107.000	11.000	154.000	224.000	1
74	60.000	40.000	69.000	110.000	70.000	1
75	3445.000	213.000	319.000	45.000	1962.000	0
76	86.000	30.000	10.000	35.000	29.000	1
77	593.000	41.000	99.000	111.000	70.000	1
78	469.000	147.000	125.000	265.000	520.000	1
79	269.000	1081.000	347.000	1725.000	25.000	7
80	86.000	187.000	136.000	363.000	1.000	7
81	14.000	237.000	92.000	470.000	1.000	7

82	239.000	275.000	55.000	255.000	85.000	4
83	56.000	55.000	92.000	345.000	275.000	1
84	10.000	10.000	8.000	1.000	1.000	4
85	157.000	127.000	34.000	96.000	1.000	6
86	10.000	24.000	372.000	24.000	1.000	6
87	980.000	73.000	58.000	12.000	1.000	5
88	980.000	73.000	58.000	12.000	1.000	5
89	260.000	3.000	18.000	2.000	1.000	2
90	586.000	19.000	77.000	6.000	1.000	6
91	18085.000	5.000	234.000	18.000	1.000	7
92	4.000	99.000	82.000	42.000	1.000	6
93	50.000	100.000	51.000	305.000	9.000	7
94	308.000	149.000	479.000	146.000	1.000	6
95	27.000	136.000	469.000	131.000	1.000	6
96	181.000	262.000	41.000	28.000	1.000	5
97	173.000	334.000	172.000	8125.000	377.000	7
98	27.000	90.000	42.000	63.000	2.000	6
99	304.000	117.000	442.000	138.000	1.000	7
100	200.000	700.000	250.000	740.000	1.000	7
101	16.000	25.000	19.000	39.000	1.000	7
102	22.000	40.000	36.000	6.000	1.000	5
103	1770.000	3630.000	1070.000	8480.000	78.000	7

Anexos A2 Base de datos para entrenamiento de SVM2

N	H2	CH4	C2H6	C2H4	C2H2	Estado
1	650.000	53.000	34.000	20.000	0.000	4
2	1565.000	93.000	34.000	47.000	0.000	4
3	577.000	3541.000	521.000	2928.000	7.000	2
4	170.000	330.000	77.000	340.000	13.000	2
5	613.000	3240.000	1432.000	2788.000	0.000	2
6	0.399	5.526	0.825	4.442	0.003	2
7	0.732	3.044	0.291	1.382	0.002	2
8	4.593	24.797	14.707	13.856	0.003	3
9	2.608	18.971	39.848	2.740	0.004	0
10	0.857	6.367	5.081	4.994	0.000	0
11	0.149	0.991	0.075	0.101	0.010	2
12	3.168	9.265	2.940	6.631	0.022	2
13	1.323	0.430	0.000	0.046	0.013	4
14	29.991	1.859	0.737	0.519	0.059	4
15	30.991	2.859	0.637	0.619	0.069	4
16	4.337	1.057	0.200	0.923	0.003	4
17	5.386	0.417	0.048	0.028	0.000	4

18	5.779	0.546	0.155	0.073	0.007	4
19	31.991	2.113	0.661	0.558	0.051	4
20	157.000	127.000	34.000	96.000	1.000	2
21	10.000	24.000	372.000	24.000	1.000	0
22	980.000	73.000	58.000	12.000	1.000	4
23	980.000	73.000	58.000	12.000	1.000	4
24	586.000	19.000	77.000	6.000	1.000	4
25	4.000	99.000	82.000	42.000	1.000	0
26	308.000	149.000	479.000	146.000	1.000	1
27	27.000	136.000	469.000	131.000	1.000	0
28	181.000	262.000	41.000	28.000	1.000	2
29	27.000	90.000	42.000	63.000	2.000	2
30	22.000	40.000	36.000	6.000	1.000	3

Anexos A3 Base de datos para entrenamiento de SVM3

N	H2	CH4	C2H6	C2H4	C2H2	Estado
1	650.000	53.000	34.000	20.000	0.000	3
2	1565.000	93.000	34.000	47.000	0.000	5
3	228.000	380.000	82.000	1012.000	19.000	7
4	50.000	90.000	18.000	260.000	5.900	7
5	48.000	230.000	160.000	810.000	7.000	7
6	90.000	160.000	54.000	330.000	29.000	7
7	168.000	1353.000	581.000	3281.000	63.000	7
8	81.000	130.000	74.000	230.000	2.900	5
9	130.000	440.000	180.000	730.000	0.000	7
10	70.000	69.000	29.000	241.000	10.000	7
11	130.000	440.000	180.000	730.000	0.000	7
12	3606.400	1182.000	328.400	1604.800	6.300	7
13	577.000	3541.000	521.000	2928.000	7.000	7
14	1400.000	3000.000	560.000	3500.000	4.000	7
15	47.000	106.000	28.700	242.200	6.350	7
16	220.000	340.000	42.000	480.000	14.000	7
17	380.000	190.000	30.000	280.000	22.000	7
18	30.000	62.000	60.000	460.000	3.400	7
19	770.000	1420.000	401.000	1452.000	3.000	7
20	249.000	726.000	278.000	938.000	0.000	5
21	170.000	330.000	77.000	340.000	13.000	7
22	170.000	320.000	53.000	520.000	3.200	7
23	11.000	88.000	83.000	250.000	8.500	5
24	1000.000	4300.000	1100.000	5400.000	24.000	7
25	613.000	3240.000	1432.000	2788.000	0.000	5
26	4.116	0.898	0.962	2.578	0.038	5
27	1.702	0.241	0.209	0.255	0.004	5

28	0.399	5.526	0.825	4.442	0.003	7
29	6.065	12.025	0.651	15.713	0.001	7
30	0.732	3.044	0.291	1.382	0.002	6
31	4.480	45.470	35.390	342.500	21.562	7
32	4.593	24.797	14.707	13.856	0.003	5
33	0.857	6.367	5.081	4.994	0.000	3
34	1.859	3.108	2.148	3.212	0.008	5
35	3.168	9.265	2.940	6.631	0.022	5
36	8.698	1.064	0.513	2.126	0.535	5
37	29.991	1.859	0.737	0.519	0.059	7
38	4.337	1.057	0.200	0.923	0.003	5
39	31.991	2.113	0.661	0.558	0.051	7
40	269.000	1081.000	347.000	1725.000	25.000	5
41	86.000	187.000	136.000	363.000	1.000	7
42	14.000	237.000	92.000	470.000	1.000	7
43	157.000	127.000	34.000	96.000	1.000	0
44	10.000	24.000	372.000	24.000	1.000	0
45	586.000	19.000	77.000	6.000	1.000	0
46	18085.000	5.000	234.000	18.000	1.000	3
47	4.000	99.000	82.000	42.000	1.000	7
48	50.000	100.000	51.000	305.000	9.000	3
49	308.000	149.000	479.000	146.000	1.000	3
50	27.000	136.000	469.000	131.000	1.000	7
51	173.000	334.000	172.000	8125.000	377.000	5
52	27.000	90.000	42.000	63.000	2.000	3
53	304.000	117.000	442.000	138.000	1.000	5
54	200.000	700.000	250.000	740.000	1.000	5
55	16.000	25.000	19.000	39.000	1.000	1
56	1770.000	3630.000	1070.000	8480.000	78.000	7

Anexos A4 Base de datos para validación de SVM1

N	H2	CH4	C2H6	C2H4	C2H2	Diagnostico	Estado
1	24	13	43	5	319	Descarga de baja energía	0
2	127	24	32	0	81	Descarga de baja energía	0
3	9474	4066	6552	353	12997	Descarga de baja energía	0
4	441	207	224	43	261	Descarga de baja energía	0
5	212	38	47	15	78	Descarga de baja energía	0
6	800	1393	2817	304	3000	Descarga de baja energía	0
7	4906	8784	9924	1404	9671	Descarga de baja energía	0
8	858	1324	2793	208	7672	Descarga de baja energía	0
9	274	27	33	5	97	Descarga de baja energía	0
10	1249	370	606	56	1371	Descarga de baja energía	0

11	307	22	33	2	109	Descarga de baja energía	0
12	127	107	154	11	224	Descarga de baja energía	0
13	1076	95	71	4	231	Descarga de baja energía	0
14	240	20	28	5	96	Descarga de baja energía	0
15	160	10	1	3	1	Descarga de alta energía	4
16	199	770	1508	217	72	Falla térmica	4
17	33	79	215	30	5	Falla térmica	4
18	60	144	449	67	9	Falla térmica	4
19	16	87	395	75	30	Falla térmica	5
20	416	695	867	74	0	Falla térmica	5
21	244	754	1281	172	27	Falla térmica	5
22	266	584	862	328	1	Falla térmica	6
23	65	61	143	16	3	Falla térmica	6
24	425	17424	37043	7299	158	Falla térmica	6
25	117	167	481	48	7	Falla térmica	6
26	137	369	1242	144	16	Falla térmica	6
27	2004	9739	5113	2750	0	Falla térmica	6
28	231	3997	5584	1726	0	Falla térmica	6
29	507	1053	1440	297	17	Falla térmica	6
30	80	619	2480	326	0	Falla térmica	6
31	345	112.3	27.5	51.5	58.8	Descarga de baja energía	0
32	127	107	11	154	224	Descarga de alta energía	1
33	60	40	6.9	110	70	Descarga de alta energía	1
34	200	48	14	117	131	Descarga de alta energía	1
35	32.4	5.5	1.4	12.6	13.2	Descarga de alta energía	1
36	300	490	180	360	95	Falla térmica	4
37	181	262	41	28	0	Falla térmica	5
38	980	73	58	12	0	Falla térmica	5
39	160	130	33	96	0	Falla térmica	6
40	95	110	160	50	0	Falla térmica	6
41	27	90	42	63	0.2	Falla térmica	6
42	650	53	34	20	0	Falla térmica	6
43	565	53	34	47	0	Falla térmica	6
44	200	700	250	740	1	Falla térmica	7
45	173	334	172	812.5	37.7	Falla térmica	7
46	220	340	42	480	14	Falla térmica	7
47	170	320	53	520	3.2	Falla térmica	7
48	56	286	96	928	7	Falla térmica	7
49	78	161	86	353	10	Falla térmica	7
50	176.0	206.0	47.7	75.7	68.7	Descarga de baja energía	0
51	35.0	25.0	0.0	23.0	22.0	Descarga de baja energía	0
52	293.0	50.0	13.0	115.0	120.0	Descarga de alta energía	1
53	443.0	85.0	9.5	103.0	174.0	Descarga de alta energía	1

54	160.0	90.0	27.0	17.0	5.0	Descarga de baja energía	4
55	980.0	73.0	58.0	12.0	0.0	Descarga de baja energía	4
56	565.0	93.0	34.0	47.0	0.0	Descarga de baja energía	4
57	150.0	53.0	34.0	20.0	0.0	Descarga de baja energía	4
58	766.0	993.0	116.0	665.0	4.0	Falla térmica	6
59	120.0	120.0	33.0	84.0	0.6	Falla térmica	6
60	0.0	434.0	226.0	387.0	0.0	Falla térmica	6
61	86.0	110.0	18.0	92.0	7.4	Falla térmica	6
62	73.0	520.0	140.0	1200.0	6.0	Falla térmica	7
63	42.0	97.0	157.0	600.0	0.0	Falla térmica	7
64	16.0	237.0	92.0	470.0	0.0	Falla térmica	7
65	15.0	125.0	29.0	574.0	7.0	Falla térmica	7
66	5.0	217.0	69.0	523.0	6.0	Falla térmica	7
67	2844.0	8517.0	4422.0	10196.0	39.0	Falla térmica	7
68	117.0	357.0	92.0	468.0	4.0	Falla térmica	7
69	80.0	153.0	42.0	276.0	18.0	Falla térmica	7
70	8.0	631.0	254.0	2020.0	39.0	Falla térmica	7

Anexos A5 Base de datos para validación de SVM2

N	H2	CH4	C2H6	C2H4	C2H2	Diagnostico	Estado
1	16	87	395	75	30	Falla térmica	5
2	416	695	867	74	0	Falla térmica	5
3	244	754	1281	172	27	Falla térmica	5
4	266	584	862	328	1	Falla térmica	6
5	65	61	143	16	3	Falla térmica	6
6	425	17424	37043	7299	158	Falla térmica	6
7	117	167	481	48	7	Falla térmica	6
8	137	369	1242	144	16	Falla térmica	6
9	2004	9739	5113	2750	0	Falla térmica	6
10	231	3997	5584	1726	0	Falla térmica	6
11	507	1053	1440	297	17	Falla térmica	6
12	80	619	2480	326	0	Falla térmica	6
13	181	262	41	28	0	Falla térmica	5
14	980	73	58	12	0	Falla térmica	5
15	160	130	33	96	0	Falla térmica	6
16	95	110	160	50	0	Falla térmica	6
17	27	90	42	63	0.2	Falla térmica	6
18	650	53	34	20	0	Falla térmica	6
19	565	53	34	47	0	Falla térmica	6
20	766.0	993.0	116.0	665.0	4.0	Falla térmica	6
21	120.0	120.0	33.0	84.0	0.6	Falla térmica	6

22	0.0	434.0	226.0	387.0	0.0	Falla térmica	6
23	86.0	110.0	18.0	92.0	7.4	Falla térmica	6

Anexos A6 Base de datos para validación de SVM3

N	H2	CH4	C2H6	C2H4	C2H2	Diagnostico	Estado
1	266	584	862	328	1	Falla térmica	6
2	65	61	143	16	3	Falla térmica	6
3	425	17424	37043	7299	158	Falla térmica	6
4	117	167	481	48	7	Falla térmica	6
5	137	369	1242	144	16	Falla térmica	6
6	2004	9739	5113	2750	0	Falla térmica	6
7	231	3997	5584	1726	0	Falla térmica	6
8	507	1053	1440	297	17	Falla térmica	6
9	80	619	2480	326	0	Falla térmica	6
10	160	130	33	96	0	Falla térmica	6
11	95	110	160	50	0	Falla térmica	6
12	27	90	42	63	0.2	Falla térmica	6
13	650	53	34	20	0	Falla térmica	6
14	565	53	34	47	0	Falla térmica	6
15	200	700	250	740	1	Falla térmica	7
16	173	334	172	812.5	37.7	Falla térmica	7
17	220	340	42	480	14	Falla térmica	7
18	170	320	53	520	3.2	Falla térmica	7
19	56	286	96	928	7	Falla térmica	7
20	78	161	86	353	10	Falla térmica	7
21	766.0	993.0	116.0	665.0	4.0	Falla térmica	6
22	120.0	120.0	33.0	84.0	0.6	Falla térmica	6
23	0.0	434.0	226.0	387.0	0.0	Falla térmica	6
24	86.0	110.0	18.0	92.0	7.4	Falla térmica	6
25	73.0	520.0	140.0	1200.0	6.0	Falla térmica	7
26	42.0	97.0	157.0	600.0	0.0	Falla térmica	7
27	16.0	237.0	92.0	470.0	0.0	Falla térmica	7
28	15.0	125.0	29.0	574.0	7.0	Falla térmica	7
29	5.0	217.0	69.0	523.0	6.0	Falla térmica	7
30	2844.0	8517.0	4422.0	10196.0	39.0	Falla térmica	7
31	117.0	357.0	92.0	468.0	4.0	Falla térmica	7
32	80.0	153.0	42.0	276.0	18.0	Falla térmica	7
33	8.0	631.0	254.0	2020.0	39.0	Falla térmica	7