

# Stator fault diagnosis of a permanent magnet synchronous generator using a decision tree classifier

J.A. Álvarez-Salas \* \*\* R. Álvarez-Salas \* M.A. González-García \*\*\*

F.J. Villalobos-Piña \*\* V. Cárdenas \*

\*Universidad Autónoma de San Luis Potosí, San Luis Potosí, S.L.P., 78290 México

(e-mail: [jaas@uaslp.mx](mailto:jaas@uaslp.mx), [ralvarez@uaslp.mx](mailto:ralvarez@uaslp.mx), [vcarden@uaslp.mx](mailto:vcarden@uaslp.mx))

\*\*Tecnológico Nacional de México / Instituto Tecnológico de Aguascalientes, Aguascalientes, Ags., 20255 México  
(e-mail: [francisco.vp@aguascalientes.tecnm.mx](mailto:francisco.vp@aguascalientes.tecnm.mx))

\*\*\*CONAHCYT / Universidad Autónoma de San Luis Potosí, San Luis Potosí, S.L.P., 78290 México

(e-mail: [mgonzale@uaslp.mx](mailto:mgonzale@uaslp.mx))

---

**Abstract:** This work presents a decision tree-based classifier to diagnose short circuit faults between the stator's turns in a permanent magnet synchronous generator. The generator currents are processed with the discrete wavelet transform to obtain features to feed the binary classifier that performs the diagnosis. Experimental results are presented to show the performance of the proposed scheme.

**Keywords:** Binary classifier, decision tree, faults, permanent magnet synchronous generator.

---

## 1. INTRODUCCIÓN

Los métodos de aprendizaje automático han sido ampliamente usados en el diagnóstico de fallas mecánicas, eléctricas o ambas en los diferentes tipos de máquinas eléctricas. El aprendizaje automático puede clasificar y localizar las fallas presentes en los componentes de la máquina eléctrica en tiempo real empleando un procesador digital. El grado de complejidad de los algoritmos de aprendizaje es determinado por el nivel de asertividad en el diagnóstico de la máquina eléctrica, Nitish et al., (2019). El aprendizaje automático forma parte de los sistemas de reconocimiento de patrones, típicamente estos sistemas se conforman de tres partes: el sensor o transductor, el extractor de características y el clasificador, Toliyat et al., (2017).

En el monitoreo de máquinas eléctricas se han implementado sistemas de reconocimiento de patrones y el diseño de clasificadores para el diagnóstico de diversas fallas a través del aprendizaje automático. Estos métodos hacen uso de patrones para distinguir la operación aceptable o inaceptable de la máquina y así determinar la existencia de alguna falla. Los patrones pueden ser determinados por observaciones basadas en la operación con falla o por simulación de un modelo del sistema. Una vez entrenado el sistema de aprendizaje automático es posible que reconozca y clasifique las fallas en la máquina. Sin embargo, una de las desventajas que presenta el reconocimiento de patrones es la dependencia de una gran cantidad de datos en el proceso de entrenamiento para diagnosticar una falla, Kumar et al., (2021).

Se han publicado diversos trabajos para el diagnóstico de fallas en máquinas síncronas. En Hoang and Kang, (2020), se propone el diagnóstico de fallas en rodamientos a través de las señales de corriente de un motor síncrono de imanes permanentes, utilizando el aprendizaje profundo y el proceso de fusión de la información. En Kao et al., (2019), se presenta

el diagnóstico de un motor síncrono de imán permanente con diferentes fallas, a través de un algoritmo que extrae información de las corrientes. Se proponen dos métodos de extracción de características de los datos y la clasificación por medio de la ondeleta empaquetada y una red neuronal convolucional 1-D.

En lo que respecta a las máquinas de inducción, en Goktas et al., (2021) se desarrolló un algoritmo basado en un perceptrón multicapa utilizando las señales de corriente y vibraciones mecánicas para la detección automática de la desalineación mecánica en el motor de inducción trifásico. En Younas et al., (2021) se presenta el diagnóstico de fallas en barras del rotor de un motor de inducción a través de seis clasificadores como parte de la técnica de aprendizaje automático que valora la exactitud de las variables de flujo y corriente que diagnostican la falla. En Mao et al., (2019) se utilizan las herramientas del módulo del vector de Park y los árboles de decisión para clasificar las fallas mixtas de barras rotas y excentricidad en el entrehierro de un motor de inducción. En Choudhary et al., (2021) se emplea análisis termográfico y los árboles de decisión para clasificar las fallas en rodamientos en un motor de inducción.

En este trabajo se presentan los resultados de la aplicación de un clasificador binario, basado en un árbol de decisión, para el diagnóstico de fallas de corto circuito entre vueltas del estator de un generador síncrono de imanes permanentes (GSIP). En la Sección 2, se analizan los fundamentos teóricos del clasificador y el extractor de características de las corrientes del GSIP. La Sección 3 presenta un banco de pruebas basado en un GSIP desarrollado para validar algoritmos de diagnóstico de fallas en el estator de diferente severidad. En la Sección 4, se valida el desempeño del clasificador con datos experimentales empleando diferentes métricas para diversas condiciones de falla del estator. La Sección 5 presenta las conclusiones.

## 2. CLASIFICADOR BINARIO

Dentro del aprendizaje automático se encuentra el aprendizaje supervisado, esta técnica requiere de un conjunto de datos con las características de las clases y las etiquetas correspondientes para entrenar un modelo de aprendizaje automático. Con la entrada se entrena al algoritmo de aprendizaje para que se genere un modelo predictivo capaz producir predicciones una vez que el modelo se le ingresan nuevos datos.

La clasificación es una subcategoría del aprendizaje supervisado, cuyo propósito es predecir las etiquetas en una nueva clase a través de observaciones pasadas del algoritmo de aprendizaje. Las etiquetas de la nueva clase son valores binarios y desordenados, cuyo propósito es agruparlos en una nueva categoría considerando determinadas reglas en el ordenamiento.

Las entradas del clasificador binario tienen que provenir de una señal procesada de las señales eléctricas o mecánicas que se monitorean de la máquina eléctrica. En la Figura 1 se indica el proceso de la clasificación desde la medición de las variables como tensión, corriente, flujo magnético, velocidad, par o vibración mecánica para extraer las características a través del procesamiento de estas señales en la frecuencia, en la frecuencia-tiempo, en el tiempo-escala, o cualquier otro método, para luego emplearlas como datos de entrenamiento y prueba en el clasificador y, finalmente, obtener la clasificación sin falla o con falla.

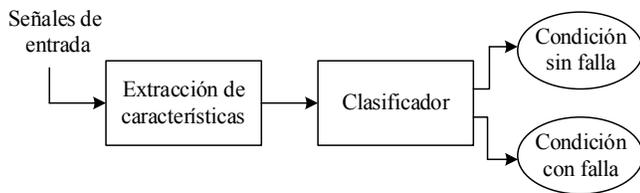


Figura 1. Diagrama a bloques de la clasificación binaria.

Existen diversos algoritmos de aprendizaje supervisado que se emplean como clasificadores binarios. En la siguiente sección, se describe un algoritmo que fue elegido, en primera instancia, en la implementación del clasificador binario para detectar la existencia de una falla eléctrica en el estator del GSIP.

### 2.1 Árboles de decisión

Los árboles de decisión son un algoritmo de aprendizaje automático que permite operar como clasificadores, en donde a través de los nodos y las ramas se va realizando una serie de decisiones que permiten generar la clasificación binaria. En la Figura 2 se muestra un esquema general del árbol de decisiones con tres capas y varias hojas. La distribución de los árboles se basa en una serie de cuestionamientos que permiten ser valorados a través de las acciones que llevan a más de una opción que trate de resolver la pregunta. Dependiendo de la complejidad de la clasificación se puede generar el número de capas en el árbol, Raschka et al., (2019).

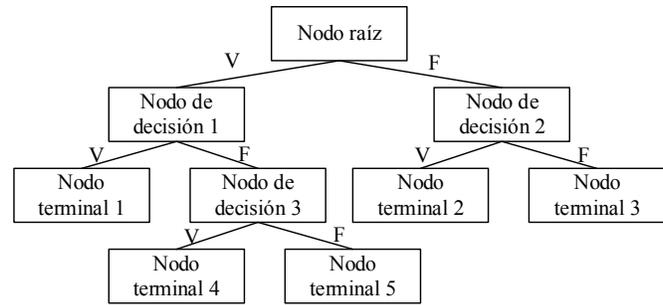


Figura 2. Diagrama de la estructura de un árbol de decisión.

Con este algoritmo de decisión se inicia en la raíz del árbol y se dividen los datos en las características que resulten en la mayor ganancia de información (IG, por sus siglas en inglés). Un proceso iterativo se puede repetir en cada nodo interno hasta que las hojas sean puras. Esto significa que todos los datos de entrenamiento en cada nodo pertenecen a la misma clase, lo que puede generar un árbol muy profundo con muchos nodos, generando un sobreajuste en la clasificación. En la práctica esto no sucede ya que de origen se debe limitar los niveles del árbol.

El árbol de decisión emplea una función objetivo que optimiza el algoritmo de aprendizaje a través de la ganancia de información en cada nodo. La expresión de la ganancia de información se describe por la ecuación (1).

$$IG(D_p, f) = I(D_p) - \sum_{j=1}^m \frac{N_j}{N_p} I(D_j) \quad (1)$$

donde  $f$  es la característica de desempeño de la división en el nodo,  $D_p$ ,  $D_j$  son el conjunto de datos del  $n$ -ésimo nodo padre e hijo,  $I$  es la medición de la impureza,  $N_p$  número de ejemplos de entrenamiento del nodo padre y  $N_j$  número de ejemplos de entrenamiento del nodo hijo. Los niveles de impureza o criterios de división que utilizan los árboles de decisiones son: impureza Gini y entropía.

La entropía es una medida de la variable aleatoria, también se puede describir como la cantidad de información requerida en un promedio para describir la variable aleatoria. Se define de acuerdo con la siguiente expresión (2).

$$I_H = - \sum_{i=1}^c P(i) \log_2 P(i) \quad (2)$$

donde  $P(i)$  es la probabilidad de que un suceso “ $i$ ” ocurra en el nodo.

La impureza Gini es un criterio que reduce la probabilidad de una clasificación errónea, se define con la expresión (3).

$$I_G = 1 - \sum_{i=1}^c P(i)^2 \quad (3)$$

En la práctica, la impureza Gini como la entropía suelen producir resultados muy similares.

## 2.2 Transformada ondeleta discreta

La herramienta de análisis para señales con escalas de tiempo y frecuencias distintas es básicamente una transformación de la señal con funciones que seccionan los datos con diferentes componentes de frecuencia para variar su resolución. A la familia de funciones matemáticas adecuadas para este fin se le conoce como transformada ondeleta y se obtiene a partir de una función base llamada ondeleta madre. La transformada ondeleta es función de la dilatación de la escala y de la translación del tiempo, Verde et al., (2013).

Dentro de las ondeletas más utilizadas se encuentra la ondeleta Daubechies 4, denominada Daub4. En la implementación de la transformada ondeleta discreta con la ondeleta Daub 4, el cálculo de sus coeficientes de las tendencias se define por la expresión (4), Walker, (2008).

$$a^n = \alpha_1 a^{n-1}[m]+ \alpha_2 a^{n-1}[m-1]+ \alpha_3 a^{n-1}[m-2]+ \alpha_4 a^{n-1}[m-3] \quad (4)$$

donde los coeficientes de escalamiento se calculan por medio de las siguientes expresiones (5).

$$\alpha_1 = \frac{1 + \sqrt{3}}{4\sqrt{2}} \quad \alpha_2 = \frac{3 + \sqrt{3}}{4\sqrt{2}} \quad (5)$$

$$\alpha_3 = \frac{3 - \sqrt{3}}{4\sqrt{2}} \quad \alpha_4 = \frac{1 - \sqrt{3}}{4\sqrt{2}}$$

El cálculo de sus coeficientes de las fluctuaciones se define por la expresión (6).

$$d^n = \beta_1 d^{n-1}[m]+ \beta_2 d^{n-1}[m-1]+ \beta_3 d^{n-1}[m-2]+ \beta_4 d^{n-1}[m-3] \quad (6)$$

donde los coeficientes de la ondeleta se calculan por medio de las expresiones (7).

$$\beta_1 = \frac{1 - \sqrt{3}}{4\sqrt{2}} \quad \beta_2 = \frac{\sqrt{3} - 3}{4\sqrt{2}} \quad (7)$$

$$\beta_3 = \frac{3 + \sqrt{3}}{4\sqrt{2}} \quad \beta_4 = \frac{-1 - \sqrt{3}}{4\sqrt{2}}$$

La descomposición de una señal mediante la transformada ondeleta en un cierto número de niveles, correspondientes a diferentes bandas de frecuencia, se determina por la expresión (8), Cherif et al., (2015).

$$n = \left\lceil \frac{\log\left(\frac{f_s}{f_{señal}}\right)}{\log(2)} \right\rceil \quad (8)$$

donde  $f_s$  es la frecuencia a la cual se muestrea la señal,  $f_{señal}$  es la frecuencia de la señal original y  $n$  debe ser un número entero.

En el procesamiento de las señales a través de la transformada ondeleta discreta, es común obtener el valor eficaz (RMS, por sus siglas en inglés) de los coeficientes de las señales de tendencia y fluctuación, para los diferentes niveles en que se descompone la señal, con el fin de extraer características de

las señales medidas para los algoritmos de aprendizaje automático. El valor eficaz se define por la expresión (9).

$$V_{RMSj} = \sqrt{\frac{1}{N} \sum_{k=1}^n |M_{jk}(n)|^2} \quad (9)$$

donde  $j$  es el nivel de la descomposición,  $N$  es el número de muestras de la señal y  $M_k$  es la magnitud de las componentes de la subseñal promedio o tendencia Walker, (2008).

En este trabajo se emplea la transformada ondeleta discreta para procesar las señales de corriente que se monitorean del GSIP para extraer las características de éstas.

## 2.3 Métricas para la validación de los clasificadores

En los clasificadores binarios, las métricas permiten validar el desempeño del modelo. Se realiza una comparativa entre los datos de entrenamiento y de prueba que se utilizaron en el modelo del clasificador binario.

Algunas métricas que se emplean para la validación de los algoritmos de clasificación binaria son los siguientes:

- Matriz de confusión
- Exactitud
- Precisión
- Sensibilidad
- Especificidad
- Curvas ROC

La matriz de confusión es la herramienta base para conocer lo adecuado o no del modelo de la clasificación desarrollada. Como tal, la matriz no es una medida o indicador unívoco de lo bueno o de lo malo que es un modelo por sí mismo, pero sí es la base para construir diferentes medidas de rendimiento de un algoritmo clasificador. En la Figura 3, se muestra la estructura de la matriz de confusión, Verde et al., (2013).

		Predicción	
		Simétrico	Falla
Clase Real	Simétrico	Verdadero Positivo	Falso Negativo
	Falla	Falso Positivo	Verdadero Negativo

Figura 3. Matriz de confusión para la validación del clasificador binario.

Otras métricas que se utilizan para la validación de los modelos de aprendizaje automático son las que se describen por las expresiones (10)-(13).

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN} \quad (10)$$

$$Precisión = \frac{VP}{VP + FP} \quad (11)$$

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \quad (12)$$

$$\text{Especificidad} = \frac{VN}{VN + FP} \quad (13)$$

donde  $VP$  son los verdaderos positivos,  $VN$  son los verdaderos negativos,  $FP$  son los falsos positivos y  $FN$  son los falsos negativos. Cabe señalar que la suma  $VP + VN$  corresponde a las predicciones correctas.

Las curvas ROC presentan la sensibilidad en función de los falsos positivos para distintos puntos de corte. Son útiles para elegir el punto de corte más adecuado de una valoración, conocer el rendimiento global de ésta y comparar la capacidad discriminativa de dos o más valoraciones diagnósticas. Se grafican entre las relaciones de la sensibilidad y la especificidad.

### 3. BANCO DE PRUEBAS

Un GSIP de 400 W/12V trifásico, forma parte de un banco de pruebas, que se utilizó para la evaluación del clasificador en presencia de fallas de cortocircuito entre vueltas del estator. El generador fue modificado con derivaciones en la fase A y B, para que externamente se puedan controlar la severidad de las fallas de cortocircuito entre vueltas de una misma fase o entre vueltas de dos fases diferentes. Las derivaciones se disponen de 1 a 7 vueltas en las fases modificadas.

En la Figura 4 se muestra los bloques del banco de pruebas del generador y en la Figura 5 una imagen de su implementación. Básicamente, se conforma de un circuito para la adquisición de las señales de corriente con una carga trifásica resistiva en las terminales del generador. A través de sensores de efecto Hall se adquieren las señales de corriente, las cuales entran a una etapa de acondicionamiento de señales para luego ser adquiridas por un procesador digital de señales dsPIC30F4011. Una vez que se dispone de las señales de corriente, la extracción de características y el clasificador se implementan en un programa en Python.

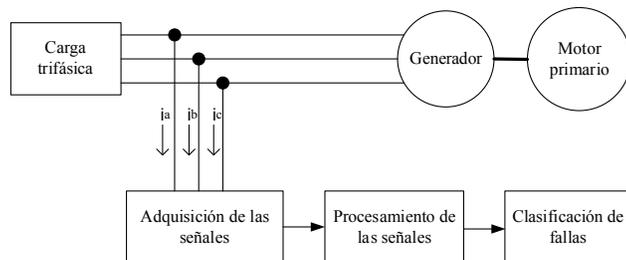


Figura 4. Diagrama a bloques del banco de pruebas del GSIP.



Figura 5. Banco de pruebas del GSIP.  
<https://doi.org/10.58571/CNCA.AMCA.2024.068>

### 4. RESULTADOS

Como parte de las pruebas y resultados en las etapas de adquisición, extracción de características y clasificación de las fallas entre vueltas del estator del GSIP, se empleó una velocidad de operación del generador de 200 rpm, con señales de corriente a una amplitud y frecuencia de 2 A, 20 Hz y una frecuencia de muestreo de 1 kHz. Se adoptó la frecuencia de muestreo de 1 kHz, debido a que permite capturar las frecuencias de interés por debajo de la frecuencia de Nyquist a 500 Hz en las diferentes bandas de frecuencia de las señales generadas por la transformada ondeleta discreta con la ondeleta Daub4.

Se calculó el valor eficaz de los coeficientes de cada una de las señales de tendencia y fluctuación dadas por la transformada ondeleta discreta de acuerdo con la expresión (9). Las diferentes bandas de frecuencia se obtuvieron considerando los valores de la frecuencia de la señal y la frecuencia de muestreo, como se indica en la expresión (8). En la Tabla 1, se muestran los valores eficaces (RMS) de los coeficientes de las señales de tendencias (A) y fluctuaciones (D).

A través de un algoritmo en Python, se analizaron las señales de corriente en cuatro niveles de descomposición dados por la transformada ondeleta discreta. En la Figura 6, se graficó la importancia de cada característica, correspondiendo la mayor a la dada por la señal de fluctuación de nivel 4.

Los datos de entrada al clasificador binario se conformaron con los valores RMS de los coeficientes de las señales de tendencia y fluctuación en condiciones de simetría (sin falla), y con los datos de una de las tres fallas de corto circuito entre vueltas del estator. Se le asoció una etiqueta a los datos para clasificar las condiciones sin falla o con falla a través de los valores 0 y 1, respectivamente. La Tabla 2 muestra las características generadas con los datos adquiridos para un cierto experimento.

El algoritmo de clasificación recibe como entrada los ocho características dadas por los valores RMS de las señales generadas por la transformada ondelata más la etiqueta. Los datos utilizados para la evaluación del clasificador fueron 30 adquisiciones de las corrientes sin falla y 30 adquisiciones de las corrientes con falla, por lo que se construyeron tres arreglos de 60 filas con 9 columnas como datos de entrada para el entrenamiento y prueba del clasificador.

Se realizó un escalamiento de los datos para facilitar al algoritmo el proceso de aprendizaje. Se efectuó una separación de los datos de la siguiente manera: 70% para entrenamiento y 30% para prueba.

En el árbol de decisiones, se utilizaron la impureza Gini y la entropía como criterios de división, encontrando resultados similares en la clasificación. Para validar los resultados del clasificador ante los diferentes escenarios de falla en el estator del GSIP se emplearon las métricas que se describen en la Sección 2.3. En la Tabla 3 se indica el resultado de las métricas del Exactitud y Precisión. Cuando estas métricas producen como resultado la unidad, indican el mejor desempeño posible del clasificador. Se puede observar que

aún con la falla más incipiente el clasificador puede dictaminar correctamente el estado de la máquina.

Tabla 1. Valor RMS de los coeficientes de las señales de tendencia y fluctuación dados por la transformada ondeleta discreta para un experimento – Caso sin falla.

Característica	Caso simétrico (sin falla)
A1	4.419
A2	6.253
A3	8.852
A4	12.52
D1	0.026
D2	0.077
D3	0.180
D4	0.340

Tabla 2. Valor RMS de los coeficientes de las señales de tendencia y fluctuación dados por la transformada ondeleta discreta para un experimento – Casos con falla.

Característica	Caso con falla 1 vta fase A	Caso con falla 4 vtas fase A	Caso con falla 7 vtas A 2 vtas B
A1	4.422	4.456	4.574
A2	6.265	6.301	6.468
A3	8.860	8.908	9.148
A4	12.506	12.57	12.964
D1	0.027	0.029	0.030
D2	0.082	0.087	0.096
D3	0.182	0.185	0.189
D4	0.360	0.361	0.403

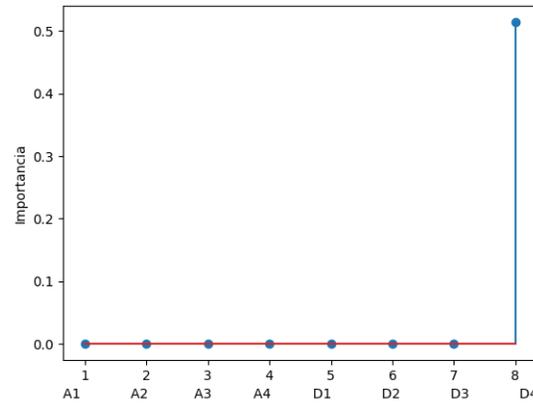


Figura 6. Importancia de las características para el caso con una falla de corto circuito de 1 vuelta en la fase A.

Tabla 3. Datos de las métricas del clasificador para los casos con falla.

Condición	Exactitud	Precisión
1 vta fase A	1	1
4 vtas fase A	1	1
7 vtas fase A		
2 vtas fase B	1	1

Tabla 4. Matriz de confusión del clasificador para los casos con falla.

Condición	VP	VN	FP	FN
1 vta fase A	19	23	0	0
4 vtas fase A	19	23	0	0
7 vtas fase A				
2 vtas fase B	19	23	0	0

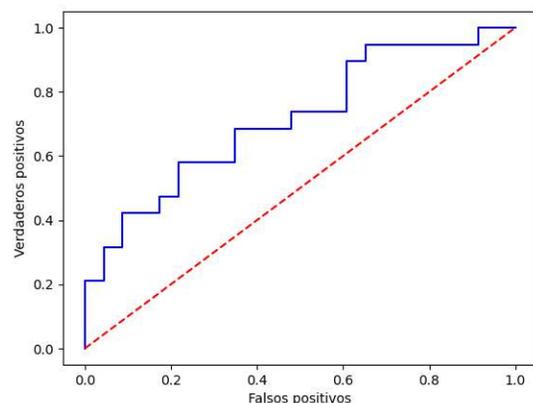


Figura 7. Curvas ROC, caso con una falla de 1 vuelta en la fase A.

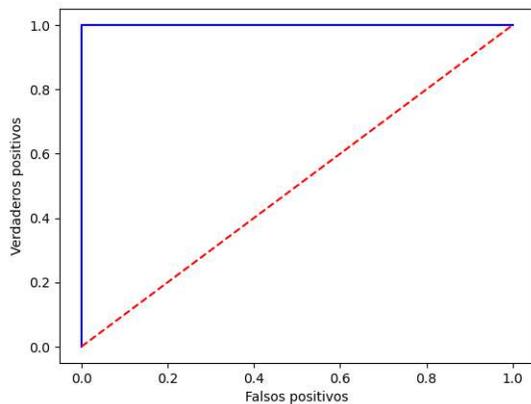


Figura 8. Curvas ROC, caso con una falla de 7 vueltas en la fase A y 2 vueltas de la fase B.

Respecto a la matriz de confusión, de la proporción de datos con las que se entrena el algoritmo, no se generan ningún falso positivo o falso negativo, como se muestra en la Tabla 4. Lo que indica una acertividad en el diagnóstico de las fallas, inclusive en el caso de las más incipiente de 1 vuelta en cortocircuito en el estator del GSIP.

De forma complementaria, las curvas ROC, de las Figuras 7 y 8, indican que porcentaje de los datos ha sido capaz de identificar correctamente el modelo. En la Figura 7, para el caso más incipiente, la curva se encuentra por arriba de la línea del umbral, pero no alcanza a reflejar el valor más alto de los verdaderos positivos. En cambio en la Figura 8 la proporción de los verdaderos positivos en el modelo es el mayor valor que se pueda presentar en este tipo de curvas.

## 5. CONCLUSIONES

En este trabajo se presentó un clasificador binario empleando un algoritmo con árboles de decisión para el diagnóstico de fallas entre vueltas de un estator en un GSIP. La utilización de la transformada Daub4 en las primeras bandas de frecuencia, presentan una variación del valor eficaz de las señales de tendencias y fluctuaciones al considerar la condición de simetría y con la falla más incipiente del estator. Esto permite que el proceso de clasificación binaria sea más eficiente. Durante la validación del algoritmo de clasificación se observó un desempeño elevado ante la falla más incipiente del generador. Se implementó un banco de pruebas para validar los algoritmos de la transformada ondeleta discreta y el árbol de decisiones en conjunto como herramientas para un diagnóstico de fallas confiable y con una estructura relativamente simple.

## AGRADECIMIENTOS

El primer autor agradece el apoyo para la realización de este trabajo a la L.E.I. Ana Cecilia Rivera Rivera de la UASLP.

## REFERENCIAS

Cherif, H., Menacer, A., Bessam, B., and Kechida, R. (2015). Stator inter turns fault detection using discrete wavelet transform. *Proceedings - SDEMPED 2015: IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives*, 138–142. <https://doi.org/10.1109/DEMPED.2015.7303681>

- Choudhary, A., Goyal, D., Letha, S.S. (2021). Infrared Thermography-Based Fault Diagnosis of Induction Motor Bearings Using Machine Learning. *IEEE Sens. J.*, 21, 1727–1734 DOI: 10.1109/JSEN.2020.3015868
- Goktas, T., Arkan, M., and Gurusamy, V. (2021). A Comparative study of current, vibration and stray magnetic flux based detection for parallel misalignment fault in induction motors. *13th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, SDEMPED 2021*, 11–16. <https://doi.org/10.1109/SDEMPED5110.2021.9605>
- Hoang, D.T. and Kang, H.J. (2020). A motor current signal-based bearing fault diagnosis using deep learning and information fusion. *IEEE Transactions on Instrumentation and Measurement*, 69(6), 3325–3333. <https://doi.org/10.1109/TIM.2019.2933119>
- Kao, I.H., Wang, W.J., Lai, Y.H., and Perng, J.W. (2019). Analysis of permanent magnet synchronous motor fault diagnosis based on learning. *IEEE Transactions on Instrumentation and Measurement*, 68(2), 310–324. <https://doi.org/10.1109/TIM.2018.2847800>
- Kumar, R. et al. (2021). A Topological Neural-Based Scheme for Classification of Faults in Induction Machines. *IEEE Transactions on Industry Applications* 57(1): 272–83. DOI: 10.1109/TIA.2020.3032944
- Mao, J.; Chen, F.; Jiang, B.; Wang, L. (2019). Composite Fault Diagnosis of Rotor Broken Bar and Air Gap Eccentricity Based on Park Vector Module and Decision Tree Algorithm. *In Proceedings of the CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes (SAFEPROCESS)*, Xiamen, China, 5–7 July 2019; pp. 701–706.
- Nitish, A. and Singh, A. K. (2019). Condition Monitoring and Fault Diagnosis Techniques of Electric Machines. *In 2019 3rd International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE)*, 594–599. DOI: 10.1109/RDCAPE47089.2019.8979045
- Raschka, S. and Mirjalili, V. (2019). *Python Machine Learning*. Third Edit. Birmingham UK: Packt Birmingham-Mumbai
- Toliyat, H. A., Nandi S., Choi S., Meshgin-Kelk H. (2017). *Application of Pattern Recognition to Fault Diagnosis. In Electric Machines Modeling, Condition Monitoring and Fault Diagnosis*, ed. CRC Press. USA: Taylor and Francis Group, 185. <https://doi.org/10.1201/b13008>
- Verde, C., Gentil, S., and Morales Menéndez, R. (2013). *Monitoreo y Diagnóstico Automático de fallas en Sistemas Dinámicos*. Trillas.
- Walker, J.S. (2008). *A primer on wavelets and their scientific applications*, second edition. Chapman & Hall/CRC.
- Younas, M.B., Ullah, N., Goktas, T., Arkan, M., and Gurusamy, V. (2021). The performance evaluation of machine learning based techniques via stator current and stray flux for broken bar fault in induction motors. *IEEE 13th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives*, <https://doi.org/10.1109/SDEMPED5010.201.9605516>