

## Diagnóstico de fallas en generadores de potencia utilizando algoritmos de machine learning

Quetzalli Amaya Sánchez<sup>1</sup>, Alberto Alfonso Aguilar Lasserre<sup>1</sup>,  
Marco Julio del Moral Argumedo<sup>1</sup>, Gustavo Arroyo Figueroa<sup>2</sup>

<sup>1</sup> Tecnológico Nacional de México,  
Instituto Tecnológico de Orizaba,  
División de Estudios de Posgrado e Investigación,  
México

<sup>2</sup> Instituto Nacional de Electricidad y Energías Limpias (INEEL),  
México

{quetza\_amaya, albertoaal}@hotmail.com,  
marcojulioarg@gmail.com, garroyo@ineel.mx

**Resumen.** Un generador de potencia es un activo clave en la disponibilidad y confiabilidad de la red eléctrica nacional. Estos activos son muy confiables, sin embargo, debido a la operación estresante que son sometidos pueden presentar fallas recurrentes, por esta razón la detección oportuna del estado de salud es fundamental. Este trabajo presenta el desarrollo de un modelo inteligente de diagnóstico de fallas de generadores basado en algoritmos de Machine Learning (ML). Para el aprendizaje, se utilizó una base de datos de pruebas de índice de salud de generadores asociada al tipo de falla, curada por expertos en equipos eléctricos. Se utilizaron dos algoritmos de clasificación: árbol de decisión y máquina de soporte vectorial, los parámetros de algoritmos se optimizaron mediante procedimientos estándar de aprendizaje automático. Los resultados muestran que el algoritmo más adecuado para el diagnóstico de fallas es el árbol de decisión con una precisión del 87%, una precisión balanceada del 81%, un índice Kappa de 0.75, un índice de Jaccard de 0.67 y un coeficiente de correlación de Matthews de 0.77. El modelo inteligente tiene la capacidad de predecir con gran certeza la presencia de una falla y el tipo de falla con buena exactitud. El proveer información sobre el estado de salud y la falla en un generador permitirá tomar decisiones adecuadas y oportunas sobre la operación y mantenimiento de estos activos.

**Palabras clave:** Generadores de potencia, diagnóstico de fallas, aprendizaje automático, árbol de decisión, máquina de soporte vectorial.

### Fault Diagnosis in Power Generators Using Machine Learning Algorithms

**Abstract.** A power generator is a key asset in the availability and reliability of the national power grid. These assets are very reliable; however, due to the

stressful operation they are subjected to, they can experience recurrent failures. For this reason, timely detection of their health status is essential. This work presents the development of an intelligent fault diagnosis model for generators based on Machine Learning algorithms. For the learning process, a database of generator health index tests associated with the type of failure, curated by experts in electrical equipment, was used. Two classification algorithms were used: decision tree and support vector machine, and the algorithm parameters were optimized using standard machine learning procedures. The results show that the most suitable algorithm for fault diagnosis is the decision tree with an accuracy of 87%, a balanced accuracy of 81%, a Kappa index of 0.75, a Jaccard index of 0.67, and a Matthews correlation coefficient of 0.77. The intelligent model has the ability to predict with high certainty the presence of a fault and the type of fault with good accuracy. Providing information on the health status and faults in a generator will allow for appropriate and timely decisions regarding the operation and maintenance of these assets.

**Keywords:** Power generators, fault diagnosis, machine learning, decision tree, support vector machine.

## 1. Introducción

La energía eléctrica es fundamental para el desarrollo económico y la calidad de vida en la sociedad contemporánea. La energía eléctrica es producida en centrales de generación hidroeléctrica y termoeléctrica, principalmente. En México, la Comisión Federal de Electricidad (CFE) es responsable de generar el 54% de la energía del país, mientras que el restante 46% proviene de empresas privadas [1]. Un generador eléctrico es una máquina encargada de transformar la energía mecánica en energía eléctrica. La disponibilidad y confiabilidad de estos equipos es crucial para el suministro y la estabilidad del sistema eléctrico nacional (SEN) [2]. Los componentes principales de un generador experimentan un deterioro progresivo debido a las tensiones eléctricas, mecánicas, térmicas y ambientales a las que están expuestas durante su operación. Este proceso de envejecimiento se ve acelerado por un mantenimiento deficiente y por operar en condiciones severas o anormales. Cuando un generador experimenta una falla durante su operación, puede provocar inestabilidad en todo el sistema eléctrico y pérdida de suministro eléctrico.

Entre las principales fallas que puede presentar un generador están: el cortocircuito entre las espiras del devanado del estator debido al deterioro del aislamiento representando más del 25% de las fallas; y las descargas parciales, responsables del 22% de las fallas en los devanados [3]. Es de suma importancia el monitoreo y diagnóstico de fallas en un generador para garantizar la disponibilidad y confiabilidad del SEN; así como para prolongar la vida útil del activo [4]. La detección de fallas en generadores se enfoca principalmente en el análisis de descargas parciales, crucial para su fiabilidad. Este análisis cubre varias formas de descargas, como a la ranura, por delaminación, entre bobinas, superficiales/tracking y en huecos del aislamiento principal.

El análisis de descargas parciales es una técnica clave, aunque su interpretación a menudo requiere del conocimiento y experiencia de los expertos en activos eléctricos.

Simplificar esta interpretación y clasificar los generadores según su estado de salud es crucial para llevar a cabo acciones de operación y mantenimiento [5].

Dada la importancia de contar con sistemas de apoyo a la operación y mantenimiento de equipos eléctricos, se han realizado diversos trabajos para la identificación y el análisis de fallos en equipos eléctricos y generadores de potencia, así como en sus partes fundamentales, lo que permite una evaluación más precisa y eficiente de la salud del equipo [6]. Destacan la aplicación de sistemas basados en una metodología no lineal para determinar el índice de salud de generadores que utiliza la información obtenida de las pruebas que se aplican a los componentes principales del generador y diversos criterios de evaluación establecidas en referencias nacionales e internacionales.

Para cada variable y parámetro de condición se define su importancia en el estado del activo y la puntuación máxima que puede obtenerse. El cálculo del Índice de Salud del activo está basado en una formulación no-lineal de tipo exponencial [7]. Estos métodos son empíricos y están basados en la experiencia y conocimiento de los expertos en equipo eléctricos, su principal problema es confiabilidad y disponibilidad de los datos debido al manejo no adecuado de las pruebas eléctricas, se requieren un mínimo de 82 variables para obtener un valor confiable para determinar el índice de salud. La investigación y el desarrollo de sistemas de diagnóstico de fallas en generadores basada en algoritmos de Inteligencia Artificial es incipiente debido principalmente a la disponibilidad y calidad de los datos.

Melih, Veysi, Hakan y Muhamment [8] proponen una metodología novedosa para analizar las fallas en los generadores de barcos. En su enfoque, integran una versión mejorada del método de toma de decisiones multicriterio, enriquecida con Lógica Difusa (LD), lo que les permite desarrollar un mecanismo de decisión para priorizar las fallas del generador. Altaf, Al-Anbuky y GholamHosseini [9], proponen una Red Neuronal Artificial (RNA) distribuida supervisada para identificar múltiples tipos de fallas y determinar la ubicación del evento de falla en una red de motores industriales.

En este trabajo, se propone el uso de algoritmos de aprendizaje automático supervisado: árbol de decisión y máquina de soporte vectorial, para diagnosticar fallas en los generadores de centrales hidroeléctricas y termoeléctricas haciendo uso de los datos de las pruebas de descargas parciales. El objetivo es tener información precisa y oportuna de las fallas, para mejorar la operación, confiabilidad y eficiencia de los sistemas de generación de energía.

## **2. Materiales y métodos**

En esta sección se detalla los materiales y métodos empleados para el desarrollo de los modelos inteligentes para el diagnóstico de fallas de generadores de potencia mediante el uso de algoritmos de aprendizaje automático supervisado, la figura 1 muestra el diagrama de flujo de la metodología utilizada.

### **2.1. Análisis general**

En esta etapa se establecen los límites y alcances del problema tomando en cuenta el conocimiento del dominio, así como un marco de referencia para definir el espacio de soluciones a explorar. El objetivo principal de este trabajo es diagnosticar las fallas

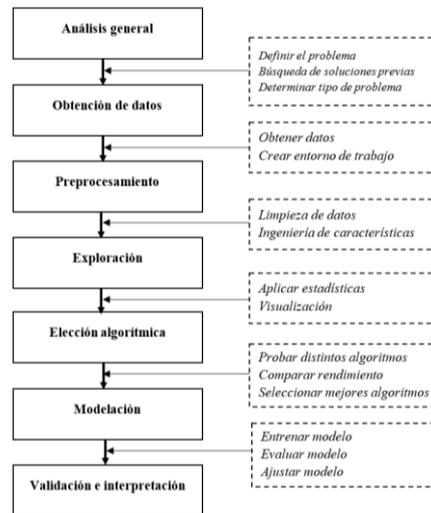


Fig. 1. Diagrama de flujo de la metodología.

en generadores de potencia. Se ha observado en la revisión de la literatura que existen enfoques previos para abordar este problema utilizando en modelos físicos basados en la experiencia de los expertos en estos activos eléctricos. Sin embargo, se opta por desarrollar un modelo inteligente debido a las ventajas de flexibilidad y robustez que ofrecen los algoritmos de aprendizaje automático. El problema asociado al diagnóstico de fallas en generadores de potencia se clasifica como un problema de clasificación multiclase, ya que implica categorizar el diagnóstico del generador en múltiples categorías de fallas.

## 2.2. Obtención de datos

En esta etapa, se comienza identificando y recopilando los datos necesarios para llevar a cabo el diagnóstico de fallas. Se cuenta con una base de datos de pruebas de generadores de potencia, compuesta por 196 filas y 20 columnas. Esta base de datos incluye una variable de salida que indica el tipo de falla y 19 atributos relacionados con pruebas de índice de salud del activo, tales como factores de disipación, monitoreo de descargas parciales, tipo de enfriamiento e inspección visual.

En la Tabla 1 se presentan las variables flotantes de la base de datos, las cuales están representadas por número reales. En la Tabla 2 se presentan las variables categóricas de la base de datos.

## 2.3. Preprocesamiento

La fase de preparación de datos implica una serie de procesos, como transformación de datos, normalización, limpieza y eliminación de ruido. En este caso específico, se realiza ingeniería de características para transformar las variables: *Enfriamiento*, *DP\_simm*, *DP\_maxVal*, *Visual* y *Diagnóstico*, las cuales originalmente se presentan de tipo entero en la base de datos, en variables categóricas. Este proceso es esencial para

**Tabla 1.** Variables categóricas de la base de datos.

Variable	Descripción	Categorías
Enfriamiento	Tipo de enfriamiento del generador	0. NA
		1. Hidroeléctrica
		2. Hidrógeno
		3. Aire
DP_simm	Simetría en semiciclos	4. Aire forzado
		0. Simétricos
		1. Descargas parciales en el semiciclo (+) menores al semiciclo (-)
DP_maxVal	Valor máximo de descargas parciales	2. Descargas parciales en el semiciclo (+) mayores al semiciclo (-)
		0. DP < 10
		1. 30 > DP > 10
Visual	Inspección visual	2. DP > 30
		0. Sin evidencias
		1. Ionización externa entre un bastón y el dedo de sujeción del núcleo
		2. Presencia de polvo blanco, principalmente en bobinas de salida de fase
		3. Detección de zonas con descargas externas visualmente o con cámara corona
		4. Evidencia de actividad de descargas en la zona de graduación
		5. Pintura de graduación de campo eléctrico en salida de algunos bastones del núcleo y en puentes de interconexión
		6. Evidencia de tracking
		7. Incipiente contaminación en cabezales
		8. Contaminación en cabezales
		9. Olor a ozono audible/visibles en la zona recta de las bobinas con voltaje aplicado
		10. Ionización audible/visible en la zona recta de las bobinas con voltaje aplicado
Diagnóstico	Tipos de fallas del generador de potencia	11. Fractura de los capuchones
		12. Obstrucción de ductos de ventilación
		0. Descargas a la ranura
		1. Descargas por delaminación entre el aislamiento principal y conductor de cobre
		2. Descargas entre bobinas en cabezales
3. Descargas superficiales/tracking en cabezales debido a contaminación		
4. Descargas internas en huecos del aislamiento principal		
5. Descargas por alto contenido de huecos en el aislamiento principal		

clasificar los datos según valores predefinidos asociados a una cualidad específica. Se selecciona Python como el principal lenguaje de programación para llevar a cabo el desarrollo. Para facilitar la gestión de los paquetes y entornos requeridos, se utiliza Anaconda como gestor de paquetes.

## 2.4. Exploración

La fase de exploración de datos implica un análisis detallado y una visualización exhaustiva para familiarizarse con los datos. Por ello, se lleva a cabo un análisis estadístico para obtener información relevante y detectar patrones que requieran un análisis más profundo. La representación visual de los datos mediante gráficos estadísticos es fundamental para comprender la evolución y las relaciones entre

**Tabla 2.** Variables flotantes de la base de datos.

Variable	Descripción
FD_tand_A	Factor de disipación $\tan \delta$ (0.2Vn) Ø A
FD_tand_B	Factor de disipación $\tan \delta$ (0.2Vn) Ø B
FD_tand_C	Factor de disipación $\tan \delta$ (0.2Vn) Ø C
FD_Dtand_A	Factor de disipación $\Delta \tan \delta$ (0.6Vn-0.2Vn) Ø A
FD_Dtand_B	Factor de disipación $\Delta \tan \delta$ (0.6Vn-0.2Vn) Ø B
FD_Dtand_C	Factor de disipación $\Delta \tan \delta$ (0.6Vn-0.2Vn) Ø C
DP_VnCrA_Ap	Descargas parciales (nC) $Vn/\sqrt{3}$ Ø A semiciclo (+)
DP_VnCrA_An	Descargas parciales (nC) $Vn/\sqrt{3}$ Ø A semiciclo (-)
DP_VnCrB_Bp	Descargas parciales (nC) $Vn/\sqrt{3}$ Ø B semiciclo (+)
DP_VnCrB_Bn	Descargas parciales (nC) $Vn/\sqrt{3}$ Ø B semiciclo (-)
DP_VnCrC_Cp	Descargas parciales (nC) $Vn/\sqrt{3}$ Ø C semiciclo (+)
DP_VnCrC_Cn	Descargas parciales (nC) $Vn/\sqrt{3}$ Ø C semiciclo (-)
DP_diff_A	Diferencia en la magnitud de descargas parciales en semiciclo (+) vs semiciclo (-) Ø A
DP_diff_B	Diferencia en la magnitud de descargas parciales en semiciclo (+) vs semiciclo (-) Ø B
DP_diff_C	Diferencia en la magnitud de descargas parciales en semiciclo (+) vs semiciclo (-) Ø C

variables. Por ejemplo, la distribución de frecuencia de la variable tipo de falla (diagnóstico), ver Fig. 2, muestra que se trata de una base de datos no balanceada.

### 2.5. Elección algorítmica

La elección del algoritmo depende de los objetivos del proyecto y la naturaleza de los datos. En este caso, se busca clasificar fallas en generadores de potencia, lo que implica predecir la categoría de una muestra. Se evaluaron dos algoritmos de aprendizaje supervisado de clasificación multiclase: árbol de decisión y máquina de soporte vectorial. En la Tabla 3 se presenta una descripción de cada algoritmo junto con los hiperparámetros utilizados para su sintonización. Donde el DecisionTreeClassifier se limita la profundidad máxima del árbol a 5 niveles y requiere al menos 2 muestras para dividir un nodo interno. Por otro lado, SVC utiliza un kernel de función de base radial (no lineal) para mapear los datos en un espacio dimensional superior antes de clasificarlos.

### 2.6. Modelación

Una vez seleccionados los algoritmos junto con sus hiperparámetros, se procede a su modelación. Los datos se dividen en conjuntos de entrenamiento y prueba, asignando el 80% de los datos al conjunto de entrenamiento (156 datos) y el 20% restante al conjunto de prueba (40 datos). Esta división se realiza debido a la escasez de datos disponibles.

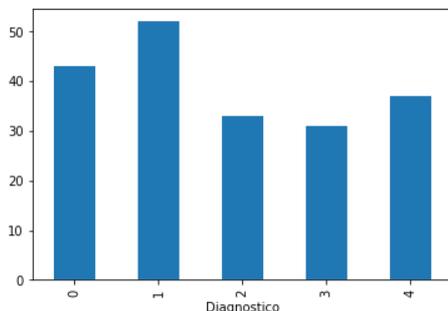


Fig. 2. Distribución de frecuencia de la variable diagnóstico.

Tabla 3. Algoritmos de clasificación de aprendizaje supervisado.

Algoritmo	Descripción	Clasificador
Árbol de decisión	Se representa como un árbol donde cada nodo interno denota una característica o atributo, cada rama indica una regla de decisión, y cada hoja representa el resultado de la clasificación	DecisionTreeClassifier(random_state=42, max_depth=5, min_samples_split=2)
Máquina de soporte vectorial	Busca encontrar el hiperplano que mejor separa los puntos de datos en diferentes clases en un espacio multidimensional	SVC(probability=True, random_state=42, kernel='rbf')

### 2.7. Validación

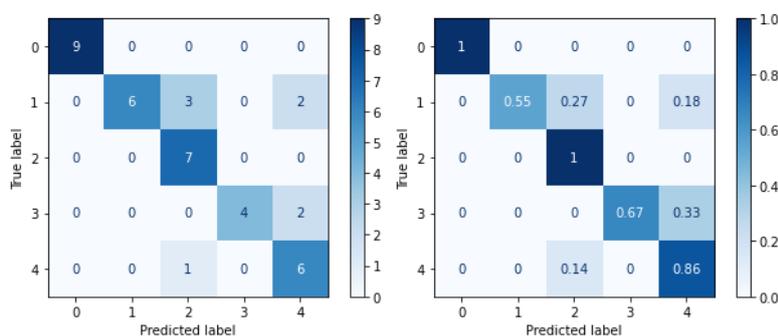
Estos modelos se evalúan utilizando métricas específicas que consideran el desequilibrio en la distribución de las clases. Entre las métricas utilizadas se incluyen: la precisión, que mide la proporción de predicciones correctas entre todas las predicciones realizadas; el recall (sensibilidad), que mide la proporción de casos positivos que fueron correctamente identificados por el modelo; el F1-score, que es la media armónica de precisión y recall; la exactitud, que mide las predicciones correctas en relación con todas las predicciones realizadas; la exactitud balanceada, que evalúa el rendimiento en situaciones de desequilibrio de clases; el índice Kappa de Cohen, que mide la concordancia entre las predicciones y las etiquetas; el índice de Jaccard, que cuantifica la similitud entre dos conjuntos de datos; el coeficiente de correlación de Matthews, que evalúa la calidad de las predicciones; la especificidad, que mide la proporción de casos negativos que fueron correctamente identificados, y la matriz de confusión, que muestra la distribución de las predicciones en comparación con las etiquetas reales.

## 3. Resultados y discusiones

En esta sección, se realiza una comparación del desempeño de los algoritmos de clasificación multiclase. Estos algoritmos son evaluados utilizando métricas específicas que consideran el desequilibrio presente en la distribución de las clases. De esta manera, se proporciona una evaluación más justa y equitativa del rendimiento de los modelos.

**Tabla 4.** Reporte de clasificación del modelo árbol de decisión.

	Clase 0	Clase 1	Clase 2	Clase 3	Clase 4
Precision	1.00	1.00	0.64	1.00	0.60
Recall	1.00	0.55	1.00	0.67	0.86
F1-score	1.00	0.71	0.78	0.80	0.71
Support	9	11	7	6	7
Accuracy	0.80				



**Fig. 3.** Matrices de confusión del modelo árbol de decisión (no normalizada y normalizada).

El análisis de métricas de evaluación en ML es un proceso fundamental para evaluar el rendimiento y la efectividad de un modelo de aprendizaje automático.

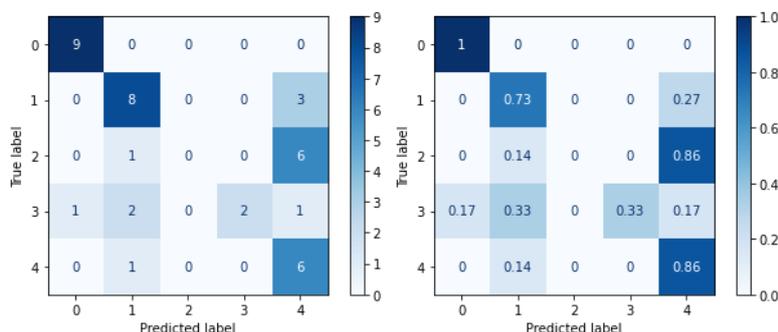
### 3.1. Evaluación del algoritmo de árbol de decisión

En la Tabla 4 se muestran los resultados del reporte de clasificación obtenidos mediante el algoritmo de árbol de decisión. Se observa para la clase 0, se logra una clasificación perfecta para la falla tipo 0. En la clase 1, todas las predicciones positivas de la falla tipo 1 son correctas, pero identifica el 55% de todos los casos reales de la falla tipo 1. En cuanto a la clase 2, el 64% de las predicciones positivas correspondientes a la falla tipo 2 son correctas e identifica todos los casos reales para esa clase. En la clase 3, todas las predicciones positivas de la falla tipo 3 son correctas, pero identifica el 67% de todos los casos reales para esa clase. Para el caso de la clase 4, el algoritmo logra una precisión del 60% en la predicción de la falla tipo 4 e identifica el 86% de todos los casos reales de dicha categoría. En general, este modelo presenta una exactitud del 0.80, indicando que el 80% de todas las predicciones hechas por el modelo son correctas.

Otras métricas para evaluar la clasificación con desequilibrio de clases son las siguientes: El algoritmo de árbol de decisión muestra una exactitud balanceada de 0.81, lo que indica un rendimiento aceptable en general. Sin embargo, el índice Kappa de Cohen muestra un valor de 0.75, sugiriendo una concordancia entre las predicciones del modelo y las etiquetas reales. El índice de Jaccard de 0.67 indica una similitud considerable entre las predicciones y las etiquetas reales. Además, un coeficiente de correlación de Matthews de 0.77 sugiere una estimación sustancial entre las predicciones y las etiquetas reales. Por otra parte, el algoritmo muestra una

**Tabla 5.** Reporte de clasificación del modelo máquina de soporte vectorial.

	Clase 0	Clase 1	Clase 2	Clase 3	Clase 4
Precision	0.90	0.67	0.00	1.00	0.38
Recall	1.00	0.73	0.00	0.33	0.86
F1-score	0.95	0.70	0.00	0.50	0.52
Support	9	11	7	6	7
Accuracy	0.62				



**Fig. 4.** Matrices de confusión del algoritmo de máquina de soporte vectorial (no normalizada y normalizada).

especificidad de 1 en la clase 0, lo que indica que es capaz de identificar correctamente las instancias de la clase negativa. La clase 1 tiene un valor de 0.54, indicando una especificidad baja para esa clase. En la clase 2 un valor de 1, indicando una especificidad alta para esa clase. Para la clase 3, el valor 0.66 indica una especificidad baja para esa clase. Y, la clase 4 tiene una regular especificidad de 0.86.

Con respecto a la métrica matriz de confusión, en la Figura 3 se muestra las matrices de confusión, tanto normalizada como no normalizada, de dicho algoritmo. Se puede observar en la matriz no normalizada que un total de 8 elementos están mal clasificados, de los cuales, tres fallas de tipo 1 es clasificado como falla de tipo 2, dos fallas de tipo 1 clasificado como falla de tipo 4, dos fallas de tipo 3 están clasificadas como falla de tipo 4 y una falla de tipo 4 clasificada como una falla de tipo 2.

### 3.2. Evaluación del algoritmo de máquina de soporte vectorial

En la Tabla 5 se muestran los resultados del reporte de clasificación obtenidos mediante el algoritmo de máquina de soporte de vectorial (SVM). Donde, en la clase 0 el 90% de las predicciones positivas de la falla tipo 0 son correctas e identifica todos los casos reales de la falla tipo 0, lo que significa un rendimiento sólido para esta clase. En la clase 1, el 67% de las predicciones positivas de la falla tipo 1 son correctas e identifica el 73% de todos los casos reales de la falla tipo 1. En la clase 2, el modelo no hace ninguna predicción correcta ni logra identificar ningún solo caso real de la falla tipo 2, lo que significa que el rendimiento es extremadamente deficiente para esa clase. En la clase 3, todas las predicciones positivas de la falla tipo 3 son correctas e identifica el 33% de todos los casos reales de la falla tipo 3. Y en la clase 4, el 38% de las

**Tabla 6.** Resumen de análisis de métricas.

	Árbol de decisión	Máquina de soporte vectorial
Exactitud	0.80	0.62
Exactitud balanceada	0.81	0.58
Precisión	0.87	0.60
Recall	0.80	0.62
F1-score	0.80	0.57
Especificidad	0.82	0.64
Índice de Kappa de Cohen	0.75	0.52
Índice de Jaccard	0.67	0.45
Coefficiente de correlación de Matthews	0.77	0.56

**Tabla 7.** Resumen de métricas por clase.

Modelo	Precisión por clase					Recall por clase					Especificidad por clase				
	0	1	2	3	4	0	1	2	3	4	0	1	2	3	4
Árbol de decisión	1.00	1.00	0.64	1.00	0.60	1.00	0.55	1.00	0.67	0.86	1.00	0.54	1.00	0.66	0.86
Máquina soporte vectorial	0.90	0.67	0.00	1.00	0.38	1.00	0.73	0.00	0.33	0.86	1.00	0.73	0.00	0.33	0.86

predicciones positivas de la falla tipo 4 son correctas e identifica el 86% de todos los casos reales de la falla tipo 4. El algoritmo SVM presenta una exactitud global del 0.62, indicando que el 62% de todas las predicciones hechas por el modelo son correctas.

Otras métricas para evaluar la clasificación con desequilibrio de clases son las siguientes: El algoritmo de máquina de soporte vectorial muestra una exactitud balanceada de 0.58, lo que indica que el modelo tiene en general un bajo rendimiento. El índice Kappa de Cohen muestra un valor de 0.52, sugiriendo una concordancia baja entre las predicciones del modelo y las etiquetas reales. El índice de Jaccard de 0.45 indica una similitud baja entre las predicciones y las etiquetas reales. Además, un coeficiente de correlación de Matthews de 0.56 sugiere una estimación moderada entre las predicciones y las etiquetas reales.

Con respecto a la métrica matriz de confusión del algoritmo de máquina de soporte vectorial (ver Fig. 4), se puede observar en la matriz no normalizada que un total de 15 elementos están mal clasificados, de los cuales, una falla tipo 3 es clasificada como falla tipo 0; una falla tipo 2, dos fallas tipo 3 y una falla tipo 4 son clasificadas como fallas tipo 1; y, tres fallas tipo 1, seis fallas tipo 2 y una falla tipo 3 son clasificadas como falla tipo 4.

### 3.3. Análisis de resultados

En la Tabla 6 se condensan los valores globales resultantes de cada algoritmo en relación con las métricas de evaluación mencionadas anteriormente. En la Tabla 7 se presenta el resumen de algunas métricas específicas para cada clase. Se observa que el modelo árbol de decisión logra el mejor rendimiento, prediciendo con mayor precisión

las clases de tipo 3 y 4, que son consideradas por los expertos como las fallas más graves en los generadores de potencia. Por esta razón, es preferible tener una menor tasa de falsos negativos en este tipo de fallas, ya que un falso negativo ocurre cuando una falla grave no es detectada por el modelo, lo cual podría llevar a no tomar las acciones preventivas necesarias, resultando en daños significativos y posibles interrupciones en el suministro de energía.

En el contexto del mantenimiento de generadores de potencia, la precisión del 87% y la especificidad del 82% destacan la efectividad del modelo de árbol de decisión en la identificación de fallas, especialmente las graves. Esta capacidad resulta crucial para prevenir daños significativos y garantizar la continuidad del suministro de energía. Con un recall del 80%, el modelo es capaz de detectar la mayoría de las fallas existentes, lo cual es fundamental para la seguridad y el rendimiento de los generadores. Un menor índice de falsos negativos es esencial, ya que la falta de detección de una falla grave podría ocasionar fallos catastróficos y costosos. Además, la exactitud balanceada del 81% y el coeficiente de correlación de Matthews del 77% demuestran que el modelo logra un equilibrio adecuado entre la clasificación de casos positivos y negativos, lo cual es crucial en situaciones donde las clases están desequilibradas, como es común en los datos de fallas de equipos.

Estos resultados indican que el modelo árbol de decisión representa una herramienta valiosa para mejorar la eficacia y eficiencia de las estrategias de mantenimiento preventivo y predictivo en los sistemas de generación de energía.

#### **4. Conclusiones**

Se presenta el desarrollo de un modelo inteligente para la detección de fallas en un generador de potencia. Se trata de una aplicación industrial de la Inteligencia Artificial donde la calidad y disponibilidad de los datos es limitada. El modelo inteligente se desarrolló utilizando una metodología estándar para la construcción de modelos basados en Machine Learning. Para su entrenamiento, se empleó una base de datos de pruebas convencionales (descargas parciales, factores de disipación, entre otros) utilizadas para determinar el estado de salud de los generadores. Esta base de datos, compuesta por 196 pruebas de generadores asociadas a distintos tipos de fallas y curada por expertos en equipos eléctricos, fue esencial para el proceso. En la etapa de procesamiento de datos, se aplicó ingeniería de características para extraer mayor información y generar un modelo con mayor precisión.

Los resultados indican que el modelo de árbol de decisión ofrece el mejor rendimiento, con una precisión del 87% en la detección de fallas y una exactitud balanceada del 81% en la clasificación del tipo de fallas. Para evaluar el rendimiento del modelo y considerar el desequilibrio en la distribución de las clases, se utilizaron diversas métricas como la exactitud balanceada, el índice de Kappa de Cohen, el índice de Jaccard y el coeficiente de correlación de Matthews. Esto es especialmente importante en este dominio, ya que se requiere predecir con mayor exactitud las fallas de tipo 3 y 4, consideradas por los expertos como las más graves. Estas fallas pueden detener la operación de un generador, lo que hace crucial mantener una menor tasa de falsos negativos.

La capacidad del modelo para identificar de manera precisa estas fallas críticas no solo mejora la seguridad y la eficiencia operativa, sino que también ayuda a prevenir paradas no planificadas y costosas en el sistema de generación de energía.

Como trabajo futuro se plantea utilizar otros algoritmos de aprendizaje automático tanto de tipo clásico, como ensamblados. También se plantea un proceso normado para generar datos de pruebas de índice de salud de generadores confiables que garanticen la disponibilidad y confiabilidad de los datos de prueba. Por último, los resultados obtenidos serán comparados por los procedimientos empíricos utilizados por los expertos en generadores, con la finalidad de mostrar la calidad de la predicción de fallas y desarrollar un sistema inteligente para la determinación del índice de salud y el diagnóstico de fallas de generadores de potencia.

## Referencias

1. Comisión Federal de Electricidad: Historia de la empresa, <https://www.cfe.mx/nuestraempresa/pages/historia.aspx> (2024)
2. CINVESTAV: Sistemas eléctricos de potencia, <https://www.cinvestav.mx/Departamentos/Sistemas-Elctricos-de-Potencia> (2024)
3. Yang, B., Li, F., Ye, J., Song, W.: Condition Monitoring and Fault Diagnosis of Generators in Power Networks. In: IEEE Power and Energy Society General Meeting, pp. 1–5 (2019). DOI: 10.1109/PESGM40551.2019.8973427.
4. CIGRE: <https://www.cigre.org.mx/> (2024)
5. Ramírez-Monguá, J.J., Dávila-Arias, J.Y.: Hacia el mantenimiento basado en condición de los dispositivos inteligentes en la industria 4.0 (2022)
6. Cerón, A.F., Echeverry, D.F., Aponte, G., Romero, A.A.: Índice de salud para transformadores de potencia inmersos en aceite mineral con voltajes entre 69kV y 230kV usando lógica difusa. *Información tecnológica*, vol. 26, no. 2, pp. 107–116 (2015). DOI: 10.4067/S0718-07642015000200013.
7. Campuzano-Martínez, I.R.: Diagnóstico de generadores eléctricos de potencia con técnica de monitoreo en línea y fuera de línea. *Información tecnológica*, vol. 27, no. 2, pp. 11–20 (2016). DOI: 10.4067/S0718-07642016000200003.
8. Yucesan, M., Başhan, V., Demirel, H., Gul, M.: An Interval Type-2 Fuzzy Enhanced best–Worst Method for the Evaluation of Ship Diesel Generator Failures. *Engineering Failure Analysis*, vol. 138, pp. 106428 (2022). DOI: 10.1016/j.engfailanal.2022.106428.
9. Altaf, S., Al-Anbuky, A., Gholam-Hosseini, H.: Fault Diagnosis in a Distributed Motor Network using Artificial Neural Network. *International Symposium on Power Electronics, Electrical Drives, Automation and Motion*, pp. 190–197 (2014). DOI: 10.1109/SPEEDAM.2014.6871946.