

La regresión logística como clasificador en el diagnóstico de fallas eléctricas en un generador síncrono de imanes permanentes

Logistic regression as a classifier in the diagnostic of electrical failures in a permanent magnet synchronous generator

José Antonio **Álvarez Salas**¹, Ricardo **Álvarez Salas**², Francisco Javier **Villalobos Piña**³,
Mario Arturo **González García**⁴, Amparo **Rodríguez Cobos**⁵, J. Rafael **Molina Contreras**⁶

Tecnológico Nacional de México, Instituto Tecnológico de Aguascalientes, Aguascalientes, MÉXICO

¹ ORCID: 0009-0005-6530-0500 | jaas@uaslp.mx

³ ORCID: 0000-0003-1053-5642 | francisco.vp@aguascalientes.tecnm.mx

⁶ ORCID: 0000-0001-7249-9259 | jrafael.mc@aguascalientes.tecnm.mx

Universidad Autónoma de San Luis Potosí, San Luis Potosí, MÉXICO

² ORCID: 0000-0002-7646-0260 | ralvarez@uaslp.mx

⁴ ORCID: 0000-0003-4653-4895 | mgonzale@uaslp.mx

⁵ ORCID: 0009-0005-3549-7293 | amparo.rodriguez@uaslp.mx

Recibido 21/10/2024, aceptado 01/04/2025.

Resumen

En este trabajo se emplean la transformada ondeleta Haar y un clasificador binario basado en la regresión logística para identificar las fallas de cortocircuito (c.c.) entre vueltas del estator, en un generador síncrono de imanes permanentes (GSIP). El extractor de características procesa las corrientes a través de la transformada Haar empleando la descomposición multinivel, de la cual se obtienen los valores eficaces de sus coeficientes para formar junto con la función objetivo los datos que recibe el clasificador binario en el proceso de entrenamiento y validación. Ante diferentes condiciones de falla de c.c. en el estator se analizan las métricas que validan el desempeño de la regresión logística como clasificador binario. Actualmente en el diagnóstico de fallas del GSIP se requieren de algoritmos de clasificación más simples y robustos que permitan su implementación en línea. Se presentan pruebas experimentales de un banco de pruebas del GSIP en el cual se adquieren y se procesan digitalmente las corrientes que analiza el clasificador binario para el diagnóstico de la falla. Como etapa inicial en el desarrollo de los algoritmos de diagnóstico aplicados al GSIP, se comparó el desempeño ante diferentes fallas de la regresión logística, con el desempeño de un perceptrón a través de Python.

Palabras clave: clasificador binario, cortocircuito, estator, falla, generador síncrono, regresión logística.

Abstract

In this paper, the wavelet Haar transform, and a binary classifier based on logistic regression are utilized to identify short-circuit (s.c.) faults between stator windings in a permanent magnet synchronous generator (PMSG). The feature extractor processes the currents through the Haar transform, obtaining the effective values of its coefficients. These values, along with the objective function, form the data received by the binary classifier during the training and validation processes. The performance of the logistic regression as a binary classifier is analyzed under different stator fault conditions. The necessity for simpler and more robust classification algorithms in PMSG fault diagnosis allowing online implementation is evident. The test bench of a PMSG presents the currents that are analyzed by the binary classifier for the purpose of fault diagnosis. These currents are acquired and subsequently processed digitally. As a preliminary step in the development of the diagnostic algorithms applied to the PMSG, the performance of the logistic regression model was compared with that of a perceptron model using Python.

Index terms: binary classifier, logistic regression, faults, short circuit, stator, synchronous generator.

I. INTRODUCCIÓN

Las máquinas síncronas de imán permanente han tenido un incremento importante en aplicaciones como: turbinas eólicas, turbinas hidráulicas, aplicaciones marinas, vehículos eléctricos, sistemas de posicionamiento y sistemas de control de velocidad con diversas aplicaciones industriales, por su eficiencia, su relación potencia de salida-volumen, así como la elevada relación par-corriente [1].

Hoy en día es importante ofrecer confiabilidad en la operatividad de los equipos que emplean máquinas síncronas, por lo que se ha observado la necesidad de desarrollar algoritmos de diagnóstico que identifiquen diversos tipos de fallas en la máquina bajo diferentes ciclos de operación. Generalmente los algoritmos procesan las señales eléctricas o mecánicas de la máquina para obtener características que identifiquen la falla. Se forman bases de datos con las características de la señal, para realizar una clasificación ante la presencia de diferentes niveles de severidad de la falla en la máquina [2].

Se han publicado diversos trabajos en el área de diagnóstico de fallas eléctricas y mecánicas para máquinas síncronas operando como motor o generador [3], [4], [5]. Los sistemas de monitoreo y diagnóstico de fallas en la máquina síncrona emplean variables como voltajes, corrientes, velocidad, par, flujo magnético, temperatura, para ser procesadas o analizadas ante el cambio de alguna anomalía en la máquina [6]. Para la detección de fallas en el devanado del estator de la máquina síncrona operando como generador, se han formulado modelos extendidos [7], los cuales hacen uso de cambio en sus parámetros ante la presencia de la falla, otros modelos requieren conocer las configuraciones del diseño de la máquina, o simplemente las mediciones de sus variables que podrían suministrar información al modelo modificado.

En [8] se presenta un modelo de un generador síncrono de imanes permanentes que incluye fallas de cortocircuito en el devanado de la armadura, la aproximación de la función de devanado se emplea para calcular los parámetros del modelo modificado a través de las inductancias del entrehierro que considera todos los armónicos espaciales, así como las inductancias de dispersión que emplean el método de la permeancia. Una combinación de un modelo modificado con las redes de secuencia de sus variables puede diagnosticar fallas en el estator como se indica en [9], a través de la comparación de las magnitudes de las corrientes de secuencia positiva y negativa que provee el modelo de la máquina con los parámetros modificados, se detectan fallas múltiples en la máquina como son: circuito abierto, cortocircuito entre espiras y desmagnetización en el rotor. Empleando simulación por medio del método de elemento finito con mapas de flujos magnetostáticos y mediciones eléctricas de la corriente transitoria de la máquina síncrona de imanes permanentes operando como motor, se diagnostican fallas de cortocircuito en el estator [10]. La estimación paramétrica también se ha utilizado en el diagnóstico del generador síncrono de imanes permanentes, un ejemplo es el desarrollo de un filtro de Kalman simplificado y un filtro de Kalman extendido para la detección de fallas entre vueltas de una de las fases del generador síncrono de imanes permanentes [11].

Los modelos de la máquina síncrona se han combinado con procesamiento de las señales y métodos de aprendizaje automático como se indica en [12], en este trabajo la señal de corriente se adquiere para ser procesada y transformada en un modelo con un factor que incluye la falla en el estator en el marco de referencia d-q. A partir de esta transformación se realiza la extracción de la amplitud del segundo armónico de corriente por medio de la transformada de Fourier y se compara con un método de extracción armónico basado en la red neuronal Adeline. Sin embargo, el método de diagnóstico basado solo en señales es muy útil cuando no se puede obtener fácilmente un modelo y los datos son abundantes en información [13]. El diagnóstico basado en señales ha tenido un importante desarrollo en investigación en los últimos años, debido a que su implementación en plataformas de tiempo real, no requiere del conocimiento interno de la máquina y sólo utiliza sensores que monitorean las señales externas de la máquina [14]. En [15] un generador síncrono de imanes permanentes se presenta el diagnóstico de cortocircuitos entre espiras y desbalances mecánicos en el rotor. A través de la medición del par y la velocidad, el procesamiento de estas señales con la transformada ondeleta, permite generar

una relación entre el par y la velocidad como indicador de la presencia de la falla. Con la transformada de Fourier de tiempo corto y la transformada ondeleta discreta se realiza el procesamiento de las corrientes en un motor síncrono de imanes permanentes, que permite identificar fallas entre espiras a través de las firmas de corriente en el dominio tiempo-frecuencia [16].

Como parte de los sistemas de monitoreo y diagnóstico de fallas en la máquina síncrona, se han implementado configuraciones con tres etapas básicas como son: la etapa de adquisición de las señales a través de transductores, la etapa de procesamiento de las señales a la cual se le conoce como extractor de características y la etapa de clasificación, la cual usa la información para asignar a los datos de entrada a un número finito de categorías y se pueda diagnosticar la máquina [17]. Al integrar estas etapas e incrementar la complejidad de los algoritmos que procesan y clasifican las señales se puede realizar el diagnóstico de fallas múltiples en la máquina síncrona como se indica en [18], donde se diagnostica a través de las señales de corriente un motor síncrono de imanes permanentes con diferentes fallas. Se utiliza el procesamiento de la señal por medio de una ondeleta empaquetada y el clasificador es una red neuronal de convolución 1-D profunda que incluye la función exponencial normalizada. Se pueden simplificar parte de las tareas de entrenamiento del clasificador a través de Python de acuerdo a lo que se indica en [19], donde se utilizó un análisis biespectral para el procesamiento de la señal de corriente que detecta fallas en el devanado del estator, y en la clasificación se empleó una red neuronal convolucional. Es importante señalar que a pesar de que se han robustecido las tareas de diagnóstico de fallas en la máquina síncrona, ha surgido un reto importante, la implementación de algoritmos capaces de operar simultáneamente con los esquemas de control que algunas aplicaciones requieren hoy en día. Tales condiciones involucran la necesidad de desarrollar algoritmos mucho más simples y precisos en las etapas del extractor de características y el clasificador para que puedan ser implementadas en plataformas digitales en línea [20].

En este trabajo a través de las mediciones y procesamiento de las corrientes de un GSIP integrado a un banco de pruebas, se diagnostican fallas eléctricas en el devanado del estator. El objetivo del banco es desarrollar un sistema de diagnóstico de fallas con un carácter no invasivo que dependa sólo de las mediciones de las corrientes y pueda operar en línea. Como primera etapa en la selección y desarrollo de los algoritmos de diagnóstico, se presentan los resultados de un clasificador binario a través de los algoritmos como son el perceptrón y la regresión logística (siendo uno de los algoritmos más simples que se han utilizado en el aprendizaje automático). De acuerdo con los resultados en la validación de estos algoritmos, se proyectan emplear algoritmos más complejos en base a redes neuronales o algoritmos probabilísticos con tareas de clasificación. La selección del extractor de características debe considerar señales en estado permanente o transitorio, de ahí la necesidad de emplear las ondeletas Haar con una estructura relativamente simple en su cálculo. Una vez seleccionada la combinación extractor de características y su clasificador, en una siguiente etapa se implementarán estos algoritmos en una plataforma digital que permita monitorear y diagnosticar al GSIP en línea con diferentes perfiles de velocidad. Este artículo queda limitado a los resultados obtenidos de los algoritmos de clasificación propuestos, debido a que es una etapa inicial del banco de pruebas del GSIP para el diagnóstico de fallas de cortocircuitos entre las espiras de una fase del estator. En la siguiente sección, se realiza una revisión de los fundamentos básicos del extractor de características y el clasificador binario que se emplean en los algoritmos que se procesan en el banco de pruebas del GSIP. Se presentan los resultados del extractor de características de la transformada ondeleta Haar y los resultados del entrenamiento y validación de la regresión logística a través de Python.

II. DESARROLLO

En la Fig. 1 se indica el diagrama a bloques del aprendizaje supervisado, con los datos de entrada se entrena al algoritmo de aprendizaje para que se genere un modelo predictivo capaz de producir resultados o predicciones una vez que al modelo se le ingresen nuevos datos. El aprendizaje supervisado puede emplearse para regresión (predice un dato continuo) y clasificación (predice la categoría correcta) [21].



Fig 1. Diagrama a bloques del aprendizaje supervisado.

La clasificación es una subcategoría del aprendizaje supervisado, cuyo propósito es predecir la salida o función objetivo en una nueva clase a través de observaciones pasadas del algoritmo de aprendizaje. La función objetivo de la nueva clase son valores binarios y desordenados, cuyo propósito es agruparlos en una nueva categoría considerando determinadas reglas en el ordenamiento [4]. Los algoritmos de clasificación deben ser capaces de separar las condiciones de no falla y falla de los datos que proporcione la transformada ondeleta Haar de las señales de corriente. En las siguientes secciones se describe la teoría básica del clasificador binario, el extractor de características y las métricas que se emplean en la validación de los algoritmos del clasificador.

A. Clasificador binario

El perceptrón es un clasificador binario, que forma parte del aprendizaje supervisado. Es la unidad base de las redes neuronales, se forma por una sola neurona con pesos y un umbral ajustable. Se puede definir una función de decisión $\emptyset(z)$ que toma una combinación lineal de las entradas “x” y sus correspondientes pesos “w”, donde “z” es denominada la función de entrada como se indica en la ecuación (1):

$$z = w_1x_1 + w_2x_2 + w_3x_3 + w_4x_4 + \dots w_nx_n \quad (1)$$

simplificando la función z se tiene la ecuación (2):

$$z = \sum_{j=0}^m w_jx_j \quad (2)$$

Si la entrada es mayor que el umbral θ , se predice una clase o etiqueta 1, y si es menor que el umbral se predice una clase o etiqueta -1.

$$\emptyset(z) = \begin{cases} 1 & \text{si } z \geq \theta \\ -1 & \text{si } z < \theta \end{cases} \quad (3)$$

En el aprendizaje supervisado el umbral negativo o peso es denominado usualmente como unidad de sesgo. Los pesos se actualizan simultáneamente, lo que implica que los valores de la predicción no se recalculan antes de la predicción [22].

5

En la Fig. 2, se muestra un diagrama a bloques de los elementos básicos del perceptrón. Las entradas son multiplicadas por los pesos y sumadas en la función “z”, junto con el sesgo el cual puede ser representando por el valor del peso w_0 . El valor de “z” corresponde a la función de la sumatoria en la Fig. 2. El error permite el ajuste de los pesos.

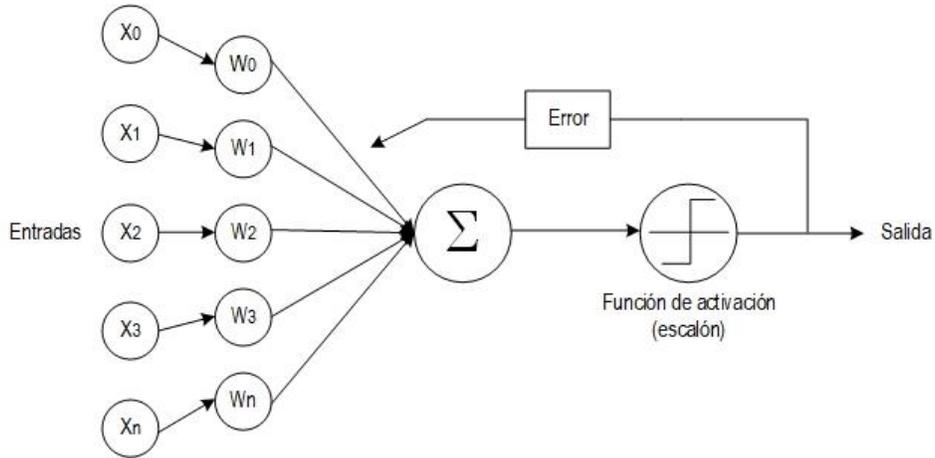


Fig. 2. Diagrama básico de un perceptrón con escalón.

La regresión logística es un modelo de clasificación binaria, cuando el conjunto de datos son linealmente separables. La regresión logística emplea las entradas y pesos del perceptrón, pero experimenta un cambio en su función de activación. Si en la ecuación (2) su función de activación emplea una función sigmoide como se indica en la ecuación (4), el algoritmo es considerado como regresión logística:

$$\varphi(z) = \frac{1}{1 + e^{-z}} \quad (4)$$

En la Fig. 3 se muestra la figura de la curva sigmoide, donde se puede observar que la función de activación tiende a 1 si “z” adquiere un valor infinito. De igual forma “z” adquiere el valor de 0 cuando adquiere un valor infinito negativo, por lo cual actúa como la función de activación del perceptrón.

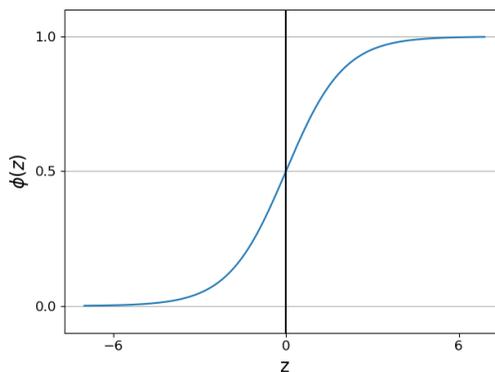


Fig. 3. Curva sigmoide.

La diferencia de la función sigmoide radica en el valor de la pendiente que permite una clasificación binaria más precisa para los datos de entrada que tienen que ser procesados.

En la Fig. 4 se muestra un diagrama a bloques de la regresión logística, el error permite el ajuste de los pesos y el sesgo para su entrenamiento. A través del error cuadrático de la diferencia de su función de activación y su salida, se permite una mejor predicción [22].

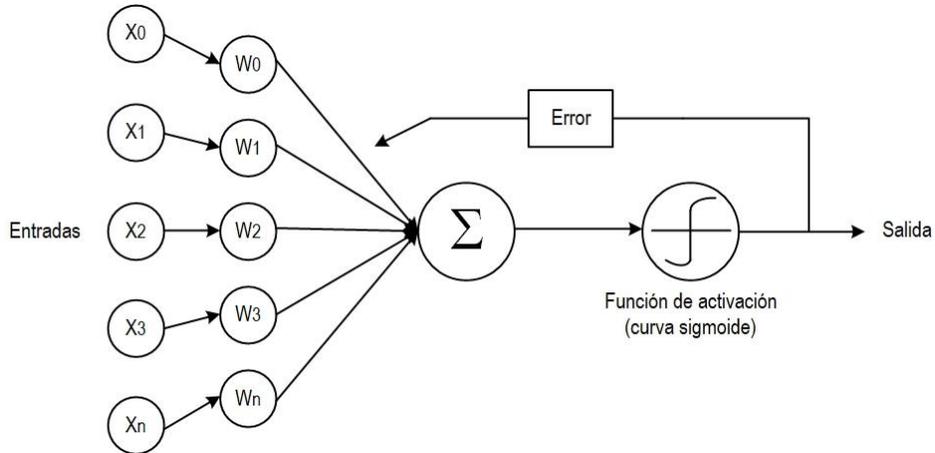


Fig. 4. Diagrama básico de un perceptrón con regresión logística.

B. Extractor de características

La función ondeleta es una onda que puede tener una forma irregular y una duración limitada en tiempo en la cual se concentra la energía de la señal. [23]. La transformada ondeleta puede implementarse en tiempo discreto y se le denomina transformada ondeleta discreta.

Una señal discreta es una función del tiempo con valores ocurriendo en instantes discretos.

$$f = (f_1, f_2, f_3, \dots, f_n) \quad (5)$$

Estos valores son típicamente medidos de una señal analógica "g"

$$f_1 = g(t_1), \dots, f_2 = g(t_2), \dots, f_n = g(t_n) \quad (6)$$

La transformada ondeleta Haar se descompone en dos subseñales discretas de la mitad de su longitud [23].

- Una subseñal representa el promedio o la tendencia
- La otra señal representa la diferencia o fluctuación

La subseñal de la tendencia se calcula con la ecuación (7):

$$a_n = \frac{f_{2n-1} + f_{2n}}{\sqrt{2}} \quad (7)$$

La subseñal de la fluctuación se calcula de acuerdo con la ecuación (8):

$$d_n = \frac{f_{2n-1} - f_{2n}}{\sqrt{2}} \quad (8)$$

La forma general de la tendencia y la fluctuación en el término del n-ésimo se define por las ecuaciones en (9):

$$a^n = \frac{a^{n-1}[2n-1] + a^{n-1}[2n]}{\sqrt{2}} \quad d^n = \frac{d^{n-1}[2n-1] + d^{n-1}[2n]}{\sqrt{2}} \quad (9)$$

para $n= 1, 2, 3, 4 \dots N/2$

7

En general la descomposición del número de niveles de los coeficientes de la ondeleta a las diferentes bandas de frecuencia se define por la ecuación (10) [24]:

$$n = \left\lceil \frac{\log\left(\frac{f_s}{f_{señal}}\right)}{\log(2)} \right\rceil \quad (10)$$

donde

f_s es la frecuencia a la cual se muestrea la señal

$f_{señal}$ es la frecuencia de la señal original

n debe ser un número entero.

En el procesamiento de las señales a través de la ondeleta madre discreta, es común obtener el valor eficaz de los coeficientes de las tendencias y fluctuaciones, para los diferentes niveles en que se descompone la señal. En la ecuación (11) se define el valor eficaz de los coeficientes [23].

$$V_{rmsj} = \sqrt{\frac{1}{N} \sum_{k=1}^n |M_{jk}(n)|^2} \quad (11)$$

donde

j y k son los niveles de la descomposición de las subseñales

N es el número de muestras de la señal

M_{jk} es la magnitud de las componentes de las subseñales

n es el número de los términos del valor eficaz de las subseñales

C. Métricas

Las métricas en el aprendizaje supervisado permiten validar el desempeño de sus algoritmos como son los clasificadores. En este trabajo se emplearon las métricas o índices de desempeño que validan al clasificador ante los escenarios de falla establecidos en el diseño del banco de pruebas del GSIP. A continuación, se describen las métricas utilizadas en la validación de los algoritmos de clasificación empleados en este trabajo.

La matriz cuadrada de confusión es un indicador, el cual permite visualizar los errores individuales y relativos del clasificador. Se puede decir que dicha matriz cómo el sistema confunde escenarios de falla con respecto a N datos conocidos y permite evaluar funciones probabilísticas de cada escenario de falla. En la Fig. 5 se indica la gráfica del arreglo de la matriz de confusión [25]. La matriz incluye verdaderos positivos y falsos positivos, que son aquellos datos que se asocian con los aciertos de la clasificación. Los falsos positivos y falsos negativos, se asocian con los desaciertos de la clasificación.

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

Fig. 5. Matriz de confusión.

La curva característica de operación recibida, ROC (Receiver Operating Characteristic) es un índice gráfico que describe las clasificaciones correctas con respecto a las falsas alarmas. Para problemas de clasificación el umbral de decisiones es binario, es decir si la falla se clasifica correctamente se le asigna 1, de otro modo se asigna un 0. Se grafican entre las relaciones de la sensibilidad y la especificidad. La sensibilidad o probabilidad de clasificación se define como una relación de la ecuación (12).

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

donde VP son los verdaderos positivos y FN son los falsos negativos que emite el clasificador binario.

La especificidad o probabilidad de falsas alarmas se define como una relación de la ecuación (13).

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

donde FP son los falsos positivos y VN son los verdaderos negativos que emite el clasificador binario. En la Fig. 6 se muestra la curva ROC, dado que mientras es mayor el área bajo la curva es mejor el desempeño del clasificador. La curva ROC semejante a la línea recta de 45° denota un clasificador muy ineficiente [25].

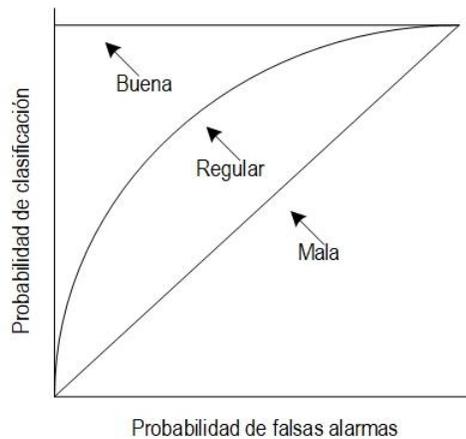


Fig. 6. Funciones de probabilidad y la relación con la curva ROC.

La exactitud se define como una relación entre los aciertos y el total de las predicciones como se indica en la ecuación (14):

$$Exac = \frac{VP + VN}{VP + VN + FP + FN} \quad (14)$$

donde VP son los verdaderos positivos, VN son los verdaderos negativos, FP son los falsos positivos y FN son los falsos negativos que emite el clasificador binario.

9

Cada una de las métricas permite proporcionar información complementaria sobre los resultados que se obtienen del clasificador para valorar su desempeño.

III. RESULTADOS

En esta sección se presenta el análisis de datos de las corrientes del generador de imanes permanentes de 400 W, en condiciones de simetría y con las fallas en diferente número de vueltas. Se emplea en el procesamiento de las señales de las corrientes, la transformada ondeleta Haar y en el clasificador dos algoritmos de aprendizaje supervisado que se analizaron en la sección anterior. Los datos nominales del generador de imanes permanentes se muestran en la Tabla 1.

TABLA 1
VALORES NOMINALES DEL GENERADOR DE IMANES PERMANENTES.

Potencia (W)	Voltaje (V)	Conexión trifásica	Velocidad (rpm)	Polos	Tipo
400	12	Y	400	12	Imanes Permanentes

Dos fases han sido modificadas con derivaciones de 1 a 7 vueltas en dos de las fases del generador. A partir de estas configuraciones se puede realizar una combinación en cada fase o entre fases para generar fallas en el generador que modifiquen las señales de tensión y corriente [26].

En la Fig. 7 se muestra el banco de pruebas del GSIP para obtener las señales de las corrientes y procesarlas a través del extractor de características definido por los valores eficaces de los coeficientes de las tendencias y fluctuaciones de la transformada ondeleta Haar. Estos coeficientes son las entradas de los algoritmos de clasificación correspondientes al perceptrón y la regresión logística. Una vez entrenado el clasificador binario permite diagnosticar al GSIP en su devanado de estator en condiciones sin falla y condiciones con falla.

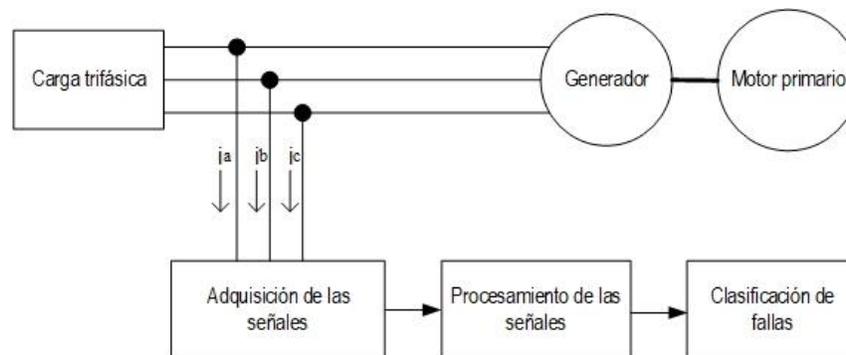


Fig. 7. Diagramas del banco de pruebas para el generador síncrono de imanes permanentes.

En la Fig. 8 se muestra una imagen de la implementación del banco de pruebas del GSIP con sus derivaciones y acoplamiento al motor de corriente directa. En el circuito de prueba para la adquisición de las corrientes con una carga trifásica resistiva en las terminales del generador, se emplean sensores de efecto Hall, posteriormente entran a una etapa de acondicionamiento de señales para ser procesadas en la unidad de procesamiento digital de señales a través de un dsPIC30F4011. El sistema de control regula la velocidad en un motor de corriente directa, como motor primario para que impulse al GSIP. Por medio del sistema de control implementado en el dsPIC30F4011, se genera el patrón de control de velocidad en el motor de corriente directa [26].



Fig. 8. Imagen del banco de pruebas para el generador síncrono de imanes permanentes.

En la Fig. 9 se muestran los voltajes del generador con una falla de 1 vuelta en la fase A. Por la presencia de la falla de cortocircuito, dos voltajes de línea reducen su amplitud respecto al tercer voltaje de línea. El voltaje de línea se genera a una velocidad de 200 rpm.

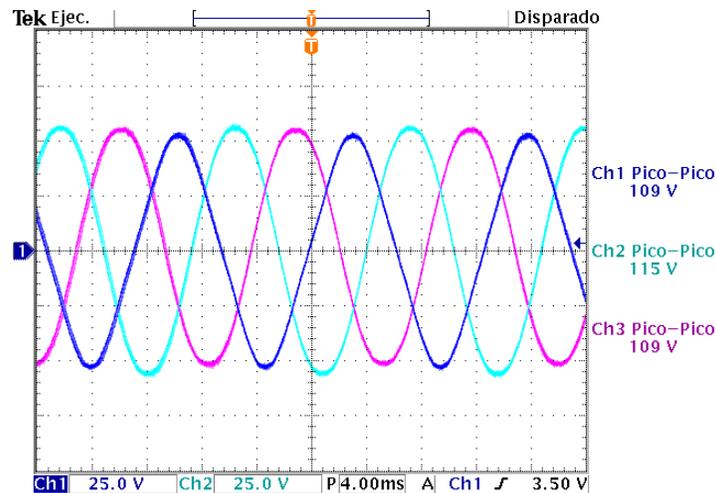


Fig. 9. Voltajes del generador considerando una falla de una vuelta.

En la Fig. 10 se muestran las tres corrientes del generador de imanes permanentes, considerando una falla de una vuelta en la fase A. La reducción de la amplitud de la fase A es mínima por la falla más incipiente del devanado del GSIP. Cuando se incrementan las vueltas en cortocircuito, la amplitud de la señal de corriente se reduce aún más. En las pruebas del GSIP se utilizó una velocidad de la operación del motor primario a 200 rpm, obteniendo señales de corriente a una amplitud y frecuencia de 2 A, 20 Hz y una frecuencia de muestreo de 1kHz.

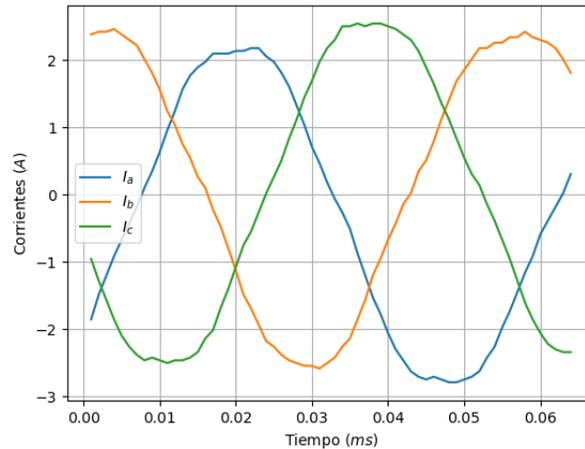


Fig. 10. Corriente del generador considerando una falla de una vuelta.

Se emplearon los cuatro primeros niveles de la transformada ondeleta en la descomposición multinivel, debido a que las adquisiciones de las corrientes en la frecuencia 20 Hz producen las componentes al doble de la frecuencia fundamental de la corriente por la presencia del cortocircuito entre vueltas en el estado permanente. El valor eficaz de los coeficientes se calculó por medio de la ecuación (11) para los cuatro niveles de la transformada ondeleta Haar de acuerdo con la ecuación (10).

En la Tabla 2 se presentan los valores eficaces de los coeficientes considerando las condiciones de simetría y con las diferentes fallas en el estator del GSIP. Los valores eficaces de las tendencias son los coeficientes A_1 , A_2 , A_3 y A_4 . Los valores eficaces de las fluctuaciones son los coeficientes D_1 , D_2 , D_3 y D_4 . Se encuentran ordenados considerando el incremento de la falla en la fase A.

TABLA 2
VALOR EFICAZ DE LOS COEFICIENTES DE LA ONDELETA MADRE HAAR.

Condición	A_1	A_2	A_3	A_4	D_1	D_2	D_3	D_4
Simétrico	4.4315	6.2663	8.8595	12.5240	0.0474	0.1053	0.2060	0.3619
1 vuelta fase A	4.4220	6.2527	8.8402	12.4968	0.0465	0.1043	0.2098	0.3615
4 vueltas fase A	4.4560	6.3008	8.9084	12.5670	0.0486	0.1057	0.2065	0.3505
7 vueltas fase A	4.4496	6.2918	8.8952	12.5740	0.0486	0.1090	0.2178	0.3810

TABLA 3
DATOS DE ENTRADA DE LOS ALGORITMOS DE APRENDIZAJE.

Coefficientes	Simétrico	Salida y	1 vuelta fase A	4 vueltas fase A	7 vueltas fase A	Salida y
A ₁	4.431583	0	4.4222	4.4561	4.4492	1
A ₂	6.2659	0	6.2536	6.3011	6.2899	1
A ₃	8.8905	0	8.8423	8.9868	8.8886	1
A ₄	12.5246	0	12.5068	12.5772	12.5840	1
D ₁	0.0265	0	0.0270	0.0299	0.0311	1
D ₂	0.0779	0	0.0829	0.0874	0.0873	1
D ₃	0.1838	0	0.1829	0.1807	0.1865	1
D ₄	0.3619	0	0.3615	0.3505	0.3810	1

Los datos de entrada de los algoritmos de aprendizaje automático, se formaron con los valores eficaces de los coeficientes, en condiciones de simetría y tres tipos de fallas entre vueltas del estator, además de la función objetivo que clasifica la condición de los datos sin falla o con falla a través de los valores 0 y 1 como se indican en la Tabla 3. Los datos se encuentran ordenados de acuerdo a su banda de frecuencia de la descomposición multinivel de la ondeleta. Estos datos se dividen en 70% de los valores para entrenar al algoritmo de aprendizaje y 30 % de los valores para la validación del modelo una vez que se ha entrenado. Adicionalmente a los datos se les efectúa un tratamiento de la información, es decir, se realizó un escalado y una estandarización. Este proceso permite que no presenten desviaciones muy grandes entre los valores mínimos y máximos dentro del conjunto de datos y no dificulte al algoritmo el proceso de aprendizaje.

Como parte de la validación de los modelos utilizados en las tareas de clasificación se emplearon tres métricas para verificar el desempeño de los algoritmos, como se indicó en la sección anterior. La primera métrica es la matriz de confusión, que separa las posibles combinaciones de los aciertos o desaciertos estimados por el modelo de clasificación binaria. En la Tabla 4 se presentan los resultados con los datos de prueba de la matriz de confusión y en la Tabla 5 se presentan los resultados de la matriz de confusión con los datos de entrenamiento para el algoritmo del perceptrón. Las Tablas 6 y 7 presentan los resultados de la matriz de confusión para el algoritmo de la regresión logística. Los datos de entrenamiento y prueba son complementarios de acuerdo con la partición 70% y 30%, por lo que la información de ambas tablas en cada uno de los tres escenarios de falla, debe contener un total de 60 datos.

TABLA 4
MATRIZ DE CONFUSIÓN DEL PERCEPTRÓN CON LOS DATOS DE PRUEBA.

Condición Simétrico-Falla	Verdaderos Positivos	Verdaderos Negativos	Falsos Positivos	Falsos Negativos
1 vuelta fase A	4	3	8	3
4 vueltas fase A	7	10	1	0
7 vueltas fase A	7	11	0	0

TABLA 5
MATRIZ DE CONFUSIÓN DEL PERCEPTRÓN CON LOS DATOS DE ENTRENAMIENTO.

Condición Simétrico-Falla	Verdaderos Positivos	Verdaderos Negativos	Falsos Positivos	Falsos Negativos
1 vuelta fase A	18	11	8	5
4 vueltas fase A	23	19	0	0
7 vueltas fase A	23	19	0	0

TABLA 6
MATRIZ DE CONFUSIÓN DE LA REGRESIÓN LOGÍSTICA CON LOS DATOS DE PRUEBA.

Condición Simétrico-Falla	Verdaderos Positivos	Verdaderos Negativos	Falsos Positivos	Falsos Negativos
1 vuelta fase A	4	3	8	3
4 vueltas fase A	7	11	0	0
7 vueltas fase A	7	11	0	0

TABLA 7
MATRIZ DE CONFUSIÓN DE LA REGRESIÓN LOGÍSTICA CON LOS DATOS DE ENTRENAMIENTO.

Condición Simétrico-Falla	Verdaderos Positivos	Verdaderos Negativos	Falsos Positivos	Falsos Negativos
1 vuelta fase A	18	13	6	5
4 vueltas fase A	23	19	0	0
7 vueltas fase A	23	19	0	0

13

En las matrices de confusión de la regresión logística y el perceptrón cuando se clasifica la falla de 1 vuelta en cortocircuito, generan una cantidad importante de falsos positivos y negativos. Los modelos no son capaces de generar las predicciones correctas sin falla o con falla en las corrientes del GSIP. Como se puede observar en las tablas de la regresión logística y el perceptrón con una falla de 4 vueltas, el desempeño de ambos clasificadores mejora ya que produce solo verdaderos positivos y negativos.

La segunda métrica utilizada para evaluar el desempeño de los algoritmos son las curvas ROC, las cuales representan la sensibilidad en función de los falsos positivos para los diferentes escenarios de la falla en el GSIP. De la Fig. 11 a la Fig. 13 se muestra la comparativa de las curvas ROC del algoritmo perceptrón y la regresión logística. De acuerdo con la Fig. 11a y la Fig. 11b, la respuesta del clasificador binario en ambos algoritmos es regular, se presentan algunos falsos positivos lo que reducen los verdaderos positivos.

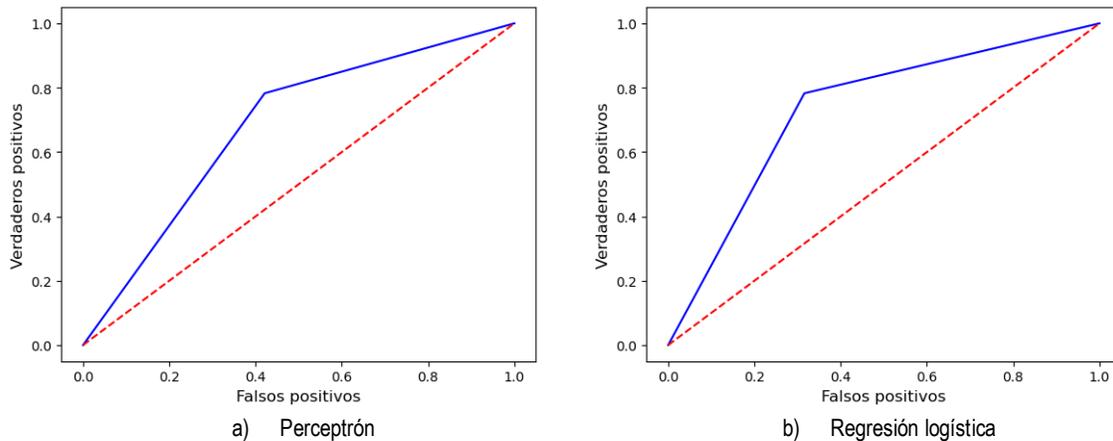


Fig. 11. Curvas ROC considerando una falla de 1 vuelta en la fase A.

Para que en las curvas ROC se muestre un buen desempeño del clasificador, la probabilidad de clasificación debe alcanzar el valor unitario como se indica en la Fig. 6 es decir, en el cálculo de la sensibilidad no existen falsos negativos y en la especificidad no existen falsos positivos. En la Fig. 12a y la Fig. 12b de las curvas ROC para los dos modelos todas se encuentran por arriba de la línea del umbral con una probabilidad de clasificación unitaria, lo que significa que el clasificador tiene un buen desempeño. En la Fig. 13a y la Fig. 13b las curvas

ROC de los dos modelos igualmente tienen una probabilidad de clasificación unitaria, lo que significa que tendrá un buen desempeño en la clasificación de los datos del GSIP. De acuerdo a las curvas ROC, los algoritmos empleados en el clasificador binario presentan una regular sensibilidad ante la presencia de fallas incipientes.

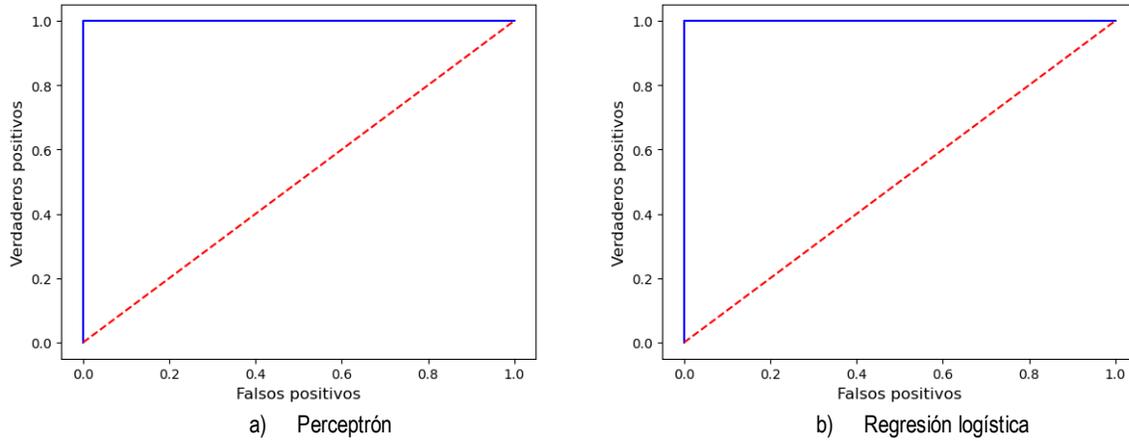


Fig. 12. Curvas ROC considerando una falla de 4 vueltas en la fase A.

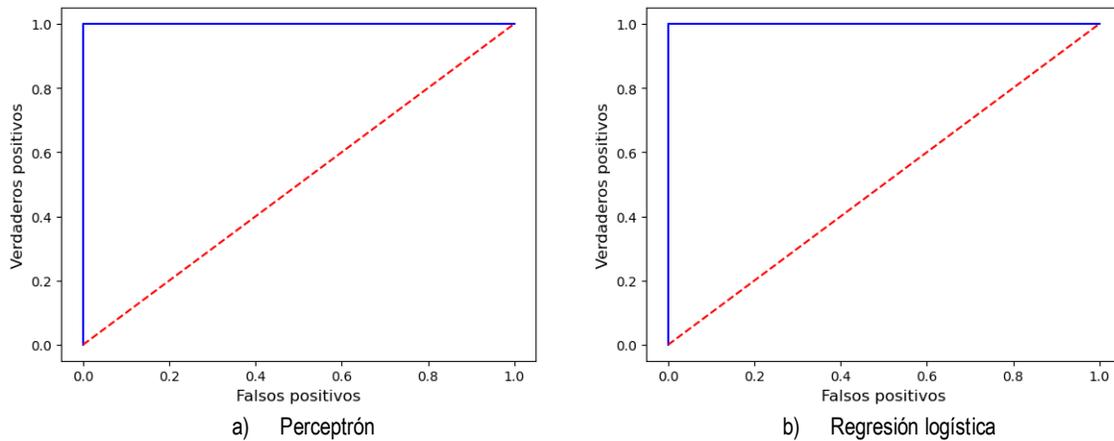


Fig. 13. Curvas ROC considerando una falla de 7 vueltas en la fase A.

La tercera métrica es la exactitud, la cual de acuerdo a la expresión (14) establece la relación de los aciertos respecto al total de las predicciones, el valor unitario representa el mejor desempeño del clasificador. En las Figs. 14, 15 y 16 para ambos algoritmos utilizados, se realiza una validación con diferentes proporciones de los datos de prueba. Se modifican los porcentajes de 20%, 30% y 40% de los datos de prueba, con las tres fallas del GSIP, cuyo propósito fue analizar el impacto que tendría sobre el cálculo de la exactitud. Se puede observar en las figuras que en los tres casos de cambio en la proporción de los datos de prueba, el desempeño de ambos algoritmos es regular ante la falla de 1 vuelta, mientras que para las dos restantes fallas el desempeño de ambos algoritmos es el mejor. Se alcanza a notar una ligera mejora en la exactitud de la regresión logística respecto al perceptrón cuando se considera la falla de 1 vuelta, esto se debe a la función de activación que emplean ambos algoritmos.

El análisis de los resultados de las tres métricas aplicado a los dos algoritmos permite validar el desempeño del clasificador binario utilizado en el GSIP. Para los tres escenarios de falla diagnosticados, el desempeño del clasificador es regular para la falla de una 1 vuelta de acuerdo a los resultados de las métricas. El resultado

anterior es importante considerar al momento de seleccionar el algoritmo del clasificador, ya que no sólo debe contar con una estructura relativamente simple para su implementación, sino que debe ser capaz de lograr el mejor desempeño en todas las combinaciones posibles de fallas a diagnosticar en el GSIP.

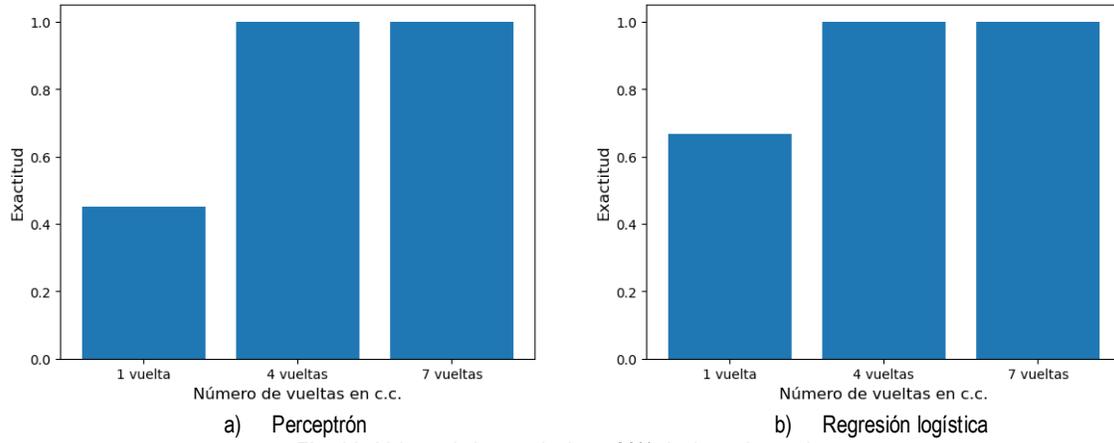


Fig. 14. Valores de la exactitud con 20% de datos de prueba.

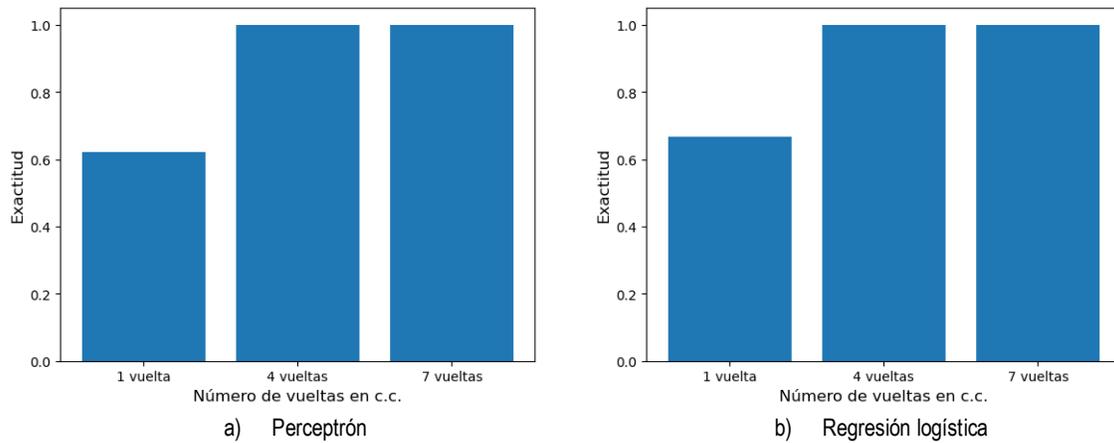


Fig. 15. Valores de la exactitud con 30% de datos de prueba.

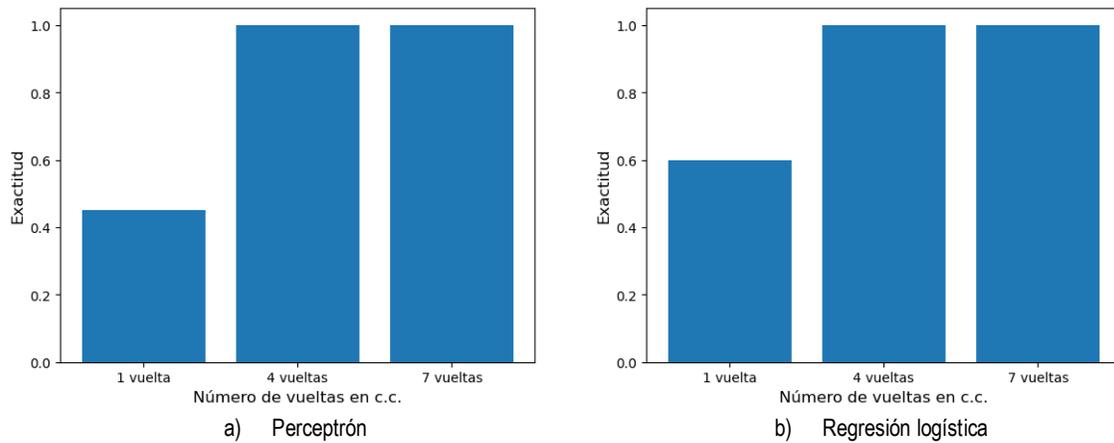


Fig. 16. Valores de la exactitud con 40% de datos de prueba.

Debido a que los algoritmos reciben los datos sin falla y con falla de los coeficientes de la transformada ondulada Haar como se indica en la Tabla 3, no todos los coeficientes de las tendencias y fluctuaciones tienen una variación significativa de su valor eficaz entre ambas condiciones. En general, los coeficientes incrementan su valor eficaz a medida que la asimetría de las fallas es mayor. Una falla de varias vueltas tendrá una diferencia más significativa que una falla de pocas vueltas en sus valores eficaces de los coeficientes. Esta condición tiene impacto en el procesamiento que realiza el clasificador, cuando trata de seleccionar fallas de incipientes.

IV. CONCLUSIONES

En la búsqueda de un diagnóstico confiable y con una estructura relativamente simple, se desarrolla en una primera etapa un banco de pruebas de un GSIP que utiliza algoritmos en base a la transformada ondulada Haar como extractor de características y la regresión logística como clasificador binario, para la detección de fallas de cortocircuito en el estator del GSIP. La implementación de la transformada Haar en las primeras bandas de frecuencia, presenta una variación del valor eficaz de sus coeficientes al considerar la condición sin falla y con la falla del estator. El resultado anterior contribuye significativamente al proceso de clasificación binaria. El clasificador binario emplea un algoritmo con la regresión logística, con estructura relativamente simple para su implementación. Se utilizaron una base fija de datos proveniente del extractor de características, los cuales a través de la función de activación sigmoide de la regresión logística fueron clasificados. Se emplearon tres métricas para validar el desempeño de la regresión logística ante los tres escenarios de falla, comparado con el desempeño de un algoritmo perceptrón el cual emplea una función de activación en escalón. En la validación de los algoritmos de clasificación para la falla de 1 vuelta de cortocircuito, se tuvo un desempeño regular, mientras que para las fallas de 4 vueltas y de 7 vueltas se tuvo un buen desempeño. Tanto la regresión logística como el perceptrón son algoritmos sensibles a la variación y tamaño de los datos que buscan clasificar. El clasificador mantiene la ventaja de generar una implementación relativamente simple, pero tiene la desventaja de no generar una sensibilidad ante la presencia de fallas incipientes. Como etapa subsecuente se buscará modificar el número de datos a procesar en el extractor de características que impacten directamente en el clasificador y probar algoritmos más complejos en la clasificación en base a redes neuronales o en base a sistemas probabilísticos, para mejorar la sensibilidad en la clasificación de fallas incipientes.

CRedit (*Contributor Roles Taxonomy*)

Contribuciones de los autores: Conceptualización: **JAAS, RAS**; Metodología: **JAAS, RAS**; Software **JAAS**; Investigación: **JAAS, RAS**; Redacción y preparación del borrador original: **JAAS**; Redacción, revisión y edición: **JAAS, RAS, FJVP, MAGG**; Supervisión: **FJVP, MAGG, ARC, JRMC**; Análisis formal: **JAAS, RAS**; Administración del proyecto: **FJVP, MAGG**; Adquisición de fondos: **JAAS, RAS, FJVP, MAGG**.

Financiamiento: Los autores agradecen el apoyo recibido de los Cuerpos Académicos **Sistemas Electromecánicos y Energía Sustentable y Automatización y Control de Sistemas**.

Declaración de disponibilidad de datos: Los datos se encuentran en el artículo.

Agradecimientos: Los autores agradecen a Ana Cecilia **Rivera Rivera** por el apoyo recibido con el equipo de medición durante la realización del proyecto.

Conflicto de interés: Los autores declaran que no existe conflicto de interés.

REFERENCIAS

- [1] I. Boldea, "Electric generators and motors: An overview," *CES Trans. Electr. Mach. Syst.*, vol. 1, no. 1, pp. 3-14, 2020, doi: <https://doi.org/10.23919/TEMS.2017.7911104>
- [2] M. Rezamand, M. Kordestani, R. Carriveau, D. S. K. Ting, M.E. Orchard, M. Saif, "Critical Wind Turbine Components Prognostics: A Comprehensive Review," *IEEE Trans. Instrum. Meas.*, vol. 69, no. 12, pp. 9306-9328, 2020, doi: <https://doi.org/10.1109/TIM.2020.3030165>
- [3] S. Choi, *et al.*, "Fault diagnosis techniques for permanent magnet AC machine and drives-A review of current state of the art," *IEEE Trans. Transp. Electrification*, vol. 4, no. 2, pp. 444-463, 2018, doi: <https://doi.org/10.1109/TTE.2018.2819627>
- [4] G. Helbing, M. Ritter, "Deep Learning for fault detection in wind turbines," *Renew. Sustain. Energy Rev.*, vol. 98, pp. 189-198, 2018, doi: <https://doi.org/10.1016/j.rser.2018.09.012>
- [5] H. Henao, *et al.*, "Trends in fault diagnosis for electrical machines: A review of diagnostic techniques," *IEEE Ind. Electron. Mag.*, vol. 8, no. 2, pp. 31-42, 2014, doi: <https://doi.org/10.1109/MIE.2013.2287651>
- [6] D. Basak, A. Tiwari, S. P. Das, "Fault diagnosis and condition monitoring of electrical machines - A review," *Proc. IEEE Int. Conf. Ind. Technol.*, Mumbai, India, pp. 3061-3066, 2006, doi: <https://doi.org/10.1109/ICIT.2006.372719>
- [7] Z. T. Mei, G. J. Li, Z. Q. Zhu, R. Clark, A. Thomas, Z. Azar, "Scaling Effect on Inter-Turn Short-Circuit of PM Machines for Wind Power Application," *2021 IEEE Int. Electr. Mach. Drives Conf. IEMDC 2021*, Hartford, CT, USA, 2021, doi: <https://doi.org/10.1109/IEMDC47953.2021.9449606>
- [8] Z. Mei, G. J. Li, Z. Q. Zhu, R. Clark, A. Thomas, Z. Azar, "Scaling Effect On Inter-Turn Short-Circuit Fault of PM Machines for Wind Power Application," *IEEE Trans. Ind. Appl.*, vol. 59, no. 1, pp. 789-800, 2023, doi: <https://doi.org/10.1109/TIA.2022.3211249>
- [9] Z. Nie, N. Schofield, "Condition monitoring of a permanent magnet synchronous generator for a wind turbine application," *IET Conf. Publ.*, vol. 2016, no. CP684, pp. 1-6, 2016, doi: <https://doi.org/10.1049/cp.2016.0233>
- [10] S. Ferrari, G. Dilevrano, P. Ragazzo, P. Pescetto, G. Pellegrino, "Fast Determination of Transient Short-Circuit Current of PM Synchronous Machines Via Magnetostatic Flux Maps," *IEEE Trans. Ind. Appl.*, vol. 59, no. 1, pp. 4000-4009, 2023, doi: <https://doi.org/10.1109/TIA.2023.3265952>
- [11] A. G. Olabi, *et al.*, "A review on failure modes of wind turbine components," *Energies*, vol. 14, no. 17, 2021, doi: <https://doi.org/10.3390/en14175241>
- [12] D. Wei, K. Liu, W. Hu, X. Peng, Y. Chen, R. Ding, "Short-Time Adaline Based Fault Feature Extraction for Inter-Turn Short Circuit Diagnosis of PMSM via Residual Insulation Monitoring," *IEEE Trans. Ind. Electron.*, vol. 70, no. 3, pp. 3103-3114, 2023, doi: <https://doi.org/10.1109/TIE.2022.3167164>
- [13] C. Verde, S. Gentil, R. Morales-Menéndez, *Monitoreo y Diagnóstico Automático de Fallas en Sistemas Dinámicos*, México: Trillas, 2011.
- [14] S. H. Kia, H. Henao, G. A. Capolino, "Efficient digital signal processing techniques for induction machines fault diagnosis," in *2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*, Paris, France, 2013, pp. 232-246. doi: <https://doi.org/10.1109/WEMDCD.2013.6525183>
- [15] W. Yang, P. J. Tavner, M. Wilkinson, "Condition monitoring and fault diagnosis of a wind turbine with a synchronous generator using wavelet transforms," *IET Conf. Publ.*, no. 538 CP, pp. 6-10, York, UK, 2008, doi: <https://doi.org/10.1049/cp:20080473>
- [16] S. Halder, S. Bhat, C. Bhaumik, R. Rakshit, "Stator Inter-Turn Fault Diagnosis in Permanent Magnet Synchronous Motor," *Proc. 2020 IEEE 1st Int. Conf. Smart Technol. Power, Energy Control. STPEC*, Nagpur, India, 2020, pp. 3-8, 2020, doi: <https://doi.org/10.1109/STPEC49749.2020.9297677>
- [17] M. H. Toliyat, *et al.*, "Application of Pattern Recognition to Fault Diagnosis," in *Electric Machines Modeling, Condition Monitoring and Fault Diagnosis*, USA: Taylor and Francis Group, 2015.
- [18] I. H. Kao, W. J. Wang, Y. H. Lai, J. W. Perng, "Analysis of Permanent Magnet Synchronous Motor Fault Diagnosis Based on Learning," *IEEE Trans. Instrum. Meas.*, vol. 68, no. 2, pp. 310-324, 2019, doi: <https://doi.org/10.1109/TIM.2018.2847800>
- [19] P. Pietrzak, M. Wolkiewicz, T. Orlowska-Kowalska, "PMSM Stator Winding Fault Detection and Classification Based on Bispectrum Analysis and Convolutional Neural Network," *IEEE Trans. Ind. Electron.*, vol. 70, no. 5, pp. 5192-5202, 2022, doi: <https://doi.org/10.1109/TIE.2022.3189076>
- [20] W. Lee, G. Choi, "A Comprehensive Review of Fault-Tolerant AC Machine Drive Topologies: Inverter, Control, and Electric Machine," *2021 IEEE 13th Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives, SDEMPED*, Dallas, TX, USA, 2021, pp. 269-275, 2021, doi: <https://doi.org/10.1109/SDEMPED51010.2021.9605560>

- [21] A. Sengupta, "A First Course in Machine Learning by Simon Rogers and Mark Girolami," *International Statistical Review*, vol. 82, no. 1. 2014. doi: https://doi.org/10.1111/insr.12051_21
- [22] V. M. Raschka, *Python Machine Learning*, 3rd ed., Birmingham UK: Packt Birmingham-Mumbai, 2019.
- [23] J. S. Walker, *A primer on wavelets and their scientific applications*, 2nd ed., UK: Taylor & Francis, 2008.
- [24] H. Cherif, A. Menacer, B. Bessam, R. Kechida, "Stator inter turns fault detection using discrete wavelet transform," *Proc. IEEE 10th Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives*, pp. 138-142, Guarda, Portugal, 2015, doi: <https://doi.org/10.1109/DEMPED.2015.7303681>
- [25] C. Verde, S. Gentil, R. Morales-Menéndez, *Monitoreo y Diagnóstico Automático de Fallas en Sistemas Dinámicos*, México: Trillas, 2013.
- [26] R. A. Ortiz Medina, "Diagnóstico de Fallas Eléctricas en Estator de Máquinas Eléctricas de Aerogeneradores," Tesis, Doctortado, Ciencias de la Ingeniería, Instituto Tecnológico de Aguascalientes, 2021.