

Ecuador – Febrero 2017 - ISSN: 1696-8352

DETERMINACIÓN DE ALGORITMOS EN MÁQUINAS SOPORTES VECTORIAL Y REDES NEURONALES PARA EL DIAGNOSTICO DE FALLAS EN GASES DISUELTOS EN EL ACEITE

***Ing. Ángel Iván Torres Quijije, MSC**

Ingeniero en Electrónica y Telecomunicaciones graduado en la Escuela Politécnica Nacional de Quito - Ecuador, Master en Conectividad y Redes de Ordenadores, grado obtenido en la Universidad Técnica Estatal de Quevedo (UTEQ) Ecuador, Los Ríos, Docente de la Facultad de Ciencias de la Ingeniería de la UTEQ. Correo: atorres@uteq.edu.ec

****Ing. Andrea Raquel Zúñiga Paredes, MSC**

Ingeniero en Sistemas Computacionales graduado en la Universidad de Guayaquil - Ecuador, Master en Gerencia de Innovaciones Educativas., grado obtenido en la Universidad Técnica Estatal de Quevedo (UTEQ) Ecuador, Los Ríos, Docente de la Facultad de Ciencias de la Ingeniería de la UTEQ. Correo: azuniga@uteq.edu.ec

*****Ing. Juan Carlos Pisco Vanegas, MSC**

Licenciado en Tecnologías en Electromecánica, Electrotecnología y Electrotécnia graduado en la Universidad Politécnica Estatal de San Petersburgo - Rusia, Master en Electromecánica, Electrotecnología y Electrotecnia, grado obtenido en la Universidad Politécnica Estatal de San Petersburgo - Rusia, Docente de la Facultad de Ciencias de la Ingeniería de la UTEQ. Correo: jpisco@uteq.edu.ec

******Ing. Andrés Alexander De La Torre Macías**

Ingeniero Eléctrico graduado en la Universidad Técnica Estatal de Quevedo, Correo: andres.deltorrem@gmail.com

Para citar este artículo puede utilizar el siguiente formato:

Ángel Iván Torres Quijije, Andrea Raquel Zúñiga Paredes, Juan Carlos Pisco Vanegas y Andrés Alexander De La Torre Macías (2017): "Determinación de algoritmos en máquinas soportes vectorial y redes neuronales para el diagnóstico de fallas en gases disueltos en el aceite", Revista Observatorio de la Economía Latinoamericana, Ecuador, (febrero 2017). En línea: <http://www.eumed.net/cursecon/ecolat/ec/2017/algoritmo.html>

RESUMEN

El parámetro principal que determina el estado de los transformadores de potencia en operación ya sea normal o en deterioro, es el aislamiento en su interior, compuesta de los componentes dieléctricos como el aceite y el papel que cubren el recinto del bobinado.

Anormalidades en la aislación son productos de la degradación de los componentes mencionados; formándose subproductos químicos que se derivan del envejecimiento y se acumulan en el aceite en forma de gases, como efecto principal se merma la vida útil de los transformadores.

El método más aceptado y utilizado para detectar gases en el interior de un transformador es el Análisis de Gases Disueltos (AGD), debido a que emite mayor información, permite diagnosticar probables fallas mediante técnicas convencionales de interpretación de resultados (gases en ppm) antes de que se presente en la máquina, a este tipo de fallas se las conoce comúnmente como “Fallas Incipientes”.

En el presente trabajo se tomaron muestras del AGD realizados a varios transformadores de potencia sumergidos en aceite para formar una base de datos (concentraciones de gases y falla diagnosticada), con lo que se evaluó y realizó un diagnóstico del estado a varios transformadores de potencia basado en métodos inteligentes de interpretación de datos para la predicción de fallas, estos son: Redes Neuronales Artificiales y Máquinas de Soporte Vectorial para compararlos con los criterios científicamente aceptados como: Criterio de Rogers y Criterio de Dornenburg, con el fin de determinar el método más asertivo en detectar fallas incipientes en transformadores de potencia.

Palabras claves:

Transformadores de potencia; Análisis de gases disueltos; RNA; SVM; Fallas incipientes.

ABSTRACT

The main parameter that determines the state of the power transformers in operation, whether normal or deteriorating, is the insulation inside, composed of dielectric components such as oil and paper covering the winding enclosure. Abnormalities in insulation are products of degradation of the mentioned components; Forming chemical

by-products that are derived from aging and accumulate in the oil in the form of gases, the main effect is the life of the transformers.

The most accepted and used method to detect gases inside a transformer is the Dissolved Gas Analysis (DGA), because it emits more information, allows to diagnose probable failures by means of conventional techniques of interpretation of results (gases in ppm) before which is present in the machine, this type of fault is commonly known as "Incipient Failure".

In the present work, samples of the DGA were made to several power transformers submerged in oil to form a database (gas concentrations and fault diagnosed), evaluated and performed a diagnosis of the state to several power transformers based on intelligent methods of data interpretation for the prediction of failures, these are: Artificial Neural Networks and Vector Support Machines to compare them with the criteria scientifically accepted as: Criterion of Rogers and Criterion of Dornenburg, In order to determine the most assertive method to detect incipient faults in power transformers.

Keywords:

Power transformers; Analysis of dissolved gases; DGA; SVM; Incipient failures.

1. Introducción.

Los Sistemas Eléctricos de Potencia (SEP) están comprendidos por las siguientes etapas: Generación, transmisión y distribución de la energía eléctrica, debe cumplir con un nivel aceptable de confiabilidad y calidad. La confiabilidad de un SEP en esencia depende del correcto funcionamiento de todos los elementos que lo componen, entre ellos se encuentran los transformadores de potencia, siendo una de las máquinas más costosas dentro de un sistema de transmisión o generación.

Todo transformador en funcionamiento produce gases en cierta cantidad que se mezclan con el aceite dieléctrico en su interior, cuando existe un exceso de estos gases se genera

una anomalía; ocasionando que el trafo¹ esté funcionando con calentamientos locales o a su vez con problemas eléctricos, no obstante, puede darse una combinación de ambos. Una anomalía se podría traducir como una “falla”, que puede manifestarse como esfuerzos mecánicos o eléctricos en la máquina, los cuales producen subproductos gaseosos combustibles y no combustibles como: hidrógeno (H₂), metano (CH₄), acetileno (C₂H₂), etileno (C₂H₄), etano (C₂H₆), monóxido de carbono (CO) y dióxido de carbono (CO₂) respectivamente.

Dependiendo del tipo de falla y temperatura asociada, se genera cierta combinación de gases, determinado mediante pruebas químicas como la cromatografía², pueden dar indicios del origen de la falla, la interpretación por medio de los gases utilizados para una determinación cualitativa de fallas individuales, puede resultar difícil cuando existe más de una falla, o cuando un tipo de falla progresa a otro, tal es el caso cuando un problema eléctrico se convierte en uno térmico. [1]

Se han desarrollado programas para el mantenimiento de los transformadores de potencia, pero no se ha desarrollado hasta el momento ninguna prueba de diagnóstico confiable para evaluar la condición interna de los transformadores, excepto el Análisis de Gases Disueltos (AGD) en aceites de transformadores. Es una técnica utilizada ampliamente, aceptada como una herramienta de diagnóstico para la detección de fallas incipientes en transformadores de potencia tales como: descargas internas, efectos corona, sobrecalentamiento de la celulosa, del aceite o de ambos. Los resultados obtenidos por el AGD, puede determinar prematuramente la causa de la falla, obteniendo un ahorro en costos de operación y mantenimiento, así como una mejora del nivel de confiabilidad del SEP. [2]

El presente trabajo de investigación muestra una solución al diagnóstico del contenido de los gases en el aceite, utilizando técnicas de aprendizaje supervisado para entrenamiento multiclase entre las cuales están las Redes Neuronales Artificiales (RNA) y las Máquinas de Soporte Vectorial (SVM, Support Vector Machines), esta última es una buena herramienta para la clasificación de patrones pequeños porque minimiza los errores al clasificar los datos de entrenamiento y obtiene una mejor habilidad de generalización según Jair Cervantes en su tesis doctoral del 2009 titulada “Clasificación de grandes conjunto de datos vía Maquinas de Vectores Soporte y aplicaciones en sistemas biológicos

¹ Trafo: palabra que se usa para abreviar Transformador.

² Cromatografía de gases: es una técnica en la que la muestra (de aceite) se volatiliza y se inyecta en la cabeza de una columna cromatográfica con el fin de separar los gases presentes.

” de la especialidad de Ingeniería Eléctrica del Instituto Politécnico Nacional de México.
[3]

Evaluar y determinar de forma manual la condición integral de equipos de transformación de un SEP y generar posteriormente acciones correctivas que permitan recuperar su condición, sobrepasa la capacidad logística disponible en cuanto a recurso humano y tiempo. Los transformadores de potencia son máquinas de gran dimensión y peso, en su interior contienen grandes cantidades de aceite (miles de litros) al cual se penetran gases funcionando rutinariamente, la cantidad de gases que se generan provocados por el desprendimiento de los materiales aislantes dentro de la maquina dependen tanto de factores eléctricos como térmicos, para detectar gases en el aceite de los transformadores se utiliza el AGD o cromatografía. Para interpretar los resultados existen estándares IEEE³ y normas ASTM⁴ establecidos desde décadas atrás, utilizan los métodos de Dornenberg, Rogers y Triangulo de Duval a los cuales se denotan como técnicas convencionales para la interpretación del AGD.

Aplicar análisis comparativos de los algoritmos basados en Máquinas de Soporte Vectorial y Redes Neuronales Artificiales para el diagnóstico de fallas en transformadores de potencia empleando muestras de Gases Disueltos en el aceite.

El aceite derivado del petróleo es usado como refrigerante y aislante, puede ser llamado la “sangre” de un transformador. Al igual que un médico realiza un análisis de sangre para determinar su salud, el ingeniero encargado de realizar el AGD dispone de los medios para determinar la salud de los transformadores. Pero se presenta las siguientes interrogantes: ¿Los resultados son válidos? y ¿Qué nos indican? [4]

El AGD ha sido aceptado como el estándar en la industria para la determinación de fallas incipientes⁵ en los transformadores. Siempre que el método sea seguido correctamente, los resultados obtenidos deben dar la información necesaria para tomar una decisión informada sobre el estado del funcionamiento de un transformador, pero esta decisión debe ser seleccionada de acuerdo a los métodos existentes para la interpretación de los resultados del AGD.

³ IEEE.- Instituto de Ingeniería Eléctrica y Electrónica es una asociación mundial de ingenieros dedicada a la estandarización y el desarrollo en áreas técnicas.

⁴ ASTM.- Sociedad Americana para Pruebas y Materiales fundada en 1898 es una de las organizaciones internacionales de desarrollo de normas más grande del mundo.

⁵ Fallas incipientes. - En los transformadores de potencia cierto tipo de fallas tiende a producir gases en el interior, estas fallas por lo general son fallas francas que se manifiestan como arco eléctrico y se conocen como incipientes, es decir, el inicio hacia una falla. [32]

La vida útil de los transformadores de potencia es un tema de gran interés, debido a que cumplen una función muy importante en los sistemas eléctricos de potencia, una pérdida en la etapa de transformación no prevista podrá ocasionar grandes perjuicios económicos y sociales. [5]

Por lo general, un transformador de potencia es un dispositivo muy confiable diseñado para una vida útil de 20-35 años y una vida mínima de 25 años a temperaturas de funcionamiento comprendidas entre 65 °C y 95 °C. Aunque en la práctica la vida de un transformador de potencia podría llegar a 60 años con un mantenimiento adecuado. [6]

El transformador es básicamente compuesto por material ferromagnético laminado, envuelto por bobinas de cobre aisladas con celulosa y toda esta estructura está inmersa en aceite aislante, de allí la necesidad del estudio y acompañamiento para tomar decisiones correctas sobre cómo mantenerlo, como operarlo y como protegerlo. [5]

El aceite mineral aislante, durante la operación del transformador, sufre un proceso de degradación continuo, con alteraciones en sus propiedades físicas, químicas y eléctricas provocadas por la acción de la temperatura, oxígeno, de la reacción con materiales utilizados en la construcción y por la exposición a los esfuerzos eléctricos, es decir, se tiene: deterioro de las propiedades aislantes del aceite, aceleración del proceso de degradación de la celulosa, formación de lodo, etc. [5]

La degradación del papel, a medida que el transformador envejece, su aislamiento sólido pierde resistencia mecánica. El grado de polimerización o GP mide la longitud de las moléculas de la celulosa que reacciona directamente con la resistencia mecánica de una muestra. Cuanto más larga es la cadena de moléculas (polímeros), mayor será la resistencia mecánica de la aislación. [5]

El origen de los gases de falla puede ser dividido en tres grandes categorías:

- Descarga corona o descargas parciales (descarga de baja energía).
- Arqueos o Arco eléctrico (descarga de alta energía).
- Calentamiento térmico (calentamiento interno).

Estas tres categorías difieren principalmente en la intensidad de energía, la más severa ocurre con el arqueo, en menor cantidad con el calentamiento y finalmente con descargas parciales.

Una lista de los gases de falla que pueden ser encontrados en una unidad de transformación se la detalla a continuación: [7]

a) Hidrocarburos

- Metano (CH₄)
- Etano (C₂H₆)
- Etileno (C₂H₄)
- Acetileno (C₂H₂)
- Hidrogeno (H₂)

b) Óxidos de carbono

- Monóxido de carbono (CO)
- Dióxido de carbono (CO₂)

c) Gases que no son de falla

- Nitrógeno (N₂)
- Oxígeno (O₂)

Estos gases se acumulan en el aceite, así como en la cubierta de unidades con un espacio libre por encima del aceite como resultados de varias fallas. Esta acumulación de gases se distribuye uniformemente en todo el aceite, siempre y cuando el equipo esté en funcionamiento, pero cuando el equipo está en reposo, la mayor concentración de gases tiende a subir, por lo que no es posible tener una mayor precisión en la toma de muestras cuando el transformador está parado, en el apartado de recomendaciones se hace un breve hincapié al respecto.

De acuerdo al estándar IEEE Std C57.104-2009, se han adoptado cuatro condiciones para clasificar los riesgos de un transformador, cuando no se dispone de una historia previa, para funcionamiento continuo con distintos niveles de gases combustibles. El criterio que se utiliza consiste en evaluar la concentración individual y total de todos los gases combustibles como se indica en la tabla 2, que muestra la concentración de gases combustibles en forma individual y total de acuerdo con cuatro condiciones. [8]

Condición 1: Si la totalidad de gases combustibles (TCG) se encuentra por debajo 720 partes por millón (ppm), se considera que el transformador está funcionando en condiciones satisfactorias. Si cualquier gas combustible individual supera los niveles indicados se debe realizar una investigación adicional.

Condición 2: Si la totalidad de gases combustibles se encuentra dentro del rango [721-1920] ppm, significa que el nivel de gases combustibles es superior al normal. Cualquier gas combustible individual que supere los niveles especificados se debe realizar una investigación adicional.

Condición 3: Si la totalidad de gases combustibles se encuentra dentro del rango [1921-4630] ppm, significa un alto nivel de descomposición. Cualquier gas combustible individual que exceda los límites especificados se debe realizar una investigación adicional. Probablemente se está en presencia de una o varias fallas.

Condición 4: Si la totalidad de gases combustibles se encuentra por encima de 4630 ppm, indica una excesiva descomposición. Un servicio continuo podría provocar una falla del transformador. Se debe proceder inmediatamente y con cautela.

En la práctica el AGD convencional, ha sido utilizado durante aproximadamente treinta años, y ha adquirido enorme éxito en comparación con otras técnicas [9]. La principal razón de este éxito es que la toma de muestras, los procedimientos de análisis son sencillos, de bajo costo y fácil de ser normalizados. Se han desarrollado alrededor del AGD varios estándares como: IEC599 [10], IEC599r [10], C57.104 [8]. Una aclaración que se debe hacer es que las muestras de gases no se pueden generalizar para transformadores de igual potencia, ya que cada transformador es un caso particular debido a sus características constructivas y condiciones de operación: carga, mantenimiento, historial de fallos, etc. Por tal razón los transformadores de igual tamaño arrojarán diferentes concentraciones de gases.

El estudio del método del gas más importante inicio en los laboratorios de la compañía Doble Engineering y fue resumido por primera vez en 1973 y oficialmente propuesto en la Cuadragésima primera conferencia internacional anual de clientes de la compañía Doble en el año 1974 por David Pugh. [11]

Redes neuronales artificiales (RNA).

Basados en la eficiencia de los procesos llevados a cabo por el cerebro, e inspirados en su funcionamiento, varios investigadores han desarrollado desde hace más de treinta años la teoría de las redes neuronales artificiales (RNA), las cuales emulan el comportamiento de las redes neuronales biológicas, y se han utilizado para aprender estrategias de solución basadas en ejemplos de comportamiento típico de patrones; estos sistemas no

requieren que la tarea a ejecutar se programe, ellos generalizan y aprenden de la experiencia. [12]

Redes neuronales de base Radial.

A diferencia de la disposición que se tiene en la función de activación que permite construir modelos de entrenamiento mediante back-propagation, estas nuevas redes basadas en funciones de base radial o RBF por sus siglas en inglés (radial basis function), construyen sus modelos con funciones de activación que son diferente tanto en la capa oculta como la de salida. Una red RBF como la presentada en la figura 5, está diseñada con neuronas en la capa oculta activadas mediante funciones radiales de carácter no lineal con sus centros gravitacionales propios y en la capa de salida mediante funciones lineales. [13]

El entrenamiento, a diferencia de la red usando *Back-propagation*, es solamente hacia adelante. De este modo, la salida z de una red RBF, en general, está influenciada por una transformación no lineal originada en la capa oculta a través de la función radial y una lineal en la capa de salida mediante la función lineal continua. [13]

El primer cálculo efectuado en la capa oculta es hallar en un nodo de la capa oculta la distancia radial (distancia euclidiana) d entre el vector de entrada x , con n observaciones a ese nodo en particular y el centro de gravedad c de ese mismo nodo, tal como se presenta en la ecuación. [13]

Ecuación. Distancia euclidiana.

$$d = |x - c| = \sqrt{(x_1 - c_1)^2 + (x_2 - c_2)^2 + \dots + (x_n - c_n)^2}$$

Este valor d es un componente de la entrada para activar la función radial $G(\bullet)$ (Se detallará en el trabajo final de investigación). Este valor establece la principal diferencia con las redes MLP, entre ellas la back-propagation, las cuales incluyen el producto interno en sus capas ocultas de las entradas por sus respectivos pesos.

En cuanto a la función radial $G(\bullet)$, siendo una de las más comunes $e^{(-r^2)}$, donde r es el contenido evaluado en cada nodo de la capa oculta. En este caso particular, el contenido evaluado en cada nodo es la distancia euclidiana d . De ahí la expresión, entonces sería $e^{(d^2)}$.

Una de las derivaciones del modelo RBF es emplear el ancho (desviación estándar) para activar la función $G(\bullet)$. En este caso se estaría trabajando con algo como $e^{-\frac{d^2}{2\sigma^2}}$, donde σ es el ancho para este nodo oculto.

Entre la capa oculta y la capa de salida se derivan un conjunto de pesos w que se afectan de acuerdo al algoritmo de aprendizaje. En este caso particular, es la combinación lineal entre los pesos y la resultante de cada función radial para determinar la salida z , tal como se presenta en la ecuación.

Ecuación. Salida de las capas ocultas.

$$Z = \sum w_i G(\bullet)$$

Donde $G(\bullet)$ es la salida de la capa oculta y corresponde con la función radial aplicada a la distancia euclidiana en cada una de las unidades ocultas.

Las redes neuronales probabilísticas (RNP) presentadas en la figura 5, pueden ser utilizadas para problemas de clasificación de datos. A diferencia del proceso utilizado para problemas de regresión, en el cual se realiza ajuste de pesos y *bias*, de acuerdo al error presentado; en el proceso de clasificación no se realiza ningún ajuste de pesos y solo los patrones de salida son determinados mediante la comparación y el cálculo de distancias. En la figura 1 se presenta la configuración de la red. [14]




Figura 1. Arquitectura de una RNP.

Autor: J. CADENA

Fuente: [15]

Las SVM son un tipo de clasificador derivado de la teoría estadística de aprendizaje desarrollada por Vapnik-Chervonenkis. Este clasificador ha mostrado en los últimos años

su capacidad en la clasificación y reconocimiento de patrones en general. Dado un grupo de datos distribuidos en dos clases, una SVM lineal busca un hiperplano de tal manera que la mayor cantidad de puntos de la misma clase queden en el mismo lado, mientras se maximiza la distancia de dichas clases al hiperplano. Este hiperplano minimiza el riesgo de clasificaciones erróneas en el grupo tomado para realizar el proceso de validación. [16]

El toolbox, aporta las facilidades y prestaciones graficas de MATLAB para el estudio del comportamiento de las redes: visualización grafica de la matriz de pesos y vector de desplazamiento mediante diagrama de Hinton, representaciones de errores a lo largo del entrenamiento, mapas de superficie de error en función de pesos y vector de desplazamiento, etc. Estos graficas resultan muy útiles en el estudio de la convergencia y estabilidad de los algoritmos de aprendizaje. [17]

La librería Libsvm es un conjunto de funciones en diferentes lenguajes de programación que desarrollan distintos algoritmos de máquinas de soporte vectorial. Fue realizada por Chin-Chung Chang y Chih-Jen Lin y resuelve problemas SVM de clasificación (C-SVM o un-SVM), de regresión (épsilon-SVR, un-SVR) y de estimación-distribución (SVM de una clase) tanto de clases binarias como de multiclase. [18]

En este proyecto de investigación solo se emplearon los códigos en Matlab y de entre las funciones disponibles, se hizo uso de svmtrain y svmpredict.

Svmtrain:

Es la función encargada de entrenar la SVM, se le introducen una serie de datos de entrada y genera un modelo en forma de variable tipo estructura que caracteriza nuestra SVM.

La librería Libsvm permite clasificar datos con etiquetas binarias (-1, 1) o problemas con mayor número de clases. En caso de emplear más de dos clases en el modelo de la SVM las etiquetas son positivas empezando por la numero 1 (2, 3, 4...). [18]

Svmpredict:

La función svmpredict es la encargada de ejecutar la clasificación basada en SVM. Necesita como punto de partida modelos creados a través de la función svmtrain y datos de entrada en el sistema (vectores de posición y etiqueta) y en función de estos inputs clasifica dichos datos. [18]

2. Metodología de la investigación

Este tipo de investigación es la que se aplicó en el desarrollo del presente trabajo porque consiste en la recopilación de información sobre distintos diagnósticos que se han publicado en determinación de fallas incipientes de los transformadores de potencia

mediante el análisis de gases disueltos. Para los datos de entrenamiento de métodos inteligentes se utilizaron resultados del AGD de la universidad de Shanghai China [19], del National Chin-Yi Institute of Technology de Taiwán [20], Taif University de Arabia Saudí [21] y del Jabalpur Engineering College de la India [22]. Para los datos de prueba se utilizaron resultados del AGD del College of Engineering Taif University [21].

El método de aprendizaje o de entrenamiento también denominado aprendizaje automático se utilizó en este trabajo ya que las técnicas inteligentes desarrolladas consisten en un sistema organizado que aprende cuando recibe una señal de entrada y la transforma en una de salida de acuerdo con algún principio de organización. En la figura 10 se ilustra la estructura general de un sistema de aprendizaje.



Figura 2. Estructura general: Sistema de aprendizaje.

Autor: M. Gonzales Penedo

Fuente: [23]

El aprendizaje automático se subdivide en: supervisado y no supervisado y estos a su vez están compuestos por varios métodos específicos, el cual se resume en el siguiente diagrama de la figura 3:

Figura 3.



Clasificación del aprendizaje automático.

Autor: A. De La Torre
Fuente: [23]

Con el fin de tener una idea clara de la metodología que se utilizó en este trabajo de investigación podemos escribir lo siguiente: Se utilizó la metodología de **Aprendizaje supervisado por corrección de error**, con el cual se obtuvo la solución al problema de detección de fallas en los transformadores de potencia por medio de la interpretación del AGD en el aceite, a través del entrenamiento que se le suministró a las RNA y las SVM.

El desarrollo metodológico que se elaboró en esta propuesta para dar solución al problema sobre el diagnóstico de fallas tempranas en transformadores de potencia constó de tres etapas principales, tal como se muestra, siendo así:

- a) Etapa de ingreso de datos (obtenidos del AGD en el aceite)
- b) Etapa de entrenamiento (de acuerdo a históricos tomados de diagnóstico de fallas en transformadores)
- c) Etapa de pruebas.

3. Análisis de resultados.

El siguiente histórico de datos muestra las concentraciones de gases de falla combustibles con su respectivo diagnóstico tomados de varios artículos científicos donde se aborda el problema de detección de fallas en transformadores de potencia. [19], [24], [25] y [20]

Estas muestras fueron tomadas en varios transformadores de potencia comprendidos entre los 5 MVA y 100 MVA de potencia nominal. Por lo que podemos generalizar el estudio, con los transformadores que estén dentro del rango de potencia estudiada en esta investigación.

En las tablas 1, 2, 3 y 4 se muestran los datos tomados para el entrenamiento y en las tablas 5 y 6 se muestran los datos tomados para las pruebas.

Tabla 1. Datos de entrenamiento tomados de “Fault Diagnosis of Power Transformer Based on multi-layer SVM Classifier”

Casos de entrenamiento	Concentraciones de gases en PPM					Estado del transformador (Diagnostico actual)	Clase N°
	H2	CH4	C2H6	C2H4	C2H2		
1	40,8	3	3,6	3,5	7,4	Descarga de alta energía	1
2	23	12	12	10	61	Descarga de alta energía	1
3	57	13	0,1	11	12	Descarga de alta energía	1
4	31	6,6	19	4,7	67	Descarga de alta energía	1
5	285	36,3	75	8,4	133	Descarga de alta energía	1
6	5283	179	320	3020	2314	Descarga de alta energía	1
7	335	67	18	143	170	Descarga de alta energía	1
8	44	12,2	3,4	3,2	17,4	Descarga de alta energía	1
9	42	62	5	63	73	Descarga de alta energía	1

Autor: A. DE LA TORRE

Fuente: [19]

Tabla 1. Datos de entrenamiento tomados de “ANN Approach for Condition Monitoring of Power Transformers Using DGA”

Casos de entrenamiento	Concentraciones de gases en PPM					Estado del transformador (Diagnostico actual)	Clase N°
	H2	CH4	C2H6	C2H4	C2H2		
1	24	13	5	43	319	Descarga de alta energía	1
2	127	24	0	32	81	Descarga de alta energía	1
3	127	107	11	154	224	Descarga de alta energía	1
4	212	38	15	47	78	Descarga de alta energía	1
5	274	27	5	33	97	Descarga de alta energía	1
6	307	22	2	33	109	Descarga de alta energía	1
7	416	695	74	867	0	Descarga de alta energía	1
8	441	207	43	224	261	Descarga de alta energía	1
9	800	1393	304	2817	3000	Descarga de alta energía	1
10	858	1324	208	2793	7672	Descarga de alta energía	1

Autor: A. DE LA TORRE

Fuente: [26]

Tabla 32. Datos de entrenamiento tomados de “Diagnosis of Incipient Faults in Power Transformers Using CMAC Neural Network Approach”

Casos de	Concentraciones de gases en PPM					Estado del	Clase
----------	---------------------------------	--	--	--	--	------------	-------

entrenamiento	H2	CH4	C2H6	C2H4	C2H2	transformador (Diagnostico actual)	Nº
1	127	107	11	154	224	Descargas de alta energía	1
2	60	40	6,9	110	70	Descarga de alta energía	1
3	200	48	14	117	131	Descarga de alta energía	1
4	32,4	5,5	1,4	12,6	13,2	descarga de alta energía	1
5	345	112,3	27,5	51,5	58,8	Descargas de baja energía	2
6	565	53	34	47	0	Descarga de baja energía	2
7	980	73	58	12	0	Descarga de baja energía	2
8	650	53	34	20	0	Descarga de baja energía	2
9	14,7	3,7	10,5	2,7	0,2	Estado normal	3
10	181	262	41	28	0	Sobrecalentamiento	4

Tabla 4. Datos de entrenamiento tomados de “A Novel Association Rule Mining with IEC Ratio Based Dissolved Gas Analysis for Fault Diagnosis of Power Transformers”

Casos de entrenamiento	Concentraciones de gases en PPM					Estado del transformador (Diagnostico actual)	Clase Nº
	H2	CH4	C2H6	C2H4	C2H2		
1	1,7011	1,1971	0,8177	0,117	0,1293	Descarga de alta energía	1
2	1,3229	0,4296	0,04557	0,0002	0,0131	Descarga de alta energía	1
3	29,9914	1,8591	0,5192	0,7374	0,0591	Descarga de alta energía	1
4	2,7011	1,1871	0,7167	0,217	0,2293	Descarga de alta energía	1
5	30,991	2,8591	0,6192	0,6374	0,0691	Descarga de alta energía	1
6	8,6976	1,0636	2,1259	0,5134	0,5348	Descarga de alta energía	1
7	1,8012	1,231	0,6167	0,113	0,2133	Descarga de alta energía	1
8	5,3862	0,4166	0,28271	0,0477	0,0004	Descarga de baja energía	2
9	4,3368	1,0566	0,9231	0,2002	0,0025	Descarga de baja energía	2
10	5,7787	0,5458	0,07298	0,1546	0,0069	Descarga de baja energía	2

Autor: A. DE LA TORRE

Fuente: [22]

Tabla 5. Datos de prueba tomados de “Artificial Neural Networks for Power Transformers Fault Diagnosis Base don IEC Code Using Dissolved Gas Analysis”

Casos de Prueba	Concentraciones de gases en PPM					Estado del transformador (Diagnostico actual)	Clase Nº
	H2	CH4	C2H6	C2H4	C2H2		
1	21	34	5	47	62	Descarga de alta energía	1
2	1607	615	80	916	1294	Descarga de alta energía	1
3	127	107	11	154	224	Descarga de alta energía	1
4	60	40	6,9	110	70	Descarga de alta energía	1

5	34,45	21,3	3,19	45	19,62	Descarga de alta energía	1
6	86	30	10	35	29	Descarga de alta energía	1
7	59,3	41	9,9	111	70	Descarga de alta energía	1
8	469	147	12,5	265	520	Descarga de alta energía	1
9	980	73	58	12	0,01	Descarga de baja energía	2
10	980	73	58	12	0,01	Descarga de baja energía	2

Autor: A. DE LA TORRE

Fuente: [21]

Tabla 6. Datos de prueba tomados de “Fault Diagnosis of Power Transformer Based on multi-layer SVM Classifier”

Casos de Prueba	Concentraciones de gases en PPM					Estado del transformador (Diagnostico actual)	Clase N°
	H2	CH4	C2H6	C2H4	C2H2		
1	293	50	13	115	120	Descargas de alta energía	1
2	443	85	9,5	103	174	Descargas de alta energía	1
3	35	25	0	23	22	Descargas de alta energía	1
4	980	73	58	12	0	Descargas de alta energía	1
5	160	90	27	17	5	Estado normal	1
6	176	206	47,7	75,7	68,7	Estado normal	1
7	565	93	34	47	0	Sobrecalentamiento	1
8	150	53	34	20	0	Sobrecalentamiento	1
9	10	4	3	33	6	Sobrecalentamiento	1
10	14,7	3,8	10,5	2,7	0,2	Sobrecalentamiento	1

Autor: A. DE LA TORRE

Fuente: [19]

Normalización de datos

Las Redes Neuronales como las Máquinas de Soporte Vectorial pueden ser más eficientes si pre-procesamos los datos de entrada y de salida. Por ejemplo, ciertas redes prefieren valores en el rango ideal de 0 a 1 (real de 0.1 a 0.9) mientras otras redes prefieren datos en el rango ideal de -1 a 1 (real de -0,9 a 0,9), esto se conoce como normalización de datos. [27]

Para ilustrar como se realiza la normalización, se muestra el siguiente ejemplo con el primer descriptor (H2) del primer dato de entrenamiento de la tabla.

$$H_2 \text{ min} = 0$$

$$Dato = 40,8 \quad H_2 \text{ max} = 17000$$

$$Dato_{Norm} = (dato - H_2 \text{ min}) / (H_2 \text{ max} - H_2 \text{ min})$$

$$Dato_{Norm} = (40,8 - 0) / (17000 - 0)$$

$$Dato_{Norm} = 0,0024$$

Este procedimiento se realizó para cada dato de entrada, es decir para cada concentración de gas, tomando los valores mínimos y máximos de las muestras, a continuación, se presenta una tabla con los datos normalizados obtenidos y en el apartado de anexos se muestran las restantes.

Tabla 7. Datos de entrenamiento normalizados tomados de “Fault Diagnosis of Power Transformer Based on multi-layer SVM Classifier”

Datos de entrenamientos normalizados	H2'	CH4'	C2H6'	C2H4'	C2H2'	Clase Nº
1	0,002400	0,000012	0,000043	0,000039	0,000463	1
2	0,001353	0,000094	0,000143	0,000112	0,003813	1
3	0,003353	0,000103	0,000001	0,000124	0,000750	1
4	0,001824	0,000045	0,000226	0,000053	0,004188	1
5	0,016765	0,000315	0,000893	0,000094	0,008313	1
6	0,310765	0,001612	0,003810	0,033933	0,144625	1
7	0,019706	0,000594	0,000214	0,001607	0,010625	1
8	0,002588	0,000095	0,000040	0,000036	0,001088	1
9	0,002471	0,000548	0,000060	0,000708	0,004563	1
10	0,003529	0,000348	0,000118	0,001236	0,004375	1

Autor: A. DE LA TORRE

Fuente: A. DE LA TORRE

Los casos de prueba se normalizaron de igual manera que los casos de entrenamiento, tomando los valores máximos y mínimos de los descriptores de los casos de entrenamiento. En el apartado de anexos se muestran ambas tablas con los datos normalizados.

Tabla 8. Datos de prueba normalizados tomados de “Artificial Neural Networks for Power Transformers Fault Diagnosis Base don IEC Code Using Dissolved Gas Analysis”

Datos de prueba normalizados	H2'	CH4'	C2H6'	C2H4'	C2H2'	Clase Nº
1	0,011864	0,009295	0,004673	0,005521	0,047913	1
2	0,907910	0,169362	0,074766	0,108000	1,000000	1
3	0,071751	0,029407	0,010280	0,018140	0,173107	1
4	0,033898	0,010948	0,006449	0,012951	0,054096	1
5	0,019463	0,005797	0,002981	0,005285	0,015162	1
6	0,048588	0,008193	0,009346	0,004106	0,022411	1
7	0,033503	0,011224	0,009252	0,013069	0,054096	1
8	0,264972	0,040427	0,011682	0,031229	0,401855	1
9	0,553672	0,020040	0,054206	0,001394	0,000008	2
10	0,553672	0,020040	0,054206	0,001394	0,000008	2

Autor: A. DE LA TORRE

Fuente: A. DE LA TORRE

Como se puede observar en la tabla 9 correspondiente a los datos de prueba normalizados, estos son valores pequeños, con los cuales la SVM no proporciona un adecuado OSH que separe satisfactoriamente las clases, debido a esto se realiza un escalamiento a los datos después de ser normalizados.

Resultados obtenidos del entrenamiento de la RNA

Como se explicó en el apartado 3.5.1.1 para el ensamble clasificador adoptado por la Red Neuronal se diseñaron varias redes en la librería nntool de Matlab para obtener el mejor valor de asertividad. Para lo cual se empleó la red tipo feed-forward backpropagation, en la etapa de entrenamiento se empleó la función traingdm, para el proceso de aprendizaje la función learnngdm y la función de rendimiento de error medio cuadrático (MSE).

Con lo anterior se obtuvieron los siguientes resultados mostrados:

Tabla 3. Pruebas con distintas redes neuronales.

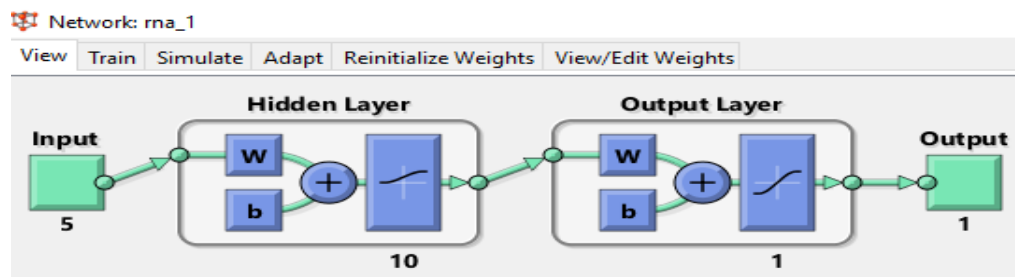
N° de red	N° de Capas	N° de neuronas	N° de entrenamientos	% de asertividad
1	1	5	5	63%
2	1	10	5	55%
3	2	5	5	78%
4	2	10	5	84%
5	3	5	5	45%

Autor: A. DE LA TORRE

Fuente: A. DE LA TORRE

De acuerdo a los resultados obtenidos con diferentes modelados de redes neuronales, se constató que la Red #4 es la más eficiente respecto a las otras redes, para lo cual se detallan los resultados obtenidos con los 10 datos de prueba y sus respectivas clases actuales versus la de la Red Neuronal. Se creó la red neuronal rna_1 como se muestra en la figura 4 con 2 capas ocultas y 10 neuronas.

Figura 4. Red Neuronal Personalizada.




Autor: A. De La Torre

Fuente: A. De La Torre

Con el primer entrenamiento de la red neuronal creada se obtuvieron los siguientes resultados mostrados en las imágenes 4, 5, 6 en cuanto a rendimiento, estado de entrenamiento y regresión respectivamente.

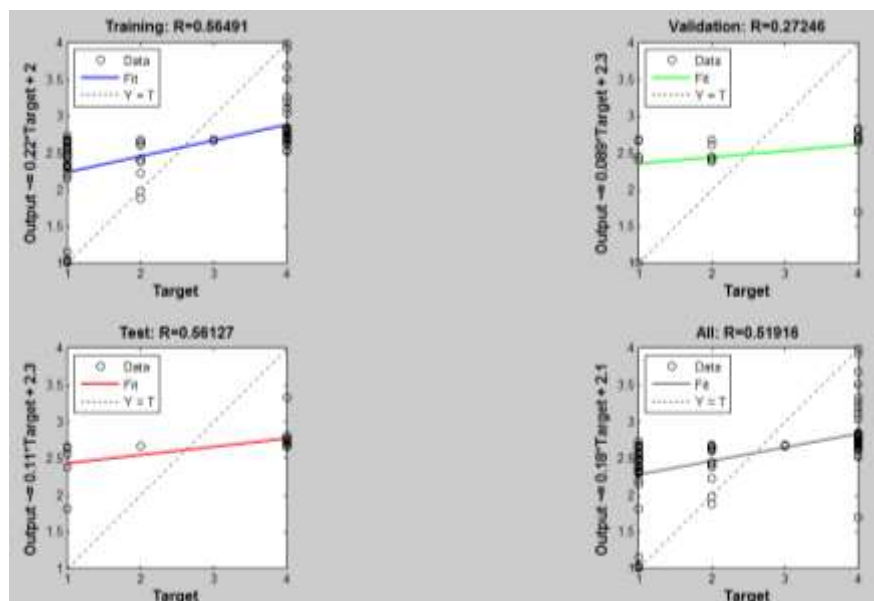
Figura 51. Estado de entrenamiento.



Autor: A. De La Torre

Fuente: A. De La Torre

Figura 62. Estado de regresión.



Autor: A. De La Torre

Fuente: A. De La Torre

En el apartado de anexos se muestran las gráficas luego de entrenar 5 veces la red neuronal creada, para observar el mejoramiento que presenta la gráfica del estado de regresión.

En la siguiente tabla se muestra los resultados de las clases obtenidas, y de color amarillo se identifican los casos que no fueron acertados por la metodología de las Redes Neuronales.

Tabla 4. Clases pronosticadas mediante RNA.

Casos	Estado Actual	Clase actual	Clase RNA	pronosticada
1	Descarga de alta energía	1		1
2	Descarga de alta energía	1		1
3	Descarga de alta energía	1		1
4	Descarga de alta energía	1		1
5	Descarga de alta energía	1		1
6	Descarga de alta energía	1		1
7	Descarga de alta energía	1		2
8	Descarga de alta energía	1		1
9	Descarga de alta energía	1		2
10	Descarga de alta energía	1		1

Autor: A. DE LA TORRE

Fuente: A. DE LA TORRE

Resultados obtenidos de la SVM como clasificador multiclase

En la tabla 11 se muestran los resultados obtenidos mediante el método de las Máquinas de Soporte Vectorial, en el apartado de anexos se muestra el código *sample.mat* creado para simular el método expuesto el cual cuenta con una recopilación de scripts implementando los toolbox de Libsvm. De la misma manera aquí se muestra los resultados de las clases obtenidas, y de color amarillo se identifican los casos que no fueron acertados por la metodología de las SVM.

Tabla 5. Clases pronosticadas mediante SVM.

Casos	Estado Actual	Clase actual	Clase SVM	pronosticada
1	Descarga de alta energía	1		1
2	Descarga de alta energía	1		1
3	Descarga de alta energía	1		1
4	Descarga de alta energía	1		1
5	Descarga de alta energía	1		1
6	Descarga de alta energía	1		1

7	Descarga de alta energía	1	1
8	Descarga de alta energía	1	1
9	Descarga de alta energía	1	1
10	Descarga de alta energía	1	1
11	Descarga de baja energía	2	2

Comparación entre diferentes metodologías

Un estudio comparativo del diagnóstico de fallas en transformadores, determinado por los varios métodos con los 10 casos de prueba se ilustra en la tabla 12. Allí se visualiza los resultados dados por los reportes de los diferentes artículos (diagnostico actual), los entregados por la Red Neuronal (RNA), los entregados por la Máquina de Soporte Vectorial SVM, y aplicando los métodos convencionales de interpretación de fallas como: Rogers y Dornenburg.

Tabla 6. Comparación de metodologías para diagnóstico de fallos.

Casos	Método de Rogers	Método de Dornenburg	RNA	SVM	Diagnostico Actual
1	N.A.	N.A.	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía
2	Descarga de alta energía	N.A.	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía
3	Descarga de alta energía	N.A.	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía
4	Descarga de alta energía	N.A.	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía
5	N.A.	N.A.	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía
6	Descarga de alta energía	N.A.	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía
7	Sobrecalentamiento	Sobrecalentamiento	Descarga de baja energía	Descarga de alta energía	Descarga de alta energía
8	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía
9	Descarga de alta energía	Descarga de alta energía	Descarga de baja energía	Descarga de alta energía	Descarga de alta energía
10	Descarga de alta energía	N.A.	Descarga de alta energía	Descarga de alta energía	Descarga de alta energía

Autor: A. DE LA TORRE

Fuente: A. DE LA TORRE


4. Discusión.

En las tablas 10 y 11 se aprecia que los resultados dados por los reportes de las publicaciones citadas y los entregados por la red neuronal coinciden a excepción de los casos 7, 9. En cuanto a la máquina de soporte vectorial se observa que no coinciden otros casos denotados en la investigación.

Como se observó en la tabla 12 solo se muestran los resultados de dos metodologías convencionales: Rogers y Dornenburg, quedaron excluidas los métodos de Duval y Gases claves debido a que estos están por debajo del grado de asertividad de los dos métodos expuestos en este trabajo, como se señala en la publicación de la Universidad Distrital Francisco de Caldas titulada “Estado del arte del análisis de gases disueltos en transformadores de potencia” del año 2014. Aun así, se concluye una buena aproximación de la metodología propuesta, con respecto a lo entregado aplicando Rogers y Dornenburg.


Para analizar los resultados presentados, se realiza un gráfico comparativo, en el cual se puede observar la efectividad de las diferentes metodologías con las cuales se puede realizar un diagnóstico de un transformador de potencia empleando muestras del análisis de gases disuelto en el aceite AGD.

Figura 7. Grafica de casos acertados entre métodos estudiados.



Autor: A. DE LA TORRE
Fuente: A. DE LA TORRE

Figura 3. Grafica de Asertividad entre métodos estudiados.



Autor: A. DE LA TORRE

Fuente: A. DE LA TORRE

Como se puede notar en la gráfica 7 y 8, la Máquina de Soporte Vectorial es la técnica que mejores resultados entrega. Se observan los casos en que este método acierta para obtener un mejor resultado comparativo respecto a las otras técnicas.

5. Conclusiones

De acuerdo a los objetivos planteados se obtuvieron los siguientes resultados:

Al seleccionar un histórico de datos del AGD en transformadores de potencia sometido a diagnósticos reales, se obtuvo una fuente confiable de valores de ingreso para los modelos tanto de las RNA y las SVM, los cuales serían los descriptores del problema que ayudaron a la salida del clasificador (ver figura 6).

Al utilizar técnicas inteligentes para proporcionar una solución al problema planteado, se pudo observar que las máquinas de soporte vectorial SVM, obtiene mejores resultados que utilizando redes neuronales artificiales RNA. Lo anterior se debe a que las SVMs pueden generalizar de una mejor forma cuando se cuenta con una base de datos relativamente pequeña, como es el caso actual. Si se desea mejorar la respuesta de salida de la RNA, una forma es obtener más datos para la etapa de entrenamiento.

De acuerdo al estudio comparativo realizado, se pudo establecer que el método de Maquinas de Soporte Vectorial está por encima en cuanto a asertividad respecto a los métodos convencionales y redes neuronales, esto se debe a que los métodos convencionales utilizan una relación de gases que no siempre se puede satisfacer ya que se

observó que en algunos casos se incurrió en una indeterminación. A diferencia de los métodos inteligentes, los cuales aprenden en base a los ejemplos introducidos, siempre van a darnos un resultado más no una indeterminación.

BIBLIOGRAFIA

- [1] J. DiGiorgio, «Technnical bulletin dissolved gas analysis,» NTT, Sacramento, 2013.
- [2] J. M. Cadena Zapata y J. A. Cadena Zapata, «Aplicación de redes neuronales probabilísticas en la detección de fallas incipientes en transformadores,» *Scientia et Technica* , vol. XIV, nº 39, pp. 48-53, 2008.
- [3] J. Cervantes Canales, *Clasificación de grandes conjuntos de datos vía Máquinas de Vectores Soporte y aplicaciones en sistemas biológicos*, México D.F.: Centro de investigación y de estudios avanzados del Instituto Politécnico Nacional, 2009.
- [4] AMPERIS PRODUCTS SL, «AMPERIS,» 2013. [En línea]. Available: <http://www.amperis.com/recursos/articulos/analisis-gases-disueltos/>. [Último acceso: 5 1 2016].
- [5] C. Jara y D. M. , «Análisis del estado y la vida remanente de un transformador elevador de 275 MVA, 18KV/550KV,» *X SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRÉ*, pp. 1-10, 2012.
- [6] W. F. y E. M. , «Vida de transformadores de potencia sumergidos en aceite aislante: Situación actual,» *IEEE Latin America Transactions*, vol. 5, nº 1, 2007.
- [7] A. Carrera Gómez, *Análisis de gases disueltos en el aceite para el mantenimiento preventivo a transformadores de potencia mediante la implementación de software*, México D.F., 2013.
- [8] IEEE, «IEEE,» 2 Febreeo 2009. [En línea]. Available: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4776518&isnumber=4776517>. [Último acceso: 1 Febrero 2016].
- [9] Duraisamy y Deverajan, «Neural fuzzy schemes for fault detection in power transformer,» *Applied Soft Computing*, vol. VII, nº 7, pp. 534-539, 2007.
- [10] Z. Wang, *Artificial intelligence application in the diagnosis of power transformer incipient faults*, Virginia: Virginia Polytechnic Institute, 2000.
- [11] D. Pugh, «Advances in Fault Diagnosis by Combustible Gas Analysis,» de *Minutes of Forty-First International Conference of Doble* , Watertown, 1974.
- [12] Universidad Tecnológica de Pereira, «Universidad Tecnológica de Pereira,» 4 2000. [En línea].

Available: <http://ohm.utp.edu.co:16080/neuronales/main.htm>. [Último acceso: 15 1 2016].

- [13] C. G, *Curso de Redes Neuronales*, Merida: Universidad de los Andes, 2008.
- [14] MATH WORKS, «The MathWorks, Inc.,» 2 Febrero 2015. [En línea]. Available: <http://es.mathworks.com/discovery/redes-neuronales.html>. [Último acceso: 4 Julio 2016].
- [15] J. A. Cadena Zapata, *Diagnóstico de fallas en transformadores de potencia*, Pereira: Universidad Tecnológica de Pereira, 2009.
- [16] R. Henao, *Selección de hiperparámetros en máquinas de soporte*, Pereira: Tesis de postgrado - Universidad Nacional de Pereira, 2004.
- [17] B. M. YESSENIA, «RECONOCIMIENTO Y CLASIFICACION DE ROSAS UTILIZANDO R.N.A Y MANTENIMIENTO DE INVENTARIO EN UN SITIO WEB,» *TESIS DE GRADO DE LA UNIVERSIDAD TECNOLÓGICA EQUINOCCIAL*, vol. I, nº 1, pp. 62-64, 2011.
- [18] R. O. Víctor, «Reconocimiento de localizaciones mediante Máquinas de Soporte Vectorial,» *Proyecto fin de carrera de la Universidad Carlos III de Madrid*, pp. 60-90, 2012.
- [19] L. Ganyun , C. Haozhong, Z. Haibao y D. Lixin, «Fault diagnosis of power transformer based on multi-layer SVM classifier,» *Electric power systems research* , vol. DXXV, pp. 9-15, 2005.
- [20] H. Chin-Pao y W. Mang-Hui, «Diagnosis of incipient faults in power transformers using CMAC neural network approach,» *Electric power systems research* , vol. DXXI, pp. 235-244, 2004.
- [21] S. Ghoneim y I. Taha, «Artificial neural networks for power transformers fault diagnosis based on IEC code using dissolved gas analysis,» *International journal of control automation and systems*, vol. IV, nº 2, pp. 18-21, 2015.
- [22] K. Shrivastava y A. Choubey, «A novel association rule mining with IEC ratio based dissolved gas analysis for fault diagnosis of power transformers,» *International journal of advanced computer research*, vol. II, nº 2, pp. 34-44, 2012.
- [23] M. Gonzales Penedo, *Aprendizaje y Entrenamiento*, Coruña: Universidad da Coruña, 2014.
- [24] S. SARMA y G. KALYANI , «Application of AI Techniques for non destructive evaluation of power transformers using DGA,» *International Journal of Innovations in Energy System and Power*, vol. II, nº 1, pp. 37-43, 2007.
- [25] H.-C. Sun, Y.-C. Huang y C.-M. Huang, «A review of Disolved Gas Analysis in Power Transformers,» *ELSEVIER*, pp. 1220-1225, 2011.
- [26] S. SARMA y KALYANI, *ANN Approach for Condition Monitoring of Power Transformers Using DGA*, Warangal: IEEE, 2004.

- [27] L. SERGIO, «Las Redes Neuronales implementacion y consideraciones prácticas,» *Fifth Mexican International Conference on Artificial Intelligence*, pp. 14-15, 24 Noviembre 2013.