

STATOR FAULT DETECTION FOR A BLDC MOTOR USING AN ARTIFICIAL NEURAL NETWORK

Rodolfo Jáuregui Acevedo

<https://orcid.org/0000-0003-4351-6341>

Francisco Javier Villalobos Piña

<https://orcid.org/0000-0003-1053-5642>

Ricardo Alvarez Salas

<https://orcid.org/0000-0002-7646-0260>

Josue Augusto Reyes Malanche

<https://orcid.org/0000-0003-3530-1105>

Carlos Humberto Saucedo Zárate

J.A. Alvarez Salas

A. Rodriguez Cobos

All content in this magazine is licensed under a Creative Commons Attribution License. Attribution-Non-Commercial-Non-Derivatives 4.0 International (CC BY-NC-ND 4.0).



Abstract: This work addresses the problem of stator short-circuit fault detection for an in-wheel Brushless Direct Current (BLDC) motor using a perceptron artificial neural network. The proposed FD scheme was compared with the motor current signature analysis based on discrete Fourier transform and discrete wavelet transform. The algorithms were validated on a test rig with an in-wheel BLDC motor for light electric vehicles.

Keywords: Fault detection, BLDC Motor, artificial neural network, perceptron.

INTRODUCCIÓN

Los motores eléctricos de corriente directa sin escobillas (BLDC, por sus siglas inglés) tienen una amplia gama de aplicaciones como son sistemas de posicionamiento, aeronaves ligeras no tripuladas (Heo & Lee, 2018) vehículos autónomos (Shi & Zhang, 2020), (Kalyankar-Narwade, Chidambaram, & Patil, 2021), aplicaciones biomédicas y de tipo militar (Singhl, Singh, Verma, Singh, & Tiwari, 2018), sistemas de generación de energía (Li, Wang, Zhang, Xin, & Liu, 2019), (Yang, Huang, Lu, & Zhong, 2018)). En particular, este tipo de motor ha cobrado un gran auge en el área de vehículos eléctricos debido a su nulo mantenimiento y eficiencia energética, así como la facilidad de su control gracias a la evolución en la electrónica de potencia y los sistemas de control digital.

Una variante de los motores BLDC son los de tipo in-wheel utilizados en vehículos eléctricos, estos se han popularizado gracias a que ha disminuido el costo de manufactura y a la mejora de la eficiencia de los sistemas de almacenamiento de energía. Sin embargo, debido al estrés al que son sometidos los motores in-wheel BLDC en los ciclos de funcionamiento típicos pueden presentar varios tipos de falla como son las fallas en los devanados del estator, cuando dichas fallas no son detectadas y atendidas oportunamente se

presenta una degradación de la máquina y del sistema electrónico de potencia. El contar con una herramienta que permita una detección temprana y oportuna de dichas fallas, evita pérdidas económicas importantes y periodos fuera de operación de estos equipos.

Existen muchas técnicas para el diagnóstico de fallas en máquinas eléctricas, las más comúnmente utilizadas son las basadas en procesamiento de señales. No obstante, actualmente ha tomado gran popularidad los métodos empleando inteligencia artificial. Estas técnicas permiten extraer características de las señales de firma de falla para su clasificación (Vodovozov, Aksjonov, Petlenkov, & Raud, 2021). Dentro del campo de la inteligencia artificial, las redes neuronales artificiales (RNA) han sido ampliamente utilizadas para realizar detección de fallas con resultados notables respecto a otras técnicas (Heo & Lee, 2018). En el enfoque de la inteligencia artificial, la disponibilidad de datos para extraer las características esenciales del fenómeno eléctrico en estudio es fundamental, esto con el fin de emitir un dictamen sobre las condiciones de salud de una máquina eléctrica (Li, Wang, Zhang, Xin, & Liu, 2019), (Tang, y otros, 2018)). Las RNA, de acuerdo a sus características, pueden desempeñarse como clasificadores o métodos de regresión (Hastie, Tibshirani, & Friedman, 2008).

Dentro de las RNA existen diferentes clases, las eurísticas y las determinísticas, supervisadas o no supervisadas (Hastie, Tibshirani, & Friedman, 2008). Las RNA se han implementado en diversos tipos de vehículos como son los trenes para el diagnóstico de fallas en las ruedas (Krummenacher, Ong, Koller, Kobayashi, & Buhmann) o en vehículos eléctricos ligeros para analizar las fallas en los rodamientos (Kudelina, y otros, 2020). Un tipo de RNA comúnmente utilizada es el perceptrón

multicapa (MLP, por sus siglas en inglés) ((Fadzail & Zali, 2019), (Sadrossadat & Rahmani, 2020), (Xu, Qiao, Zhang, Feng, & Wang, 2020), (Kalyankar-Narwade, Chidambaram, & Patil, 2021)).

El presente trabajo aborda el problema de la detección de fallas de corto-circuito en el estator de un motor BLDC tipo in-wheel para vehículos eléctricos ligeros mediante métodos de aprendizaje automático, para lo cual se utiliza la magnitud de las corrientes de línea y fase de estator para entrenar una red tipo perceptrón con el fin de efectuar la detección y clasificación de fallas. Para corroborar los resultados de la RNA se efectúa también un análisis de los espectros de frecuencia de las corrientes de estator del caso sin falla (sano) y con falla mediante la transformada discreta de Fourier (TDF), así como con la transformada discreta wavelet (TDW).

MÉTODOS Y MATERIALES

EL PERCEPTRÓN MULTICAPA

La RNA perceptrón multicapa (MLP, por sus siglas en inglés) se caracteriza por tener más de una neurona y más de una capa oculta como se ilustra en la figura 1, para entrenar la red se consideran los siguientes pasos:

1. Se alimenta la red hacia adelante.
2. Se propaga el error a la capa de los nodos de salida.
3. Se propaga el error a la capa de los nodos ocultos.
4. Se realiza la actualización de los pesos.

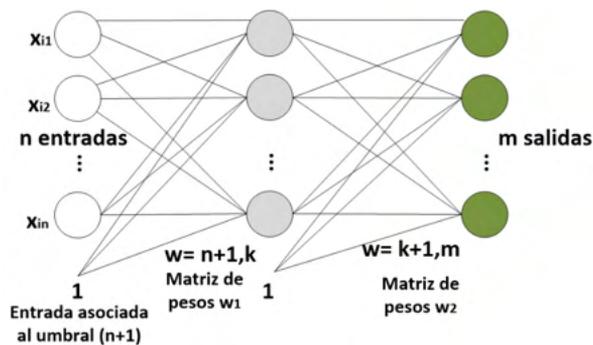


Figura 1. Estructura de la RNA MLP.

El método del gradiente descendiente se emplea para la búsqueda de los valores de los pesos (w_1, \dots, w_n) los cuales son los valores a modificar minimizando el error cuadrático E_i .

El gradiente se obtiene respecto a los pesos $\nabla E = (\frac{\partial E}{\partial w_1}, \dots, \frac{\partial E}{\partial w_n})$, modificando los pesos $\Delta w_i = -\mu (\frac{\partial E}{\partial w_i})$, para $i=1, \dots, n$; donde μ es la constante de aprendizaje que define el tamaño de corrección de un paso en cada iteración. Se realiza un ajuste de pesos hasta obtener $\nabla E = 0$, como se ilustra en la figura 2.

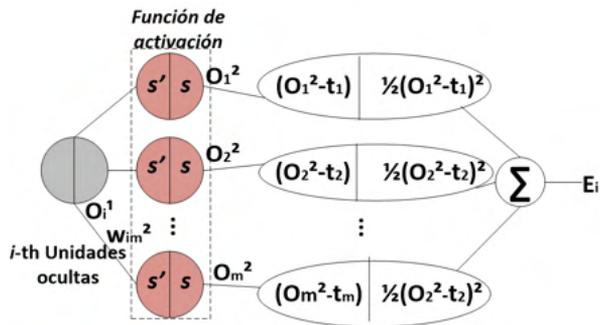


Figura 2. Estructura del entrenamiento de la RNA MLP.

Para la correcta operación de la RNA MLP es necesario considerar el valor del bias o umbral t para cada capa oculta, y que la condicionante active a la red, como se muestra en (1).

$$f = 1, \text{ si } \sum_{i=1}^n x_i w_i > t \quad (1)$$

ANÁLISIS DE LAS CORRIENTES DE LÍNEA Y DE FASE

El esquema de diagnóstico de fallas eléctricas del estator en el motor BLDC se basa en proponer tres marcos de referencia para la búsqueda de problemas en las fase A, B y C, la simplicidad de la técnica consiste en cuantificar el nivel de desbalance provocado por la falla de corto-circuito entre espiras obteniendo para ello las corrientes de línea i línea A,B,C y fase i fase A,B,C.

Para la búsqueda de falla de corto-circuito en la fase A del estator, se obtiene una magnitud resultante de la diferencia de la corriente de la fase A ($i_{fase A}$) denominada α_A y de la corriente de línea de las fases B ($i_{fase B}$) y C ($i_{fase C}$) llamada β_A .

$$\alpha_A = i_{fase A}$$

$$\beta_A = i_{fase B} - i_{fase C}$$

en donde la magnitud Mag_A de las corrientes de línea y fase para la búsqueda de falla en fase A resulta

$$Mag_A = \alpha_A + \beta_A$$

Para determinar si existe falla de corto-circuito en la fase B del estator, se obtiene una magnitud resultante de la diferencia de la corriente de la fase B ($i_{fase B}$) denominada α_B y de la corriente de línea de las fases C ($i_{fase C}$) y A ($i_{fase A}$) llamada β_B .

$$\alpha_B = i_{fase B}$$

$$\beta_B = i_{fase C} - i_{fase A}$$

en donde la magnitud Mag_B de las corrientes de línea y fase para la búsqueda de falla en fase B resulta

$$Mag_B = \alpha_B + \beta_B$$

Para la búsqueda de falla de corto-circuito en la fase C del estator, se obtiene una magnitud resultante de la diferencia de la corriente de la fase C ($i_{fase C}$) denominada α_C y de la corriente de línea de las fases A ($i_{fase A}$) y B ($i_{fase B}$) denominada β_C .

$$\alpha_C = i_{fase C}$$

$$\beta_C = i_{fase A} - i_{fase B}$$

en donde la magnitud Mag_C de las corrientes de línea y fase para la búsqueda de falla en fase C resulta

$$Mag_C = \alpha_C + \beta_C$$

TRANSFORMADA DISCRETA DE FOURIER

La transformada discreta de Fourier (TDF) de una señal $x[k]$ está dada por (2).

$$X[n] = \sum_{k=0}^{N-1} x[k] e^{-j\left(\frac{2\pi kn}{N}\right)} \quad (2)$$

con $n=0 \dots N-1$.

La TDF se utiliza para obtener información en el dominio de la frecuencia de la magnitud de las corrientes del estator (Mag_A , Mag_B , Mag_C). Para el caso sano del motor BLDC, el espectro de frecuencias del módulo de las corrientes muestra una componente de frecuencia de la corriente F_{fun} determinada por la velocidad de operación de la máquina. Para el escenario de falla eléctrica del estator aparece una componente de frecuencia F_{falla} del doble de la frecuencia F_{fun} .

TRANSFORMADA DISCRETA WAVELET

Una señal discreta es una función del tiempo con valores que ocurren en instantes discretos (Walker, 2008) y se expresa como: $f = (f_1, f_2, \dots, f_N)$. Con N siendo un entero par positivo. Los valores que constituyen la función son valores medidos típicamente de una señal análoga $g(t)$, adquiridos en instantes de tiempo $t=t_1, t_2, \dots, t_n$. La transformada discreta wavelet (TDW) permite descomponer una señal en dos subseñales, cada una corresponde a la mitad de la longitud de f . La primera

parte de la descomposición representa la aproximación y la segunda parte se conoce como fluctuación de la señal, representadas por a_m y d_m , respectivamente.

Para determinar la TDW de una señal, se pueden utilizar diferentes señales de escalamiento y wavelets, en particular, en este trabajo se usó la wavelet Haar.

La primera aproximación se determina de acuerdo: $a^1 = (a_1, a_2, \dots, a_{N/2})$, con los coeficientes de aproximación se calculados como

$$a_m = \frac{f_{2m-1} + f_{2m}}{\sqrt{2}}$$

para $m=1, 2, 3, \dots, N/2$.

La primera fluctuación está dada por $d^1 = (d_1, d_2, \dots, d_{N/2})$, con los coeficientes de fluctuación como

$$d_m = \frac{f_{2m-1} - f_{2m}}{\sqrt{2}}$$

para $m=1, 2, 3, \dots, N/2$.

De manera que la señal f se puede descomponer de la siguiente forma:

$$f \xrightarrow{H_1} (a^1 | d^1)$$

en donde el superíndice representa el nivel de descomposición de la señal.

La descomposición de la señal f se puede proseguir de acuerdo a la figura 3 para obtener el llamado análisis multi-resolución (MRA, por sus siglas en inglés), como puede observarse la cantidad de niveles de descomposición dependerá del tamaño de la señal analizada.

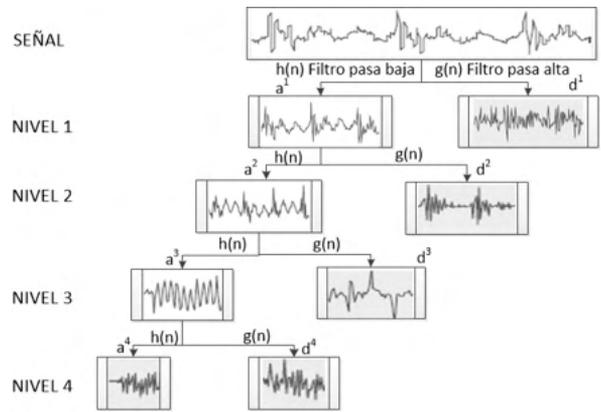


Figura 3. MRA de una señal.

CASOS DE ESTUDIO

El presente estudio se realizó en un banco de pruebas diseñado para evaluar algoritmos de diagnóstico de fallas para máquinas BLDC de tipo in-wheel (figura 4).

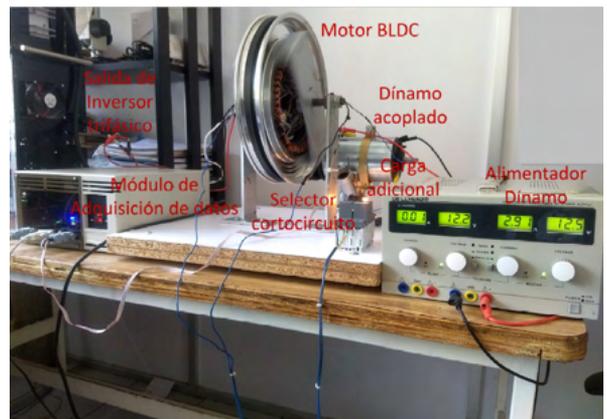


Figura 4. Banco de pruebas.

El sistema consta de un motor BLDC modificado en sus devanados del estator para generar fallas de diferente grado de severidad como se ilustra el diagrama esquemático de la figura 5.

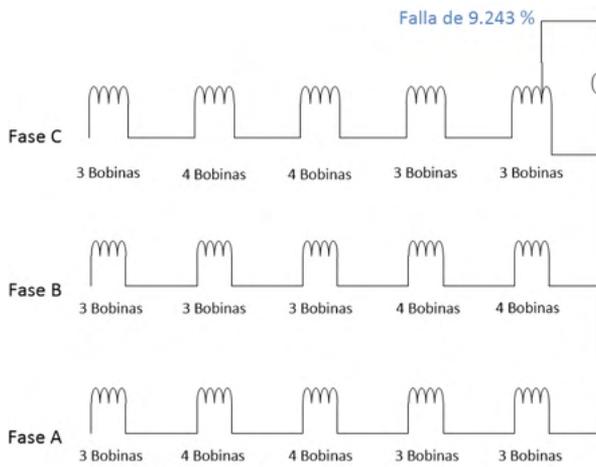


Figura 5. Corto-circuito inducido en el motor BLDC.

Las especificaciones del motor se muestran en la tabla 1. En este trabajo se consideraron dos escenarios: uno para el caso sano y otro correspondiente a una falla del estator de corto-circuito entre espiras de una misma fase. En las pruebas se aplicó un par de carga constante por medio de un dínamo automotriz acoplado mediante una polea al motor.

Potencia de motor	500 W
Voltaje de operación	18 V
Par de polos de motor	24
Resistencia por fase	0.25 Ω

Tabla 1. Especificaciones del motor BLDC.

RESULTADOS

En este trabajo se indujo una falla en el estator correspondiente a un corto-circuito del 9.243 % de espiras del devanado de una fase, se realizaron 30 ensayos con fines de análisis tanto para el caso con falla y sin ésta.

Las corrientes del estator se mapearon a un marco de referencia asociado a la búsqueda de la falla en la fase C y, posteriormente, se obtuvo la magnitud Mag_C correspondiente; la cual se analizó con tres procedimientos para detectar la

falla: el análisis frecuencial con la TDF, el MRA con la TDW y, finalmente, se entrenó una RNA perceptrón. Ésta última se consideró para el estudio debido a que es la más sencilla de las redes neuronales, se analizó su desempeño para clasificar y el ahorro en términos de costo computacional con respecto a otras estructuras más complejas. Para las pruebas se tomaron 2048 muestras de las señales de corriente a una frecuencia de muestreo de 2 kHz mediante el uso de un sistema de control y adquisición de datos diseñado para este fin basado en un procesador de señales digitales Microchip dsPic30F4011. Además, se utilizó un programa de computadora que también fue diseñado como parte del sistema de control y adquisición de señales basado en el lenguaje de programación Embarcadero Delphi XE7.

RESULTADOS EMPLEANDO LA TDF

En el primer esquema de detección se evaluó el espectro de frecuencia de la magnitud de la corriente (Mag_C) resultante de las corrientes de fase del estator del motor BLDC para los casos sin falla (sano) y con falla. En (Reyes-Malanche, Villalobos-Pina, Cabal-Yopez, Alvarez-Salas, & Rodriguez-Donate, 2021), se demuestra que la componente de frecuencia debida a un corto-circuito en los devanados del estator en máquinas eléctricas rotatorias se presenta al doble de la frecuencia de la tensión de alimentación F_{fun} , esto es, $F_{falla} = 2F_{fun}$.

En la figura 6 se presenta el espectro de frecuencia para el caso sano y en la figura 7 se presenta el caso con falla, la frecuencia de la corriente del estator fundamental $F_{fun} = 46.6667$ Hz, se observa una componente de frecuencia de $F_{falla} = 93.33$ Hz cuya magnitud es 1700% mayor respecto al caso sano.

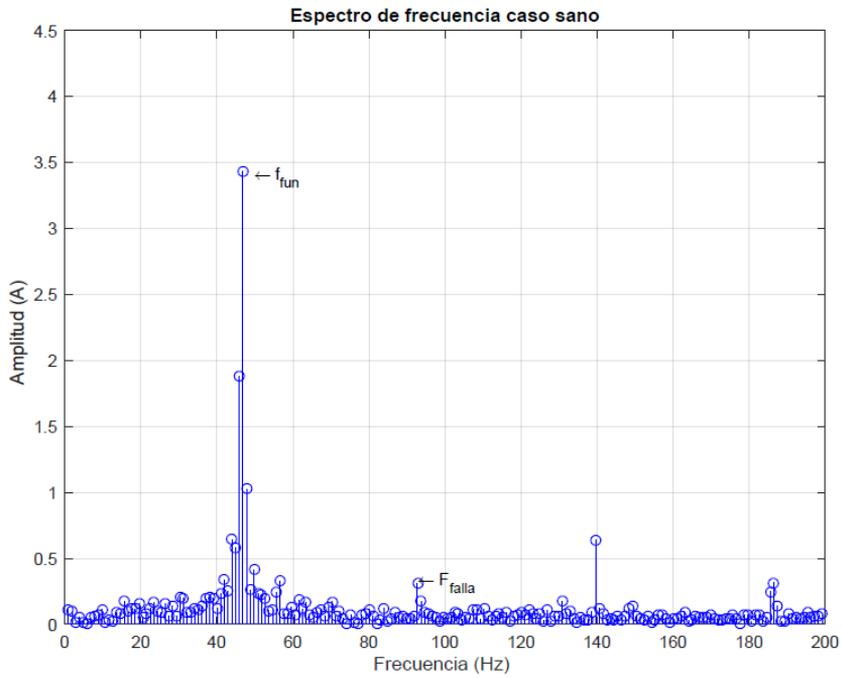


Figura 6. Espectro del módulo del vector de corriente del estator del motor BLDC, caso sano.

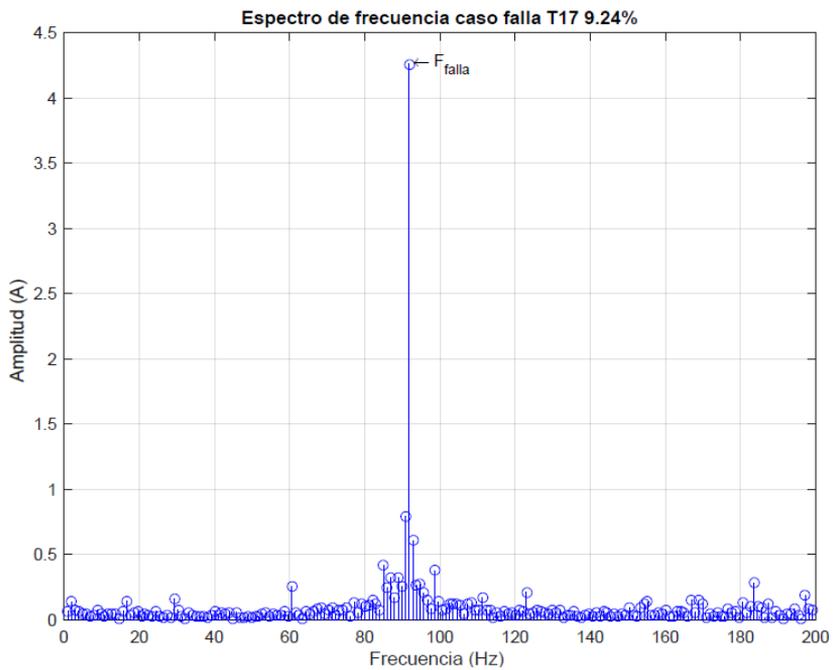


Figura 7. Espectro del módulo del vector de corriente del estator del motor BLDC, caso con falla.

Nivel	Banda de frecuencia	Caso sano	Caso con falla	Diferencia
1	500.0-1000.0	1.429036	1.8587	0.42934
2	250.0-500.0	2.23904	2.470511	0.231471
3	125.0-250.0	3.444411	4.824922	1.380511
4	62.5-125.0	6.580328	9.434952	2.854624
5	31.3-62.5	12.362764	5.129815	7.232949
6	15.6-31.3	6.899036	5.121398	1.777638
7	7.8-15.6	5.298408	1.08378	4.214628
8	3.9-7.8	1.606846	1.582669	0.024177
9	2.0-3.9	0.1.271589	1.792549	0.52096
10	1.0-2.0	0.870154	3.863493	2.993339
11	0.5-1.0	0.029717	1.582221	0.001044 1

Tabla 2. Valor RMS de los coeficientes wavelet generados por la TDW con la wavelet Haar.

RESULTADOS EMPLEANDO LA TDW

Utilizando el MRA, se cuantificó el valor RMS de los coeficientes wavelet de las diferentes bandas de frecuencias. Para el caso de estudio se obtuvieron 11 bandas de frecuencia, la banda de interés se centró en el nivel 4 para el rango de frecuencias 62.5-125 Hz; en el cual se aprecia un notable incremento en el nivel RMS de los coeficientes para el caso sano y con falla como se ilustra en la tabla 2. Por lo tanto, se comprueba que existe una falla de estator en el devanado.

RESULTADOS EMPLEANDO LA RNA PERCEPTRÓN

Se diseñó una RNA perceptrón la cual consta de cinco neuronas en la capa de entrada con una función de activación tangente sigmoideal con bias y una única neurona en la capa de salida con una función de activación lineal que también cuenta con bias (figura 8). Se implementó el algoritmo de entrenamiento basado en el gradiente descendiente y se llevó a cabo la clasificación utilizando los pesos resultantes del entrenamiento. Se aplicaron 30 capturas de señales de corriente para el caso sano y 30 para el caso con falla, los resultados se

presentan en la tabla 3. La RNA muestra una buena capacidad para la detección de fallas de corto-circuito del estator en el motor al demostrar una buena clasificación de los 60 casos.

La mayor efectividad se logró con un mínimo de cinco neuronas, una menor cantidad de neuronas no efectuó la clasificación correcta en todos los casos. Un aumento en la cantidad de neuronas no mejora la clasificación, pero si incrementa el costo computacional.

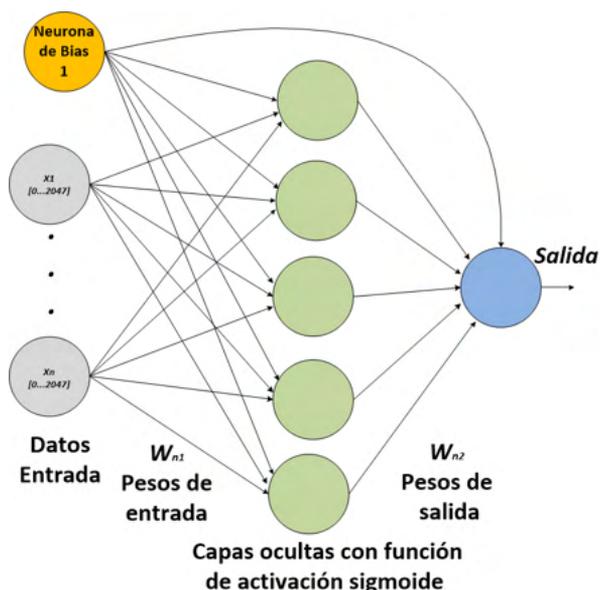


Figura 8. RNA MLP entrenada.

No. Muestra	Caso sano	Caso con falla
1	1.00E-01	1.00E+00
2	1.00E-01	1.00E+00
3	1.00E-01	1.00E+00
4	1.00E-01	1.00E+00
5	1.00E-01	1.00E+00
6	1.00E-01	1.00E+00
7	1.00E-01	1.00E+00
8	1.00E-01	1.00E+00
9	1.00E-01	1.00E+00
10	1.00E-01	1.00E+00
11	1.00E-01	1.00E+00
12	1.00E-01	1.00E+00
13	1.00E-01	1.00E+00
14	1.00E-01	1.00E+00
15	1.00E-01	1.00E+00
16	1.00E-01	1.00E+00
17	1.00E-01	1.00E+00
18	1.00E-01	1.00E+00
19	1.00E-01	1.00E+00
20	1.00E-01	1.00E+00
21	1.00E-01	1.00E+00
22	1.00E-01	1.00E+00
23	1.00E-01	1.00E+00
24	1.00E-01	1.00E+00
25	1.00E-01	1.00E+00
26	1.00E-01	1.00E+00
27	1.00E-01	1.00E+00
28	1.00E-01	1.00E+00
29	1.00E-01	1.00E+00
30	1.00E-01	1.00E+00

Tabla 3. Clasificación de señales con la RNA.

CONCLUSIONES

El uso de la RNA para detectar fallas eléctricas en el estator del motor BLDC aporta información de carácter redundante para emitir un juicio más certero sobre las condiciones de salud de la máquina en conjunto con el análisis frecuencial de las corrientes de estator basado en la TDF y el MRA empleando la TDW. Para fines del presente trabajo, se presentó una falla drástica sin embargo el esquema es útil para fallas incipientes.

REFERENCIAS

- Fadzail, N., & Zali, S. (2019). Fault detection and classification in wind turbine by using artificial neural network. *International Journal of Power Electronics and Drive System*, 10(3), 1687--1693.
- Hastie, T., Tibshirani, R., & Friedman, J. (2008). *The Elements of statistical learning* (Second Edition ed.). Springer.
- Heo, S., & Lee, J. (2018). Fault detection and classification using artificial neural networks. *IFAC-PapersOnLine*, 50(18), 470--475.
- Kalyankar-Narwade, S., Chidambaram, R., & Patil, S. (2021). Neural network- and fuzzy control-based energy optimization for the switching in parallel hybrid two-wheeler. *World Electric Vehicle Journal*, 12(1), 2032--6653.
- Krummenacher, G., Ong, C., Koller, S., Kobayashi, S., & Buhmann, J. (s.f.). Wheel defect detection with machine learning. *IEEE Transactions on Intelligent Transportation Systems*, 19(4), 1176--1187.
- Kudelina, K., Asad, B., Vaimann, T., Belahcen, A., Rassólkin, A., Kallaste, A., & Lukichev, D. V. (3 de October de 2020). Bearing Fault Analysis of BLDC Motor for Electric Scooter Application. *MDPI designs*, 4(42), 1-18.
- Li, G., Wang, H., Zhang, S., Xin, J., & Liu, H. (2019). Recurrent neural networks based photovoltaic power forecasting approach. *Energies*, 12(13), Article number 2538.
- Reyes-Malanche, J., Villalobos-Pina, F., Cabal-Yepez, E., Alvarez-Salas, R., & Rodriguez-Donate, C. (2021). Open-Circuit Fault Diagnosis in Power Inverters Through Currents Analysis in Time Domain. *IEEE Transactions on Instrumentation and Measurement*, 1-12.
- Sadrossadat, S., & Rahmani, O. (2020). ANN-based method for parametric modelling and optimising efficiency, output power and material cost of BLDC motor. *IET Electric Power Applications*, 14(6), 951--960.
- Shi, Q., & Zhang, H. (2020). Fault diagnosis of an autonomous vehicle with an improved SVM algorithm subject to unbalanced datasets. *Transactions on Industrial Electronics*, 68(7), 6248--6256.
- Singh, S., Singh, K., Verma, K., Singh, J., & Tiwari, N. (2018). A Review on control of a brushless DC motor drive. *International Journal on Future Revolution in Computer Science & Communication Engineering*, 4(1), 82--97.
- Tang, P., Peng, K., Zhang, K., Chen, Z., Yang, X., & Li, L. (2018). A Deep Belief Network-based Fault Detection Method for Nonlinear Processes. *IFAC-PapersOnLine*, 51(24), 9--14.
- Vodovozov, V., Aksjonov, A., Petlenkov, E., & Raud, Z. (2021). Neural network-based model reference control of braking electric vehicles. *Energies*, Article number 2373.
- Walker, J. (2008). *A primer on wavelets and their scientific applications* (Second edition ed.). Chapman & Hall/CRC.
- Xu, X., Qiao, X., Zhang, N., Feng, J., & Wang, X. (2020). Review of intelligent fault diagnosis for permanent magnet synchronous motors in electric vehicles. *Advances en Mechanical Engineering*, 12(7), 951--960.
- Yang, R., Huang, M., Lu, Q., & Zhong, M. (2018). Rotatoting Machinery Fault Diagnosis Using Long-short-term Memory Recurrent Neural Network. *IFAC-PapersOnLine*, 51(24), 228--232.