

DETECCIÓN DE FALLAS DE CORTOCIRCUITO EN MOTORES DE INDUCCIÓN TRIFÁSICOS

SHORT-CIRCUIT FAULT DETECTION IN THREE PHASE INDUCTION MOTORS

Efraín Ramírez Velasco

Tecnológico Nacional de México / IT de Aguascalientes, México
r21153203@aguascalientes.tecnm.mx

Francisco Javier Villalobos Piña

Tecnológico Nacional de México / IT de Aguascalientes, México
francisco.vp@aguascalientes.tecnm.mx

Josué Augusto Reyes Malanche

Universidad Tecnológica de Aguascalientes, México
josue.malanche@utags.edu.mx

Carlos Humberto Saucedo Zárate

Tecnológico Nacional de México / IT de Aguascalientes, México
carlos.sz@aguascalientes.tecnm.mx

Recepción: 29/noviembre/2022

Aceptación: 22/diciembre/2022

Resumen

Una de las aplicaciones importantes del diagnóstico de fallas en máquinas eléctricas es su contribución en el mantenimiento preventivo, el cual no sólo está basado en registros y programación de eventos, sino también en la detección y aislamiento de fallas. Mediante técnicas de procesamiento digital de señales es posible detectar fallas de cortocircuito entre espiras en los devanados del estator de un motor de inducción trifásico. En la presente investigación se obtuvieron resultados experimentales, mediante el uso de un banco de pruebas construido especialmente con fines de investigación y una plataforma electrónica que permite el control y la adquisición de señales de corriente del estator de la máquina de inducción. Finalmente se implementó una red neuronal artificial como herramienta auxiliar al análisis tiempo vs frecuencia.

Palabras Clave: Detección de fallas, máquina de inducción, red neuronal, transformada discreta.

Abstract

One of the important applications of fault diagnosis in electrical machines is its contribution to preventive maintenance, which is not only based on event recording and programming, but also on fault detection and isolation. Using digital signal processing techniques, it is possible to detect short-circuit faults between turns in the stator windings of a three-phase induction motor. In the present investigation, experimental results were obtained, through the use of a test bench specially built for research purposes and an electronic platform that allows the control and acquisition of current signals from the stator of the induction machine. Finally, an artificial neural network was implemented as an auxiliary tool for the time and frequency analysis.

Keywords: *Discrete transform, fault detection, induction machine, neuronal network.*

1. Introducción

El motor de inducción especialmente el motor de inducción trifásico juega un rol importante en la industria, debido a sus ventajas sobre otros motores eléctricos. Por lo tanto, hay una demanda muy fuerte para que estos motores operen en condiciones sanas y de confianza [Siddiqui, 2014].

En la actualidad el monitoreo de condición de máquinas eléctricas que permite reducir costos de operación, da lugar a nuevas alternativas caracterizadas por ser en línea y no invasivas, y tienen la capacidad de detectar fallas mientras la máquina se encuentra en operación, por esta razón, diferentes alternativas han sido propuestas e implementadas para la detección y diagnóstico de fallas en máquinas de inducción en los últimos años [Alsaedi, 2015].

Un enfoque mediante lógica difusa puede ayudar a diagnosticar fallas en motores de inducción, en [Azgomi, 2013] y [Zamarrón, 2015], se presentan respectivamente, un método confiable y una implementación de lógica difusa para la detección de fallas en el estator de motores de inducción.

De la misma manera en [Paz, 2013] las fallas de cortocircuito entre espiras en un motor de inducción son analizadas por dos métodos en línea, utilizando múltiples

marcos de referencia y después mediante el módulo del fasor espacial instantáneo de Park (ISP por sus siglas en inglés).

El monitoreo de las corrientes y las vibraciones son bastante comunes en la industria, pero cada una de estas cualidades por si solas pueden solamente detectar algunas fallas específicas, [Picazo-Ródenas, 2015] presenta un método no invasivo para detectar fallas electromecánicas en un motor de inducción trifásico.

Una técnica de diagnóstico para fallas tempranas, basada en señales acústicas que se obtuvieron de un motor sano, con falla de cojinetes y con falla combinada de cojinetes y cortocircuito en el devanado se presenta en [Glowacz, 2017].

Un procedimiento basado basado en el análisis del transitorio de la corriente de arranque, se presenta en [Martinez-Herrera, 2022] e identifica y clasifica múltiples fallas en máquinas de inducción. [Gargiulo, 2022] presenta un método no invasivo basado en inteligencia artificial (IA) y mediciones de corriente para la detección de fallas eléctricas y mecánicas en motores trifásicos asíncronos. Así también [Skowron, 2020] muestra una red neuronal de convolución para la detección y clasificación de fallas en los devanados de un motor de inducción.

Un algoritmo robusto se presenta en [Villalobos-Piña, 2015] para el diagnóstico de fallas eléctricas en un motor de inducción mediante análisis espectral y análisis multirresolución. Una técnica de análisis basada en la energía de la transformada discreta Ondeleta (Wavelet) que permite la detección de fallas de cortocircuito en un motor se describe en [Cherif, 2017].

Se propone también un esquema de detección de falla incipiente de cortocircuito en tiempo real en fuentes de voltaje de máquinas eléctricas alimentadas por inversor [Vinayak, 2019]. [Reyes-Malanche, 2021] propone un método de diagnóstico de fallas de circuito abierto en inversores de potencia, mediante el análisis de las corrientes en el dominio del tiempo, utilizando análisis fasorial, análisis espectral y análisis multirresolución, el método propuesto permite identificar y aislar la falla. [Ebrahimi, 2022] presenta una técnica basada en un modelo robusto para detectar múltiples fallas tales como cortocircuitos entre espiras y fallas de encoder en tiempo real. Por otro lado [Bouzid, 2018] utiliza una compensación de la corriente de secuencia negativa de un motor de inducción con falla, como medida para

incrementar la precisión y la sensibilidad de detección fallas incipientes bajo diferentes perturbaciones. En el presente trabajo realiza la aplicación de diferentes técnicas de procesamiento de señales y redes neuronales para la detección de fallas de cortocircuito en los devanados del estator de un motor de inducción trifásico.

2. Métodos

Procesamiento de Señales es un área de la Ingeniería Electrónica que se concentra en la representación, transformación y manipulación de señales, y de la información que ellas contienen. El procesamiento digital de señales, añade a la característica anterior la de manejar la amplitud en forma discreta, la cual es una condición necesaria para que la señal pueda ser procesada [Vignolo, 2008]. En el presente trabajo de investigación, la metodología para la detección de fallas se realizó como se muestra en el diagrama de la figura 1.

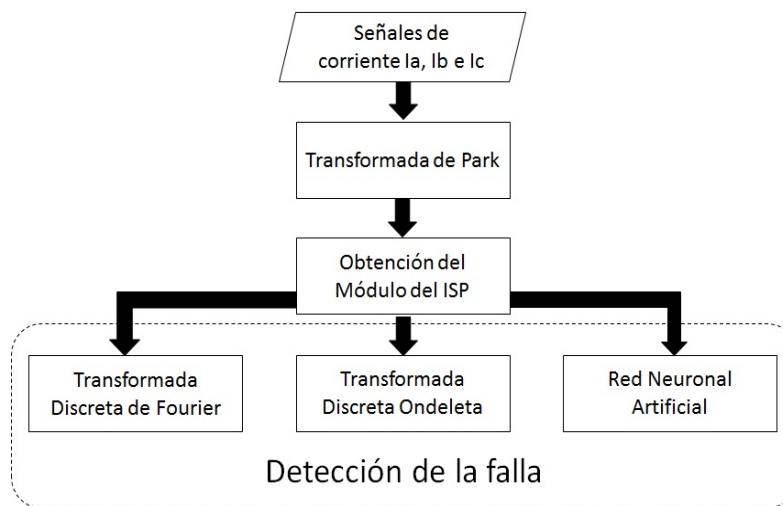


Figura 1 Diagrama del proceso de detección de fallas.

Fasor Espacial Instantáneo de Park (ISP)

La transformada de Park es una herramienta que permite visualizar el desbalance de las corrientes del estator del motor de inducción provocadas por una falla, las corrientes de línea se mapean a un marco de referencia $(\alpha - \beta)$ fijo con respecto al estator como lo denota la ecuación 1 [Villalobos, 2015].

$$\begin{bmatrix} i_\alpha \\ i_\beta \\ i_0 \end{bmatrix} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & \cos\left(-\frac{2}{3}\pi\right) & \cos\left(\frac{2}{3}\pi\right) \\ 0 & -\text{sen}\left(-\frac{2}{3}\pi\right) & -\text{sen}\left(\frac{2}{3}\pi\right) \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} \quad (1)$$

Donde i_a es la corriente de la fase a, i_b es la corriente de la fase b e i_c es la corriente de la fase c. El módulo del fasor espacial instantáneo de Park (ISP por sus siglas en inglés) se puede expresar en ecuación 2.

$$\|i_{\alpha\beta}\|^2 = i_\alpha^2 + i_\beta^2 \quad (2)$$

Transformada Discreta de Fourier (DFT)

La ingeniería ha empleado a lo largo de la historia métodos de análisis que trataban de reducir la complejidad matemática de un problema. Estas técnicas se basan en la transformación matemática de las ecuaciones. En el caso de la Transformada Discreta de Fourier (DFT), están involucradas ecuaciones 3 y 4. En donde k es el índice de la señal original, x son los datos de entrada y W son operaciones básicas mariposa dadas por la ecuación 4.

$$C(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n)W^{kn} \quad (3)$$

$$W = e^{-\frac{j2\pi}{N}} = \cos\left(\frac{2\pi kn}{N}\right) - i \sin\left(\frac{2\pi kn}{N}\right) \quad (4)$$

Tomando como referencia a $N = 4$, se puede representar de forma matricial en ecuación 5.

$$\begin{bmatrix} C(0) \\ C(1) \\ C(2) \\ C(3) \end{bmatrix} = \begin{bmatrix} W^0 & W^0 & W^0 & W^0 \\ W^0 & W^1 & W^2 & W^3 \\ W^0 & W^2 & W^4 & W^6 \\ W^0 & W^3 & W^6 & W^9 \end{bmatrix} \begin{bmatrix} x(0) \\ x(1) \\ x(2) \\ x(3) \end{bmatrix} \quad (5)$$

De la ecuación 5 se obtiene la operación denominada como operación de mariposa de la DFT la cual se ilustra en la figura 2.




Figura 2 Operación de mariposa.

Transformada discreta ondeleta de Haar nivel 1

La transformada discreta ondeleta (Wavelet del idioma inglés) es una transformada simple. En forma discreta la Wavelet de Haar está relacionada con una transformación matemática. Una señal discreta, es una función del tiempo con valores que se obtienen en instantes discretos. Generalmente se puede expresar una señal discreta como se presenta en ecuación 6 [Walker, 2008].

$$f = (f_1, f_2, f_3, \dots, f_N) \quad (6)$$

En donde N es un entero positivo que se puede relacionar con la longitud de los valores de f , estos valores son típicamente obtenidos de una señal analógica. Como todas las ondeletas, la Transformada de Haar descompone una señal discreta en dos subseñales, una llamada promedio o también nombrada trend o average del idioma inglés y la fluctuación también llamada fluctuation, difference o detail del idioma inglés de igual longitud y cuyas longitudes son la mitad de la longitud de la señal original. La función promedio se obtiene utilizando ecuación 7 y la función de fluctuación, ecuación 8. En donde $m = 1, 2, 3, \dots, N/2$.

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

$$d_m = \frac{f_{2m-1} - f_{2m}}{\sqrt{2}} \quad (8)$$

Tomando ecuaciones 7 y 8 se obtienen el vector de la función promedio ecuación 9 y el vector de la función de fluctuación, ecuación 10.

$$a_1 = \frac{f_1 + f_2}{\sqrt{2}}, a_2 = \frac{f_3 + f_4}{\sqrt{2}}, a_3 = \frac{f_5 + f_6}{\sqrt{2}}, \dots, a_{N/2} = \frac{f_{N/2-1} + f_{N/2}}{\sqrt{2}} \quad (9)$$

$$d_1 = \frac{f_1 - f_2}{\sqrt{2}}, d_2 = \frac{f_3 - f_4}{\sqrt{2}}, d_3 = \frac{f_5 - f_6}{\sqrt{2}}, \dots, d_{N/2} = \frac{f_{N/2-1} - f_{N/2}}{\sqrt{2}} \quad (10)$$

La Ondeleta de Haar nivel 1, se define como se muestra en ecuación 11.

$$\begin{aligned} W_1^1 &= \left(\frac{1}{\sqrt{2}}, \frac{-1}{\sqrt{2}}, 0, 0, \dots, 0 \right) \\ W_2^1 &= \left(0, 0, \frac{1}{\sqrt{2}}, \frac{-1}{\sqrt{2}}, 0, 0, \dots, 0 \right) \\ W_3^1 &= \left(0, 0, 0, 0, \frac{1}{\sqrt{2}}, \frac{-1}{\sqrt{2}}, 0, 0, \dots, 0 \right) \\ &\vdots \\ W_{N/2}^1 &= \left(0, 0, \dots, 0, \frac{1}{\sqrt{2}}, \frac{-1}{\sqrt{2}} \right) \end{aligned} \quad (11)$$

Redes neuronales artificiales

La popularidad del aprendizaje en línea para el entrenamiento supervisado de perceptrones multicapa, ha sido mejorada por el desarrollo del algoritmo de retropropagación [Haykin, 2009].

Para describir este algoritmo considere la figura 3, que representa una neurona j ésima que es alimentada por un grupo de funciones de señales producidas por una capa de neuronas a la izquierda.




Figura 3 Flujo de señal destacando los detalles de la salida de la neurona j .

El campo local inducido $v_j(n)$ asociado con la neurona j ésima es manifestado en la ecuación 12.

$$v_j(n) = \sum_{i=0}^m \omega_{ji}(n)y_i(n) \quad (12)$$

Donde m es el número total de entradas excluyendo el bias, aplicadas a la j ésima neurona, ω_{ji} son los pesos sinápticos, donde ω_{j0} es correspondiente con la entrada arreglada $y_0 = +1$ como se muestra en la figura 2, igual al bias b_j aplicado a la neurona j ésima y y_j es la función de salida de la j ésima neurona en la iteración n , ecuación 13. Donde $\varphi_j(v_j(n))$ es la función de activación (función logística) asociada a la j ésima neurona y el error $e_j(n)$ correspondiente a la salida de la neurona en j , está definido en ecuación 14. Donde $d_j(n)$ es la respuesta deseada.

$$y_j(n) = \varphi_j(v_j(n)) \quad (13)$$

$$e_j(n) = d_j(n) - y_j(n) \quad (14)$$

3. Resultados

Para la obtención de los resultados se implementó una plataforma experimental basada en el procesador de señales digitales el TMS320F28335 de punto flotante de 32 bits de la compañía Texas Instruments y se desarrolló un algoritmo computacional en lenguaje visual Delphi 7 para la adquisición de señales de corriente en tiempo real como se ilustra en la figura 4. El programa de computadora, permite modificar le frecuencia de muestreo de la adquisición de datos, así como la cantidad de información que se desea adquirir en cada captura.

Para fines del presente trabajo se capturaron señales de corriente del estator a una frecuencia de muestreo de 1 kHz. Para el control de la velocidad del motor, se construyó un inversor trifásico completo con un algoritmo de control volts/Hertz para un motor de alta eficiencia de la marca SIEMENS de 3 hp de potencia con conexión doble estrella a un voltaje de 220 V y 60 Hz, el cual se modificó el devanado L6 agregando los taps 2 y 3 para inducir artificialmente los diferentes escenarios de falla como se puede observar en la figura 5.

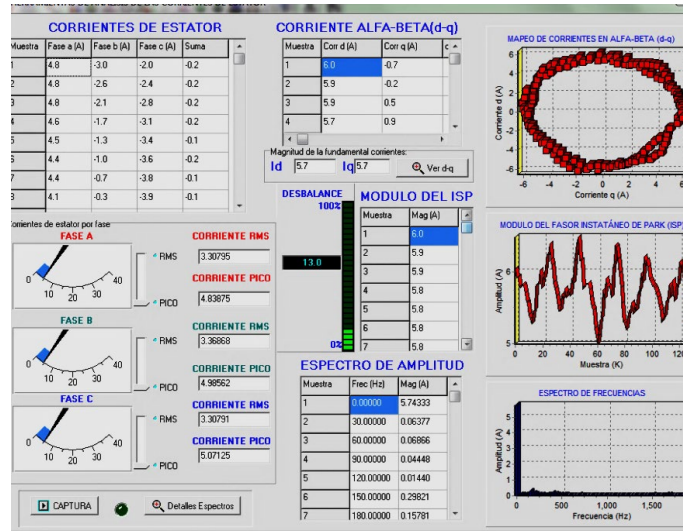


Figura 4 Interfaz de adquisición de datos desarrollada en Delphi 7.




Figura 5 Bobinas del motor en configuración doble estrella.

Para la caracterización del motor de inducción, se realizaron mediciones de resistencia e inductancia en cada uno de sus devanados utilizando un puente LCR de la marca Instek modelo LCR-821. La tabla 1, presentan dichos valores, y la tabla 2 muestra las conexiones para inducir las fallas (taps) en la bobina L6.

Tabla 1 Impedancias del motor de inducción.

MOTOR SIEMENS			
Bobina No.	Terminales	Resistencia (Ω)	Inductancia (mH)
L1	1 Y 4	4.25	56.06
L2	7 y 10	4.39	54.92
L3	2 y 5	3.07	38.96
L4	8 y 11	4.21	36.39
L5	3 y 6	3.59	38.96
L6	9 y 12	3.71	46.99

Tabla 2 Distribución de conexiones y sus valores de impedancia.

Bobina No.	Terminales	Conexión	Vueltas que resta	Resistencia (Ω)	Inductancia (mH)
L6	9 y 12	3 y tap 2	10 de 45	3.4	42.62
		3 y tap 3	17 de 45	3.34	41.64

Resultados con la transformada discreta de Fourier

Se aplicó la transformada discreta de Fourier (DFT) al módulo del fasor espacial instantáneo (ISP) que se obtiene mediante las ecuaciones 1 y 2, para así conseguir los espectros de frecuencia de cada uno de los escenarios de falla. En la figura 6 se presentan las señales de las tres corrientes de fase y su espectro de Fourier en condición sana, como se puede observar la magnitud de las tres corrientes de fase son aproximadamente iguales y en el espectro de Fourier tienden a aparecer picos en la frecuencia fundamental y al doble de esta. En la figura 7 se muestra la falla de 5% y como se puede apreciar la corriente de la fase c incrementa su magnitud debido al cortocircuito y en el espectro aparecen los picos en la frecuencia fundamental y al doble de esta, que es donde aparece la firma de falla.

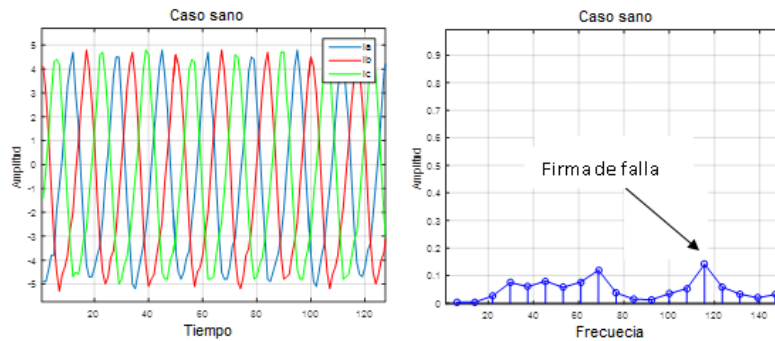


Figura 6 Condición sana respecto al tiempo y la frecuencia.

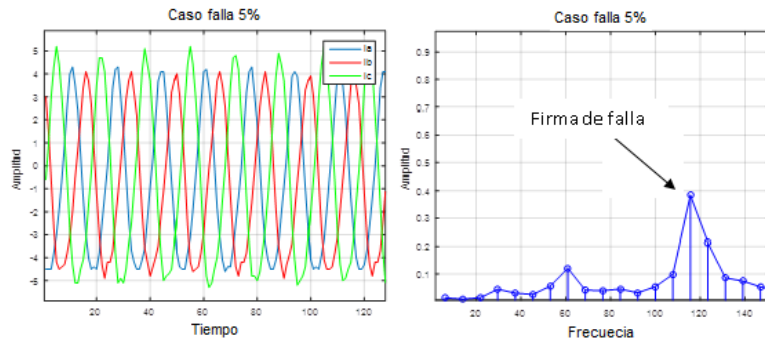


Figura 7 Condición 5% de falla respecto al tiempo y la frecuencia.

Por último en la figura 8 se exhibe la falla de 12% y es más evidente el incremento de la amplitud de la corriente de dicha fase. Dado que la frecuencia del espectro de firma de falla en las corrientes del estator ocurre al doble de la frecuencia fundamental [Villalobos-Piña, 2015].




Figura 8 Condición 12% de falla respecto al tiempo y la frecuencia.

Resultados con la ondeleta (Wavelet) de Haar nivel 1

Se aplicó la transformada discreta ondeleta de Haar nivel 1 al módulo del fasor espacial instantáneo (ISP) obtenido de los escenarios según la condición en la que se encuentran las corrientes en el estator del motor, utilizando 6 niveles de descomposición, los cuales tienen las bandas de frecuencia de (512-256) Hz, (256-128) Hz, (128-64) Hz, (64-32) Hz, (32-16) Hz, (16-8) Hz. Tomando en cuenta el análisis de Fourier, la firma de falla se presenta en la banda de frecuencia de (64 a 128) Hz, donde figura 9 muestra los resultados en condición sana del motor y como se puede observar las amplitudes de las corrientes de las tres fases son iguales.

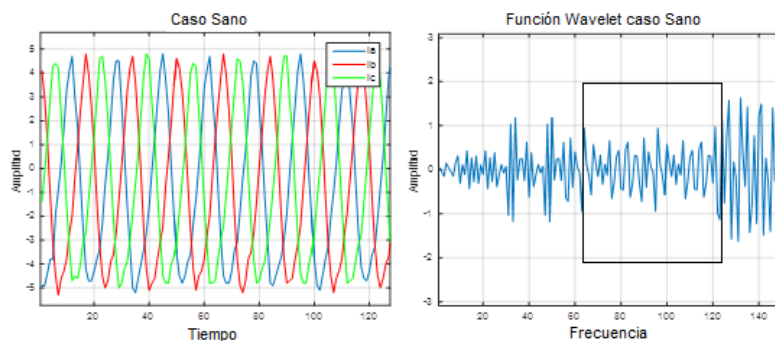


Figura 9 Condición sana respecto al tiempo y la frecuencia.

La figura 10 muestra la condición de falla del 5%, y como se puede observar la corriente de la fase c crece y la ondeleta detecta el cambio de amplitud incrementando el valor de los coeficientes en la sección del recuadro de dicha figura en donde la banda de frecuencia de 64 a 128 Hz.




Figura 10 Condición 5% de falla respecto al tiempo y la frecuencia.

En la figura 11 se presenta la condición del 12% de falla en dicha fase del estator y como se mencionó los coeficientes de la ondeleta crecen aún más su valor debido al incremento de la corriente por la falla de cortocircuito entre espiras, en la banda de frecuencia de los 64 a los 128 Hz.




Figura 11 Condición 12% de falla respecto al tiempo y la frecuencia.

Se calcularon los valores cuadrático medios (RMS por sus siglas en inglés) de 5 experimentos de cada una de las condiciones de falla, utilizando la ecuación 15, donde $d_1, d_2, d_3, \dots, d_{N/2}$ son los datos de las funciones de fluctuación obtenidos en cada uno de los niveles de descomposición de la Ondeleta, cuya longitud es n .

$$d_{rms} = \sqrt{\frac{d_1^2 + d_2^2 + d_3^2 + \dots + d_{N/2}^2}{n}} \quad (15)$$

Posteriormente se graficaron los valores que son mostrados en las figuras a continuación, donde la figura 12 presenta los valores RMS de las funciones de fluctuación obtenidas de la ondeleta en las diferentes bandas de frecuencia cuando el motor se encuentra en condición sana. La figura 13 muestra ahora el cambio en los coeficientes de la ondeleta cuando se presenta una falla de cortocircuito del 5% en la corriente de la fase c, debido al incremento de la corriente en dicha fase.

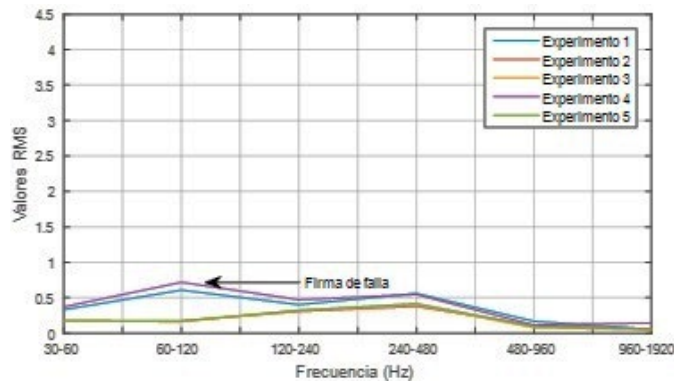


Figura 12 Casos sanos.




Figura 13 Casos con falla al 5%.

En figura 14 se observan cambios en la ondeleta cuando se presenta una falla del 12%, se exhibe nuevamente el incremento en los coeficientes de la wavelet en la banda de frecuencia de interés, por tanto, valores RMS se incrementan en esa zona.

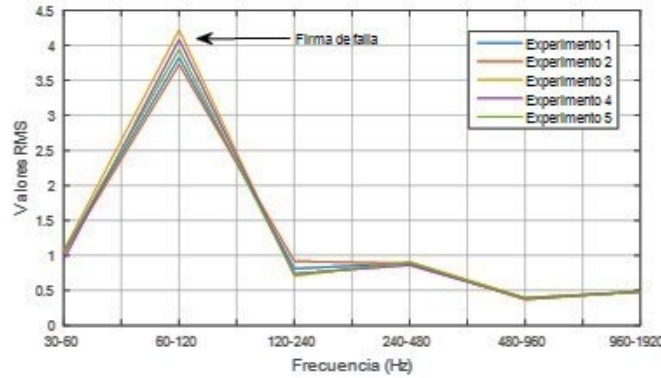


Figura 14 Casos con falla al 12%.

Por último, se aplicó una red neuronal artificial de retropropagación (feed forward back propagation FFBP por sus siglas en inglés) al módulo del ISP, la cual tiene 5 neuronas en su capa de entrada y una sola neurona en su capa de salida, las neuronas de la capa de entrada utilizan una función de activación tangente sigmodal y la neurona de la capa de salida utiliza una función de activación lineal. La intención principal de la presente investigación fue lograr una topología simple de implementar en hardware. La red neuronal artificial fue implementada en Matlab cuyo diagrama de bloques se puede observar en la figura 15. Para lo anterior se utilizaron dos escenarios de falla los cuales fueron condición sana y condición de falla incipiente del 5% del devanado de la fase c en cortocircuito entre espiras de la misma fase, se realizó el entrenamiento de la red con 200 iteraciones y los resultados fueron favorables, ya que la red logró diferenciar la condición sana de la condición de falla.




Figura 15 Red neuronal de retropropagación aplicada.

Se tiene una base de datos con 90 experimentos, los cuales 30 son en condición sana, 30 en condición de falla del 5% y 30 en condición de falla del 12%. En este trabajo se le estableció a la red neuronal el valor esperado de salida para la

condición sana de 0 y el valor deseado en condición de falla del 5% en 1. Primeramente la red neuronal se entrenó con el 70% del total de los datos obtenidos del módulo ISP, y posteriormente se definió el conjunto de prueba con el 30% de los resultados restantes, para así obtener los valores deseados de 0 en condición sana y 1 en condición de falla.

4. Discusión

Como se observó, las técnicas empleadas en este trabajo de investigación son sensibles, en un amplio porcentaje, a la detección de fallas de cortocircuito entre espiras de cualquiera de los devanados del estator del motor de inducción. Aplicar estas técnicas para el monitoreo de la condición de operación del motor de inducción, contribuye a la detección temprana de fallas de cortocircuito, así como a la programación de un mantenimiento preventivo y evitar paros innecesarios que generarían pérdidas económicas.

5. Conclusiones

Un aspecto importante dentro del diagnóstico de fallas, es que en muchas ocasiones se requiere un modelo analítico confiable para la detección de fallas de cortocircuito en el estator de un motor de inducción, el cual es muy difícil de obtener. Por ello, en ese sentido se parte hacia otra dirección empleando técnicas de procesamiento de señales tales como la transformada de Park, la transformada discreta de Fourier, la transformada discreta Ondeleta y técnicas de inteligencia artificial, tales como las redes neuronales artificiales las cuales son no invasivas y permiten conectarse a la máquina sin interrupción de su operación. Por otro lado ninguna de las técnicas antes mencionadas permiten realizar el aislamiento de la falla.

6. Bibliografía y Referencias

- [1] Alsaedi M. A. Fault diagnosis of three-phase induction motor: A review, *Applied Optics and Signal Processing*, Vol. 4, Issue 1-1, pp. 1-8, 2015.
doi: 10.11648/j.optics.s.2015040101.11.

- [2] Ben-Khader-Bouzid M., Champenois G., & Tnani S. Reliable stator fault detection based on the induction motor negative sequence current compensation, *Electrical Power and Energy Systems*, Elsevier, Vol. 95, pp. 490-498, February 2018. <http://dx.doi.org/10.1016/j.ijepes.2017.09.008>.
- [3] Ebrahimi S. H., Choux M., & Huynh V. K. Real-Time Detection of Incipient Inter-Turn Short Circuit and Sensor Faults in Permanent Magnet Synchronous Motor Drives Based on Generalized Likelihood Ratio Test and Structural Analysis, *Sensors*, MDPI, Vol. 22, Issue 9, 2022, <https://doi.org/10.3390/s22093407>.
- [4] Gargiulo F., Liccardo A., & Lo Moriello R. S. A Non-Invasive Method Based on AI and Current Measurements for the Detection of Faults in Three-Phase Motors, *Energies*, MDPI, Vol. 15, Issue 12, 2022, <https://doi.org/10.3390/en15124407>.
- [5] Glowacz A., Glowacz W., Glowacz Z., & Kozik J. Early fault diagnosis of bearing and stator faults of the single phase induction motor using acoustic signals, *Elsevier Measurement*, Vol. 113, pp. 1-9, 2018, <https://doi.org/10.1016/j.measurement.2017.08.036>.
- [6] Martinez-Herrera A. L., Ferrucho-Alvarez E. R., Ledesma-Carrillo L. M., Mata-Chavez R. I., Lopez-Ramirez L., & Cabal-Yepes E. Multiple Fault Detection in Induction Motors through Homogeneity and Kurtosis Computation, *Energies*, MDPI, Vol. 15, Issue 4, 2022, <https://doi.org/10.3390/en15041541>.
- [7] Picazo-Ródenas M. J. Antonino-Daviu J., Clemente-Alarcón V., Royo-Pastor R., & Mota-Villar A. Combination of non-invasive approaches for general assessment of induction motors, *IEEE Transactions on Industry Applications*, Vol. 51, Issue 3, May-June 2015, doi:10.1109/TIA.2014.2382880.
- [8] Reyes-Malanche J. A., Villalobos-Piña F. J., Cabal-Yepes E., Alvarez-Salas R., & Rodriguez-Donate C. Open-Circuit Fault Diagnosis in Power Inverters Through Currents Analysis in Time Domain, *IEEE Transactions on Instrumentation and Measurement*, IEEE, Vol. 70, Article Sequence Number: 3517512, INSPEC Accession Number: 20994967, May 20 2021, doi:10.1109/TIM.2021.3082325.

- [9] Siddiqui K. M., Sahay K., & Giri V. K. Health Monitoring and Fault Diagnosis in Induction Motor- A Review, *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, Vol. 3, Issue 1, 2014. <http://www.ijareeie.com/volume-3-issue-1>.
- [10] Skowron M., Orłowska-Kowalska T., Wolkiewicz M., & Kowalski C. T. Convolutional Neural Network-Based Stator Current Data-Driven Incipient Stator Fault Diagnosis of Inverter-Fed Induction Motor, *Energies*, MDPI, Vol. 13, Issue 6, March 20 2020, doi:10.3390/en13061475.
- [11] Villalobos-Piña F. J., & Alvarez-Salas R. Algoritmo robusto para el diagnóstico de fallas eléctricas en el motor de inducción trifásico basado en herramientas espectrales y ondeletas, *Revista Iberoamericana de Automática e Informática industrial*, Elsevier, Vol. 12, pp. 292–303, 2015, <http://dx.doi.org/10.1016/j.riai.2015.04.003>.
- [12] Vinayak B. A., Anand K. A., Jagadanand G. Wavelet-based real-time stator fault detection of inverter-fed induction motor, *IET Electric Power Applications*, IET Journals, Vol. 14, Issue 1, November 11 2019, doi: 10.1049/iet-epa.2019.0273.
- [13] Zamarrón A., & Rodríguez S. Diagnóstico de fallas en el Motor de Inducción usando Lógica Difusa, *Revista Iberoamericana de Ciencias*, Vol. 2, Número 2, Marzo 2015. <http://www.reibci.org/marzo-15.html>.
- [14] Azgomi H. F., Poshtan J. Induction Motor Stator Fault Detection via Fuzzy Logic, 21st Iranian Conference in Electrical Engineering (ICEE), Mashhad, Iran, published via IEEE Xplore, IEEE, September 16, 2013.
- [15] Cherif H., Menacer A., Romary R., & Pusca R. Dispersion field analysis using Discrete Wavelet Transform for inter-turn stator fault detection in induction Motors, 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED), Tinos, Greece, published via IEEE Xplore, IEEE, October 9, 2017.
- [16] Vignolo-Barchiesi J. *Introducción al Procesamiento Digital de Señales*, Ediciones Universitarias de Valparaíso, Pontificia Universidad Católica de Valparaíso, Valparaíso, Chile, 2008.

- [17] Paz-Parra A., Amaya-Enciso M. C., Olaya-Ochoa J., & Palacios-Peñaranda J. A. Stator Fault Diagnosis on Squirrel Cage Induction Motors by ESA and EPVA, Workshop on Power Electronics and Power Quality Applications, Bogotá, Colombia, Published via IEEE Xplore, IEEE, 2013.
- [18] Haykin S. Neuronal networks and learning machines, Third edition, McMaster University, Hamilton, Ontario, Canada, Pearson / Prentice Hall, 2009.
- [19] Walker J. S. A primer on Wavelets and their scientific applications, Second edition, University of Wisconsin, Eau Claire USA, Chapman & Hall/CRC, 2008.