



Ingeniería

ISSN: 0121-750X

ISSN: 2344-8393

Universidad Distrital Francisco José de Caldas

Alvarez Q., Laura I.; Lozano M., Carlos A.; Bravo M., Diego A.
Metodología para el mantenimiento predictivo de transformadores
de distribución basada en aprendizaje automático
Ingeniería, vol. 27, núm. 3, e202, 2022, Septiembre-Diciembre
Universidad Distrital Francisco José de Caldas

DOI: <https://doi.org/10.14483/23448393.17742>

Disponible en: <https://www.redalyc.org/articulo.oa?id=498873733004>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

UAEM redalyc.org

Sistema de Información Científica Redalyc
Red de Revistas Científicas de América Latina y el Caribe, España y Portugal
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso
abierto

Metodología para el mantenimiento predictivo de transformadores de distribución basada en aprendizaje automático

Methodology for Predictive Maintenance of Distribution Transformers based on Machine Learning

Laura I. Alvarez Q¹, **Carlos A. Lozano M¹**, **Diego A. Bravo M²***,

¹Escuela de Ingeniería Eléctrica y Electrónica, Universidad del Valle. Santiago de Cali, Valle del Cauca, Colombia., ²Departamento de Física, Universidad del Cauca. Popayán, Cauca, Colombia.

*Correspondence email: dibravo@unicauca.edu.co

Received: 10th-March-2021. Modified: 16th-November-2021. Accepted: 2nd-March-2022

Abstract

Context: In this paper, we describe a methodology set up to schedule the predictive maintenance of distribution transformers in the Department of Cauca (Colombia) by means of machine learning.

Method: The proposed methodology relies on a predictive classification model that finds the minimum number of distribution transformers prone to failure. To verify this, the model was implemented and tested with real data in the Department of Cauca (Colombia).

Results: It is possible to achieve an effective solution for scheduling the predictive maintenance of distribution transformers by means of machine learning.

Conclusions: The proposed model is an effective tool for problems involving the scheduling of preventive maintenance scheduling problems for distribution transformers.

Keywords: Distribution Transformers, Machine Learning, Predictive maintenance.

Acknowledgements: The authors would like to express their gratitude to Compañía Energética de Occidente [Western Energy Company] for facilitating the data on distribution transformers in the Department of Cauca (Colombia); and to Universidad del Valle and Universidad del Cauca for the academic and scientific resources granted during this project.

Language: Spanish.

Open access



Cite as: Alvarez, L., Lozano, C., Bravo, D. "Metodología para el mantenimiento predictivo de transformadores de distribución basada en aprendizaje automático". *Ing.* vol. 27, no. 3, 2022. e17742.

<https://doi.org/10.14483/23448393.17742>

© The authors; reproduction right holder Universidad Distrital Francisco José de Caldas.

Resumen

Contexto: En este artículo describimos una metodología que se ha establecido para programar el mantenimiento predictivo de transformadores de distribución en el Departamento del Cauca (Colombia) mediante aprendizaje automático.

Método: La metodología propuesta se basa en un modelo predictivo de clasificación que encuentra el número mínimo de transformadores de distribución propensos a fallar. Para verificar esto, el modelo fue implementado y probado con datos reales en el Departamento del Cauca (Colombia).

Resultados: Es posible lograr una solución efectiva para programar el mantenimiento predictivo de los transformadores de distribución mediante el uso de aprendizaje automático.

Conclusiones: El modelo propuesto es una herramienta eficaz para los problemas de programación del mantenimiento preventivo de los transformadores de distribución.

Palabras clave: transformadores de distribución, aprendizaje automático, mantenimiento predictivo.

Agradecimientos: Los autores de este trabajo desean expresar sus agradecimientos a la Compañía Energética de Occidente por facilitar los datos de los transformadores de distribución del Departamento del Cauca (Colombia) y a la Universidad del Cauca y la Universidad del Valle por todos los recursos académicos y científicos prestados durante la realización de este proyecto.

1. Introducción

Actualmente, en el departamento de Cauca, el mantenimiento a los transformadores de distribución tiene un enfoque más correctivo que preventivo. Según datos de la Compañía Energética de Occidente en el 2016 se tuvo un reporte de 1.297 transformadores quemados, lo que significó elevados costos por su reposición y por la energía no suministrada debido a la suspensión de servicio. Se registran diversas causas de quema, como manipulación por terceros, sobrecarga, fuga de aceite, falta de poda por baja tensión, y la más recurrente: descarga atmosférica. Debido a fallas en la programación de un adecuado plan de mantenimiento preventivo y al difícil acceso a algunos transformadores rurales, no todos los equipos cuentan con las protecciones (Dispositivo de protección contra sobretensiones **DPS**, cortacircuitos, fusibles, sistema de puesta a tierra e interruptor por baja tensión si aplica) instaladas adecuadamente para afrontar las condiciones de operación y garantizar su continuo funcionamiento. Es entonces cuando surge la necesidad de elaborar planes de mantenimiento preventivo que ayuden a evitar o disminuir el riesgo de falla, con base en los requerimientos del regulador del sector eléctrico, mejorar la calidad del servicio a los clientes y mejorar el uso de los recursos asignados al área de mantenimiento [1].

La gestión del mantenimiento para una empresa de distribución de energía eléctrica busca prevenir o disminuir el riesgo de falla, recuperar el desempeño, incrementar la vida útil de sus activos, cumplir con las normas técnicas, ambientales y de seguridad vigentes mejorando los índices de confiabilidad y la imagen empresarial mediante la calidad del servicio [2]. Se hace diferencia entre tres tipos de mantenimiento: correctivo, preventivo y predictivo. El mantenimiento correctivo se basa en reparar las fallas a medida que estas ocurren, no requiere ninguna planificación y para realizarlo se suspenden los procesos abruptamente. El mantenimiento preventivo tiene un carácter más sistemático, se realiza en tiempos y rutinas de actividades programadas que monitorean el estado del equipo buscando mantener su funcionamiento y reducir el desgaste. Por último, el mantenimiento

predictivo emplea datos históricos para predecir eventos futuros. Normalmente, los datos históricos se utilizan para crear un modelo matemático que capture las tendencias importantes. Este modelo predictivo se usa entonces con los datos actuales para predecir lo que pasará a continuación, o bien para sugerir acciones que llevar a cabo con el fin de obtener resultados óptimos. El mantenimiento predictivo ha recibido mucha atención en los últimos años debido a los avances en la tecnología que lo respalda, especialmente en las áreas de big data y aprendizaje automático [3], [4].

En el sector eléctrico existen varias técnicas de implementación tales como el Mantenimiento Centrado en la Confiabilidad (RCM), el mantenimiento basado en el riesgo (RBM), el Mantenimiento Productivo Total y el Análisis Causa Raíz. El RCM es una técnica para elaborar un plan de mantenimiento que disminuye las interrupciones de los procesos, en este caso en particular suspensiones en el servicio de energía eléctrica, por averías imprevistas. Para esto se analizan los fallos potenciales del sistema a profundidad y se identifican las acciones a realizar para evitarlos. El RBM tiene en cuenta los riesgos del sistema, no solo considera la probabilidad de ocurrencia de la falla sino también sus consecuencias [3]. Al combinar este análisis del riesgo con los requisitos financieros y los recursos humanos de la empresa distribuidora de energía, es posible priorizar los programas de mantenimiento y mejorar los resultados [5], [6].

En este trabajo se propone usar el aprendizaje automático como técnica de clasificación debido a la naturaleza y volumen de los datos; con ella será posible planificar los recursos asignados al mantenimiento [?] prediciendo comportamientos futuros [7], ajustado a las características de la empresa y sin desarrollar un modelo matemático complejo [?], [8]. El artículo está estructurado de la siguiente manera: la sección siguiente está dedicada a la metodología usada para el mantenimiento predictivo de los transformadores usando aprendizaje automático, seguida por los resultados y finalizando con las conclusiones del artículo.

2. Metodología para el mantenimiento predictivo en transformadores de distribución

Representar adecuadamente un sistema real mediante un modelo determinístico depende directamente de la relación explícita entre las variables de dicho sistema [9]. Para este caso en específico, la naturaleza estocástica del sistema de distribución y sus elementos no permite relacionar de forma directa y numérica las variables que intervienen en el proceso; por tal motivo, la metodología que se presenta a continuación tiene en cuenta las condiciones de operación de los elementos, las características climáticas de la región, el historial de fallas de años anteriores y el riesgo asociado a las mismas para el operador de red. El análisis y la optimización de toda la información se realizan mediante aprendizaje automático, a partir de estudios netamente estadísticos y probabilísticos para identificar el plan de mantenimiento más adecuado.

A continuación se describe cada una de las etapas de la metodología diseñada (figura 1) para el sistema de distribución de energía eléctrica en el departamento de Cauca (Colombia), específicamente a los transformadores de distribución como elemento objetivo de la red:




Figura 1. Diagrama de flujo de la metodología propuesta.

1. **Definición del alcance de la metodología:** el objetivo de esta metodología es predecir, con base en las condiciones de operación de los elementos, las características climáticas de la región, el historial de fallas de años anteriores y el riesgo asociado a las mismas para el operador de red; los transformadores que probablemente presentarán falla por quema en el periodo futuro de un año (2021) y el plan de mantenimiento adecuado según la causa más probable para evitar el evento de falla en el departamento de Cauca.
2. **Definición del contexto operacional de los equipos:** los transformadores analizados son activos de distribución conectados a la red del operador a niveles de tensión de 13,2 [kV] y 34,5 [kV], ubicados en zonas rurales y urbanas del departamento de Cauca. Se debe tener en cuenta que se presentan condiciones de alta vegetación y alto nivel ceráunico en este departamento, por lo cual hay un número significativo de quemados por cortos en baja tensión y descargas atmosféricas respectivamente. También es importante destacar que una gran cantidad de estos activos que se encuentra en sectores rurales que son de difícil acceso por la topografía de la región y no es viable económicamente un seguimiento regular debido al valor del equipo. Por la misma condición de lejanía, muchos de ellos se encuentran con deficiencias en los sistemas de puesta a tierra, conductor de red de baja tensión, cortacircuitos y ubicación óptima de los DPS.
3. **Identificación del conjunto de transformadores de distribución bajo estudio:** para este proyecto se toma como universo del sistema todos aquellos transformadores de distribución conectados a niveles de tensión de 13,2 [kV] y 34,5 [kV], ubicados en zonas rurales y urbanas del departamento de Cauca, propiedad de la empresa distribuidora que implementará el plan de mantenimiento. Es necesario hacer énfasis en que se excluyen transformadores de propiedad particular (terceros), del gobierno, y todo aquel que no sea responsabilidad directa del operador de red. Este universo está conformado por 15869 transformadores que

cumplen con el contexto operativo y los intereses de la compañía en sectores residenciales, comerciales, industriales y oficiales.

4. **Identificación de los eventos de falla en el periodo de estudio:** se realiza un recopilación de información exhaustiva desde el año 2015 hasta el 2020, detectando 6.792 eventos de falla. Su distribución en tiempo se presenta en la tabla I.

Tabla I. Cantidad de eventos de falla registrados desde el año 2015 hasta el 2020.

Año	2015	2016	2017	2018	2019	2020	Total
Número de fallas	2.108	1.297	995	871	869	652	6.792

Cada evento de falla registra su incidencia o identificador de evento que es único, el elemento sobre el cual ocurre la falla (código del transformador; se encuentran varias incidencias sobre un mismo transformador, es decir transformadores en los que reincide la falla), la fecha y la hora de inicio y finalización de la incidencia (desde que se registra la falla reportada por los usuarios hasta que se restablece el servicio) y la causa probable evidenciada por la brigada que atendió la falla.

5. **Identificación de las variables más representativas y relevantes para el sistema:** como variables representativas y relevantes para el sistema se han tomado las siguientes:

- **Tasa de quema:** variable basada en la confiabilidad del sistema y calculada a partir de los eventos de falla registrados en los años de estudio. Se define como el número de fallas de un componente por unidad de tiempo de registro.

$$TQ = \frac{\text{Número de fallas}}{\text{Tiempo de estudio}} \quad [fallas/año] \quad (1)$$

- **Localización:** variable binaria que indica la zona en la que se encuentra el transformador: 1 si es urbana y 0 si es rural.
- **Potencia nominal:** capacidad del transformador en kVA. Para transformadores inmersos en aceite la norma IEC 76-1 establece las condiciones normales de servicio como altitud sobre el nivel del mar no mayor a 1.000 m y temperatura ambiente mayor a $-25^{\circ}C$ y menor a $40^{\circ}C$.
- **Autoprotección:** variable binaria que indica si el transformador cuenta internamente con un interruptor como protección por baja tensión: 1 si es autoprotegido y 0 si no lo es.
- **Promedio de densidad de descarga a tierra DDT:** variable en $Rayos/km^2 \cdot año$ está definida como el promedio de número de rayos que caen a tierra por kilómetro cuadrado en un año.
- **Máximo de densidad de descarga a tierra DDT:** variable en $Rayos/km^2 \cdot año$ está definida como el número máximo de rayos que caen a tierra por kilómetro cuadrado en un año.
- **Criticidad según estudio previo para nivel ceráunico:** variable binaria producto del resultado de un estudio previo realizado para la empresa distribuidora por terceros: 1 si por su ubicación geográfica se encuentra en riesgo alto y 0 de lo contrario, no presenta alto riesgo.

- **Conectores amovibles:** variable binaria que indica si la instalación del transformador cuenta con conectores amovibles por media tensión para realizar intervenciones sin necesidad de hacer apertura desde el seccionador inmediatamente aguas arriba: 1 si cuenta con los conectores amovibles instalados y 0 si no los tiene.
 - **Tipo de clientes:** variable categórica que indica si el transformador alimenta principalmente a usuarios residenciales estrato 1, 2, 3, 4, 5, 6, comerciales, industriales u oficiales.
 - **Número de usuarios:** variable entera que indica a cuantos clientes les está suministrando el servicio de energía eléctrica el transformador en cuestión.
 - **Energía eléctrica no suministrada EENS:** variable basada en el riesgo que implica la falla, representa los kWh que deja de vender la empresa distribuidora cuando el transformador deja de operar debido a un evento de falla.
 - **Tipo de instalación:** variable categórica que indica si el transformador instalado se encuentra en una cabina, en una estructura tipo H, si tiene un macro con red antifraude, si es tipo *pad mounted*, si está en una estructura sencilla tipo poste, poste red antifraude, torre metálica u otros.
 - **Red aérea:** variable binaria que indica si la red de baja tensión del transformador es de tipo aérea: 1 si en efecto lo es y 0 de lo contrario.
 - **Cola de circuito:** variable binaria que indica si el transformador está ubicado dentro de la red de media tensión en un punto terminal del circuito: 1 si está en la cola y 0 si está en un punto de paso.
 - **Km de red BT:** variable continua que corresponde a la longitud en km con la que cuenta en transformador por baja tensión.
6. **Construcción de un modelo que represente al sistema:** en este trabajo el algoritmo que menor error de predicción tuvo fue el Support Vector Machine (SVM). Este algoritmo para la clasificación trata de resolver las dificultades de muestras de datos complejas, donde las relaciones pueden ser no lineales. En nuestro caso particular, se pretende clasificar a los observaciones en dos clases (dañado o buen estado), pero estas no son separables vía un hiperplano en el espacio dimensional definido por los datos [10].

A partir del conjunto de datos de entrenamiento y prueba de los años 2019 y 2020 se construyeron dos modelos SVM de clasificación binaria. El conjunto de datos del modelo SVM correspondiente al año 2019 fue conformado con 2.417 datos para el entrenamiento (que contienen todos los transformadores quemados y parte de los que están en buen estado) y los 13.452 restantes para la validación, de igual forma para el año 2020. Estos modelos se validan con las respuestas reales de cada año, pero aún no son modelos predictivos para realizar el plan de mantenimiento de años futuros, para ello deben construirse modelos predictivos.

A diferencia de un modelo de clasificación binaria ordinario, donde los datos de entrenamiento y prueba corresponden al mismo año, es imposible tener los datos de prueba para el año actual, por lo que se usaron los datos del año inmediatamente anterior (datos de entrenamiento) para construir el modelo de predicción del año 2021.

7. **Validación del modelo construido:** para validar el poder de predicción de esta aproximación, se entrenó un modelo SVM con un conjunto de datos del año 2019 y se validó con información del año 2020. El conjunto de datos de entrenamiento de 2019 fue modificado en la variable tasa de quema, esta variable contiene información del histórico de fallas del transformador. La tasa de quema se actualizó con los datos acumulados al final del año. El conjunto de datos de entrenamiento fue de 1.585, y se actualiza mes a mes con los datos registrados del año en curso en el sistema central y eliminando los del año anterior con el propósito de aumentar la capacidad predictiva del modelo.
8. **Predicción de los datos deseados mediante el modelo validado:** una vez se comprueba que el modelo predictivo es válido para el año 2020, se realizan las predicciones para el año en curso entrenando el algoritmo SVM con una muestra de 1.589 transformadores de distribución con la tasa de quema actualizada en los eventos de falla del año 2020.
9. **Formulación de la programación del mantenimiento para los equipos predichos** la formulación del plan de mantenimiento se realiza a partir de las causas probables más comunes que se han registrado en los históricos de eventos de quema: descarga atmosférica, corto circuito por baja tensión y sobrecarga. En la tabla II se presentan las actividades de mantenimiento propuestas en este trabajo para mitigar los eventos de falla. Estas actividades serán asignadas a cada uno de los transformadores predichos por el algoritmo de SVM.

La actividad A correspondiente a la inspección general está concebida para ser realizada por un supervisor motorizado (no una brigada pesada). Esta inspección se asignará por defecto a todos los transformadores predichos. Dependiendo de la información recolectada en terreno por el supervisor se ratifica si el transformador requiere una intervención. El restante de actividades será asignada en este trabajo mediante análisis netamente estadístico de las variables que caracterizan el modelo predictivo a manera de sugerencia y guía de cómo disminuir el posible riesgo.

Tabla II. Actividades de mantenimiento y descripción de sus tareas.

Actividad	Descripción	Tareas
A	Inspección General	(a) Inspección visual del estado del transformador, su estructura, sus protecciones y el sistema de puesta a tierra. (b) Recorrido de la red de baja tensión en busca de anomalías o riesgos. (c) Verificación de los usuarios asociados, detección de conexiones ilegales. (d) Verificar el estado de las acometidas.
B	Adecuación de protecciones	(a) Cambio de cortacircuitos. (b) Cambio de DPS. (c) Instalación de interruptor por baja tensión (si aplica). (d) Adecuación del sistema puesta a tierra.
C	Podas	Realización de poda exhaustiva o ligera, según sea necesario
D	Adecuación de la red de baja tensión	(a) Reposición de redes de baja tensión. (b) Cambio de red abierta por red trenzada. (c) Balanceo de cargas en las fases.
E	Repotenciación	Cambio de transformador por uno de capacidad superior al instalado

La actividad B será asignada a transformadores que se encuentren en zonas con DDT altos, se encuentren en estado de criticidad alta según el estudio de nivel cerámico y se encuentren en zona rural. La actividad C será asignada a transformadores que se encuentren principalmente en la zona rural, tengan red aérea, no sea red anti-fraude y su extensión sea considerable. La actividad D será asignada a transformadores con historial de quema reiterativa y red aérea que no sea anti-fraude. Finalmente la actividad E será asignada a todos aquellos transformadores que según su capacidad nominal, el número y el tipo de clientes está llegando al límite de la sobrecarga (límite operativo 120 % de la potencia nominal).

3. Resultados

El conjunto de datos contiene todos los transformadores de distribución conectados a niveles de voltaje de 13, 2 kV y 34, 5 kV, ubicados en las áreas rurales y urbanas del departamento de Cauca, propiedad de la Compañía Energética de Occidente. Es necesario enfatizar que quedan excluidos los transformadores de propiedad privada (terceros), del gobierno o cualquier persona diferente al operador de la red. El universo está conformado por 15.869 transformadores que responden al contexto operativo y los intereses de la empresa en el sector residencial, comercial, industrial y oficial [11]. El conjunto de datos está prefiltrado y no contiene datos atípicos ni perdidos y pueden consultarse y descargarse en [12].

Las variables predictoras X_i del conjunto de datos de entrenamiento que más aportan a la variable predicha Y_i del modelo obtenido mediante una clasificación binaria con el algoritmo SVM se pueden ver en la figura 2.




Figura 2. Importancia de las variables de entrada para el clasificador SVM.

La tasa de quema de los transformadores es la variable predictora que más influye en el modelo, esto puede ser confirmado mediante la intuición. La segunda variable de mayor importancia es la localización del transformador, esta variable es discreta (rural o urbana), siendo la parte rural del departamento de Cauca (Colombia) donde la mayoría de transformadores de distribución se

queman. Las figuras 3(a) y 3(b) muestran el número de transformadores quemados en los años 2019 y 2020 respectivamente.




Figura 3. Diagrama de pareto para los transformadores dañados según su localización.

Los resultados evidencian la falta de mantenimiento preventivo de los transformadores en la parte rural, cabe destacar que son los más alejados de la zona urbana de los municipios, además de tener asociados factores de riesgo de corto circuito por baja tensión. Los transformadores que más sufren daño son los de baja potencia nominal (menores a 20 [kVA]), como se evidencia en las Figs. 4(a) y 4(b).

Estos transformadores se encuentran en su gran mayoría en la parte rural del departamento de Cauca y tienen el riesgo de sobrecarga eléctrica debido a las conexiones ilegales muy comunes en estas zonas a causa de las condiciones socio-económicas.

A partir del conjunto de datos de entrenamiento y prueba de los años 2019 y 2020 se construyeron dos modelos SVM de clasificación binaria, los resultados se resumen en la tabla III.

Tabla III. Resumen Validación del modelo para los años 2019 y 2020.

Año	Error entrenamiento	Error prueba	Exactitud	Total quemados	Porcentaje de acierto
2019	0,0099	0,1629	0,9543	825	56,1338
2020	0,0170	0,1304	0,9739	441	52,1463

La explicación de la tabla para el año 2019 es la siguiente: la exactitud de los aciertos para la clasificación (en buen estado y quemados) de los transformadores es del 95.43 %, para un total de 825 transformadores quemados (variable de salida), el modelo predice un acierto del 56.13 % para esta variable de interés.

Las gráficas de confusión 5(a) y 5(b) validan los modelos SVM para los años 2019 y 2020. La clasificación binaria muestra en la diagonal principal los resultados de los aciertos para las clases




Figura 4. Distribución de los transformadores dañados según potencia nominal.

predichas (0 corresponde a transformadores en buen estado y 1 a los transformadores dañados), para el año 2020 el modelo acertó en 328 transformadores dañados de un total de 441, con un porcentaje de acierto del 52.4 %.




Figura 5. Gráficas de Validación del modelo para los años 2019 y 2020.

El conjunto de datos del modelo SVM correspondiente al año 2019 fue conformado con 2.417 datos para el entrenamiento (que contiene todos los transformadores quemados y parte de los que están en buen estado) y los 13.452 restantes para la validación, de igual forma para el año 2020. Estos modelos se validan con los datos de cada año, pero no son modelos predictivos para realizar el plan de mantenimiento de años futuros, para ello deben construirse modelos predictivos.

3.1. Modelo Predictivo

A diferencia de un modelo de clasificación binaria ordinario, donde los datos de entrenamiento y prueba corresponden al mismo año, es imposible tener los datos de prueba para el año actual, por lo que se usaron los datos del año inmediatamente anterior (datos de entrenamiento) para construir el modelo de predicción del año 2021.


Para validar el poder de predicción de esta aproximación, se entrenó a un modelo SVM con un conjunto de datos de 2019 y se validó con información del año 2020. El conjunto de datos de entrenamiento de 2019 fue modificado en la variable tasa de quema, esta variable contiene información del histórico de fallas del transformador, y se actualizó con los datos acumulados al final del año. El conjunto de datos de entrenamiento fue de 1.585, y se actualizó mes a mes con los datos registrados en el sistema central con el propósito de aumentar la capacidad predictiva del modelo. La tabla IV muestra la validación del modelo predictivo durante el año 2020 actualizándose mes a mes con los datos registrados del año en curso en el sistema central y eliminando los del año anterior con el propósito de aumentar la capacidad predictiva del modelo, en lugar de esperar al finalizar el año para ajustar la información.

Tabla IV. Validación del modelo predictivo mes a mes del año 2020.

Mes 2020	Error entrenamiento	Error prueba	Exactitud	Total quemados	Porcentaje de acierto
Enero	0,0028	0,4561	0,8704	1576	11,7647
Febrero	0,0028	0,4186	0,8638	1812	22,2576
Marzo	0,0022	0,3845	0,8789	1642	27,8219
Abril	0,0028	0,3384	0,8953	1482	35,7711
Mayo	0,0034	0,2981	0,9061	1401	42,925
Junio	0,0029	0,2748	0,9137	1328	46,7409
Julio	0,0023	0,2413	0,9190	1339	54,2130
Agosto	0,0023	0,2189	0,9237	1322	58,8235
Septiembre	0,0029	0,1770	0,9293	1349	68,0445
Octubre	0,0041	0,1346	0,9433	1223	75,6757
Noviembre	0,0059	0,1000	0,9519	1171	82,3529
Diciembre	0,0067	0,0550	0,9694	997	90,6200

Los valores de las dos ultimas columnas se muestran en la figura 6(a), a medida que se actualiza la información cada mes y eliminado la del mismo mes del año anterior. El número de transformadores quemados predicho por el modelo disminuye (excepto en el mes de febrero) y el porcentaje de aciertos en los transformadores quemados predichos por el modelo aumenta. Al final del año 2020, el porcentaje de acierto de la variable de salida (transformadores quemados) es del 90,62 %, lo que valida la capacidad predictiva del modelo de clasificación binaria, si este actualiza la información de la base de datos de entrenamiento mes a mes.

La predicción para el año 2021 arrojó 910 transformadores de los cuales 870 se encuentran en zona rural del Cauca, lo cual concuerda con las tendencias de falla en los años anteriores. En la figura 7 se presenta la distribución de las capacidades nominales para los transformadores predichos, en donde se evidencia que los transformadores de 10 kVA continúan siendo prioridad en riesgo. Por el contrario, para esta predicción el algoritmo no le dio prioridad a los transformadores




(a) Comportamiento del modelo predictivo

(b) Gráfica de confusión

Figura 6. Gráficas de validación del modelo predictivo del año 2020.

que según el estudio de nivel cerámico presentan alto riesgo de quema, ya que solo 217 transformadores (23,8 %) pertenecen a él. La mayoría de los transformadores alimenta al sector residencial (98,9 %), siendo sus clientes los más vulnerables y afectados en su calidad de vida y bienestar.

**Figura 7.** Capacidad nominal del conjunto de transformadores predichos.

3.2. Plan de mantenimiento

Aplicando la formulación de la programación del plan de mantenimiento de la sección anterior a los 910 transformadores predichos por el algoritmo SVM como más probables para falla por quema en el 2021, en la tabla V se presenta la cantidad total sugerida de cada actividad, se debe tener en cuenta que hay transformadores a los que se les sugiere más de una actividad a la vez, [13]. La actividad A es la inspección general, por lo cual se aplica a la totalidad del conjunto.

Tabla V. Actividades sugeridas en el plan de mantenimiento 2021

Actividad	A	B	C	D	E
Nro. Transformadores	910	597	277	240	136

En la tabla VI se presenta la distribución de actividades que se sugiere para el grupo de transformadores predichos. Se entiende que 161 transformadores requieren solo una actividad, en este caso es la inspección general que por defecto se asigna a todos los transformadores de la muestra. Por otro lado, en el otro extremo se tienen 14 transformadores que requieren las cinco actividades propuestas, a estos equipos se sugiere darles prioridad en la inspección ya que estadísticamente son los que presentan alto riesgo de falla por múltiples factores como descarga atmosférica, corto circuito en baja tensión por riesgo forestal, fraude y sobrecarga.

Tabla VI. Distribución de actividades para el grupo de transformadores predichos

Nro. actividades requeridas (A, B, C, D, E)	Nro. transformadores
1	161
2	393
3	225
4	117
5	14
TOTAL	910

3.3. Análisis financiero de la implementación del plan de mantenimiento

En términos de costos por mantenimiento correctivo, en el año 2020 se invirtieron \$3.271.763.447,42 pesos colombianos (COP) en la reposición de transformadores de distribución quemados, \$1.009.-900.783,38 (COP) correspondientes a gastos por mano de obra y \$2.261.862.664,04 (COP) a material. A esto deben sumarse los ingresos no percibidos por energía no suministrada, debido a la suspensión no programada del servicio causada por el evento de falla, equivalente en total a 82.458,44 horas durante el año 2020. La cifra puntual en dinero depende directamente de la tarifa aplicada al usuario final, por lo cual en términos prácticos y comparativos, se hará referencia a las horas sin fluido eléctrico. En promedio 126,47 horas por falla, es decir un tiempo de respuesta de cinco días, donde por lo general se cumplen cuatro días en zona rural y un día en zona urbana.

Analizando las predicciones para el año 2020 mes a mes y comparando con los hechos reales, se obtiene la tabla VII, en ella se evidencia que el potencial predictivo del algoritmo es más alto iniciando el ciclo de evaluación (año) ya que, a medida que los eventos de falla empiezan a ocurrir, este tiende a clasificar en mayor medida, reconociendo los equipos que ya se han quemado.

A lo largo de las predicciones en el transcurso de los meses, el conjunto de transformadores predichos varía parcialmente. Los valores se detallan en la última columna Nuevos predichos de la tabla VII. En total 86 transformadores fueron identificados correctamente antes de su falla, 74 de ellos para el mes de enero lo que garantiza un 86 % del potencial de predicción; para el mes de febrero se suman siete transformadores más, y a partir de la experiencia del mes anterior, en marzo dos más al igual que en abril y uno en octubre cuando finalmente se completan los 86 equipos efectivos.

Tabla VII. Clasificación de los transformadores quemados mes a mes del año 2020. [Propio]

Mes 2020	Total predicciones	Total aciertos	Predicción real	Diferencia	Nuevos predichos
Enero	1576	74	74	0	74
Febrero	1812	140	75	65	7
Marzo	1642	175	61	114	2
Abril	1482	225	41	184	2
Mayo	1401	270	30	240	0
Junio	1328	294	10	274	0
Julio	1339	341	16	325	0
Agosto	1322	370	14	356	0
Septiembre	1349	428	12	416	0
Octubre	1223	476	6	470	1
Noviembre	1171	518	5	513	0
Diciembre	997	570	4	566	0

Teniendo en cuenta estas cifras, los costos de reposición y las horas sin fluido eléctrico, en el caso hipotético de haber aplicado la metodología propuesta en este trabajo habría sido posible lograr un ahorro hasta de \$ 431.551.620,36 (COP), incluyendo material y mano de obra; además de 10.876,42 horas de servicio interrumpido por la falla, que hubiesen sido reemplazadas por 344 horas de suspensión programada debido al mantenimiento predictivo, tomando un promedio de 4 horas por la ejecución de los trabajos.

En términos del presupuesto de mantenimiento correctivo, se tiene una disminución del 13 % en los gastos al igual que en horas sin fluido eléctrico [14].

4. Conclusiones

En este trabajo el problema de predicción en la falla de transformadores de distribución es abordado mediante técnicas de Machine Learning. Desde el punto de vista del Machine Learning este es un problema de clasificación binaria. El modelo predictivo obtenido mediante esta aproximación permite construir un plan de mantenimiento predictivo reduciendo los costos del mantenimiento correctivo y optimizando los recursos asignados al área de mantenimiento de la Compañía Energética de Occidente.

Los algoritmos de Machine Learning encuentran patrones naturales en los datos que generan información y permiten tomar mejores decisiones y predicciones. Machine Learning Toolbox de Matlab; proporciona funciones de análisis de datos para recopilar tendencias y patrones a partir de un conjunto masivo de datos. El algoritmo de clasificación binaria usado fue el Support Vector Machine (SVM), que muestra un menor porcentaje de error en la capacidad predictiva de la falla en transformadores de distribución. Se presentaron algunos inconvenientes en el estudio, la información de fallas de los transformadores abarca pocas variables predictoras. Si se logra aumentar las variables predictoras, como por ejemplo: tiempo que lleva operando el equipo, intensidad de corriente en bornes de baja tensión, temperatura de operación, humedad del entorno, nivel de aceite, monitoreo del clima, etc; esta información podría ayudar al algoritmo de Machine Learning para capturar la tendencia en las fallas de los transformadores.

El futuro del mantenimiento en la industria es digital. Los avances de la tecnología y el internet de las cosas facilitan interconectar los dispositivos y máquinas, lo que permite a técnicos de mantenimiento y supervisores tener a su disposición datos en tiempo real del estado de estos artefactos; esto permite evolucionar los conceptos de mantenimiento correctivo y preventivo para dejar en primer lugar el mantenimiento predictivo enfocado en la detección de fallas, con lo cual las empresas gestionarán la programación de mantenimiento para sus industrias, reduciendo la cantidad de sobrecostos por daños y averías.

La implementación de la metodología permite un ahorro del 13 % en los gastos de mantenimiento correctivo para el año 2020. El modelo propuesto es una herramienta eficaz para la toma de decisiones, que proporciona una solución ideal para los problemas de programación del mantenimiento preventivo de los transformadores de distribución.

En el futuro se planea construir modelos predictivos con Machine Learning para estimar la vida útil restante de los transformadores de distribución. Una estimación precisa de la vida útil restante de los transformadores podría facilitar el desarrollo de un plan de mantenimiento más rentable para las empresas de distribución de energía eléctrica.

Se recomienda la aplicación de esta metodología a cualquier tipo de elemento de la red, como protecciones, líneas, reconectores, seccionadores y demás; siempre y cuando se tenga identificada la naturaleza de la falla y se cuente con la información necesaria para el entrenamiento.

5. Agradecimientos

Los autores de este trabajo desean expresar sus agradecimientos a la Compañía Energética de Occidente por facilitar los datos de los transformadores de distribución del departamento de Cauca (Colombia); a la Universidad del Cauca y la Universidad del Valle por todos los recursos académicos y científicos prestados.

Referencias

- [1] V. B. Núñez, R. Velandia, F. Hernández, J. Meléndez, and H. Vargas, "Atributos relevantes para el diagnóstico automático de eventos de tensión en redes de distribución de energía eléctrica," *RIAI - Rev. Iberoam. Autom. Inform. Ind.*, vol. 10, no. 1, pp. 73–84, 2013. 2
- [2] W. Kersting, *Distribution System Modeling and Analysis*. CRC Press, 2016. [Online]. Available: <https://doi.org/10.1201/b11697> 2
- [3] E. Shayesteh and P. Hilber, "Reliability-centered asset management using component reliability importance," in *2016 International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, 2016, pp. 1–6. 3
- [4] A. Abdussalam Nuhu, Q. Zeeshan, O. Korhan, M. Asmael, and B. Safaei, "Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0," *Sustainability*, vol. 12, no. 19, p. 8211, Oct 2020. 3
- [5] R. Brown, *Electric Power Distribution Reliability*, ser. Power Engineering (Willis). CRC Press, 2017. [Online]. Available: <https://doi.org/10.1201/9780849375682> 3
- [6] K. Alhamad and M. Alhajri, "A zero-one integer programming for preventive maintenance scheduling for electricity and distiller plants with production," *J Qual Maint Eng*, vol. 26, no. 4, pp. 555–574, Nov. 2019. [Online]. Available: <https://doi.org/10.1108/JQME-12-2018-0102> 3

- [7] T. P. Carvalho, F. A. A. M. N. Soares, R. Vita, R. da P. Francisco, J. P. Basto, and S. G. S. Alcala, "A systematic literature review of machine learning methods applied to predictive maintenance," *Comput Ind Eng*, vol. 137, p. 106024, 2019. [Online]. Available: <https://doi.org/10.1016/j.cie.2019.106024> 3
- [8] H. Li, D. Parikh, Q. He, B. Qian, Z. Li, D. Fang, and A. Hampapur, "Improving rail network velocity: A machine learning approach to predictive maintenance," *Transp. Res. Part C Emerg.*, vol. 45, pp. 17 – 26, 2014, advances in Computing and Communications and their Impact on Transportation Science and Technologies. 3
- [9] D. A. Bravo Montenegro, *Identificación de Sistemas Multivariantes. Teoría y Práctica*. Editorial Académica Española, 05 2012. 3
- [10] S. Hwang, J. Jeong, and Y. Kang, "Svm-rbm based predictive maintenance scheme for iot-enabled smart factory," in *2018 Thirteenth International Conference on Digital Information Management (ICDIM)*, 2018, pp. 162–167. 6
- [11] D.-A. Bravo M, L.-I. Alvarez Q, and C.-A. Lozano M, "Dataset of distribution transformers for predictive maintenance," *Data Brief*, vol. 38, p. 107454, 2021. [Online]. Available: <https://doi.org/10.1016/j.dib.2021.107454> 8
- [12] D. Bravo, L. Alvarez, and C. Lozano, "Dataset of distribution transformers at cauca department (colombia)," Sep. 2021. [Online]. Available: <https://data.mendeley.com/datasets/zyzj46xpm/4> 8
- [13] L. I. Alvarez, C. Lozano, and D. A. Bravo, "Machine learning for predictive maintenance scheduling of distribution transformers," *J Qual Maint Eng*, Jan. 2022. 12
- [14] L. I. A. Quiñones, *Mantenimiento Predictivo de Transformadores de Distribución*. Editorial Académica Española, 2021. 14

Laura Isabel Alvarez Quiñones

Ingeniera Física de la Universidad del Cauca (2013). Magíster en Ingeniería Eléctrica de la Universidad del Valle (2021). Actualmente trabaja en la Compañía Energética de Occidente (Colombia) en gestión de activos. Sus áreas de interés son el aprendizaje automático y el mantenimiento predictivo de sistemas eléctricos de potencia.
correo electrónico: laura.isabel.alvarez@correounivalle.edu.co

Carlos Arturo Lozano Moncada

Ingeniero Eléctrico de la Universidad del Valle, (1992); curso estudios de Maestría en Sistemas de Generación de Energía Eléctrica en la Universidad del Valle, (1995); es Doctor en Ingeniería Eléctrica de la Universidad de Strathclyde, (2002). Se ha desempeñado como profesor de la Escuela de Ingeniería Eléctrica y Electrónica de la Universidad del Valle desde 1995. Sus principales áreas de interés son: Análisis, Operación y Gestión de Sistemas de Potencia, Análisis y Aplicación de Campos Electromagnéticos y mercados de energía.
correo electrónico: carlos.a.lozano@correounivalle.edu.co

Diego Alberto Bravo Montenegro

Ingeniero Físico de la Universidad del Cauca (2003). Especialista en Automatización Industrial, Universidad del Valle (2007). Magíster en Ingeniería Automática de la Universidad del Valle (2012). Doctor en Ciencias de la Electrónica de la Universidad del Cauca (2016). Actualmente es profesor titular del Departamento de Física de la Universidad del Cauca. Sus áreas de interés son el Modelado y control de sistemas dinámicos, Robótica bípeda y Educación en ingeniería.
correo electrónico: dibravo@unicauca.edu.co