

DetECCIÓN DE BARRAS ROTAS Y DESBALANCE MECÁNICO EN MOTORES DE INDUCCIÓN UTILIZANDO LOS MOMENTOS CENTRALES DE LA SEÑAL DE CORRIENTE

Lessli B. Ramirez-Alvarez¹, Diego R. Fuerte Aguilar¹, Samuel de J. Silvan-Gonzalez², Jaime P. Castaneda Ramirez¹, Yoseft A. Miranda-Lopez¹, Misael Lopez-Ramirez¹, Eduardo Cabal-Yepez¹

¹ División de Ingenierías, Campus Irapuato-Salamanca, Universidad de Guanajuato, Yuriria, Guanajuato, México.

² Instituto Tecnológico Superior de la Región Sierra, Teapa, Tabasco, México.
educabal@ugto.mx¹

Resumen

Los motores de inducción son componentes fundamentales de cualquier proceso industrial; por lo tanto, es muy importante monitorearlos de forma continua para detectar fallas incipientes a fin de evitar interrupciones en las líneas de producción. Barras rotas y desbalance están entre las condiciones de falla más frecuentes atrayendo la atención de los investigadores en busca de técnicas eficientes para reconocer estas condiciones con gran certidumbre. La mayoría de los métodos propuestos optan por detectar las fallas durante el transitorio de arranque del motor debido a que las componentes frecuenciales características de algunas fallas se intensifican; sin embargo, los motores de inducción trabajan regularmente en un régimen de operación estable. En este trabajo se propone una técnica basada en el análisis de la señal de corriente durante el estado estable y se realiza un estudio experimental para detectar barras rotas y desbalance mecánico en un motor de inducción a través de la observación de los momentos centrales estadísticos de la señal de corriente y una red neuronal artificial del tipo perceptrón multicapa. Los resultados obtenidos demuestran que la técnica propuesta identifica y clasifica la condición de operación del motor de inducción con una certeza mayor al 90%.

Palabras clave: Barras rotas; Desbalance mecánico; Momentos centrales estadísticos; Motores de inducción; Redes neuronales artificiales.

Introducción

Los motores de inducción son de gran importancia a nivel mundial, ya que su presencia es cada vez mayor en la industria, de tal forma que su utilización representa aproximadamente el 70% del consumo de energía eléctrica en el sector industrial (Ferreira-de-Souza et al., 2022). Dichas máquinas usualmente trabajan bajo severas condiciones (térmicas, eléctricas, mecánicas, ambientales, etc.) Lo cual puede provocar la presencia de fallas en el rotor, para lo cual una detección temprana puede ser fundamental para la productividad del proceso industrial, de igual forma esto puede hacer la diferencia entre minimizar los daños en el motor, o que el motor llegue a estados críticos (Liu et al., 2022). El motor de inducción desempeña un rol fundamental, en el contexto global, como un elemento esencial en la cadena productiva, he aquí que la importancia de la detección temprana de fallas en los motores de inducción ha sido de gran interés para los investigadores durante varios años, buscando enfoques diferentes para su correcta detección con alto grado de certeza. Entre las fallas mecánicas más comunes en motores de inducción que provocan retrasos y pérdidas económicas en las líneas de producción se encuentran el desbalance (Kucuker and Bayrak, 2013) y las barras rotas (Terron-Santiago et al. 2021). Una característica de este tipo de fallas es que su diagnóstico es difícil de lograr en etapas tempranas, puesto que el motor continúa trabajando sin mostrar síntomas de algún daño (Lu et al., 2018), pero el consumo eléctrico se incrementa de manera significativa, y de no ser atendidas de manera oportuna pueden ocasionar calentamiento excesivo, vibraciones indeseadas, daños irreversibles a la máquina o equipo cercano y en el peor de los casos poner en riesgo la integridad física de las personas (Aguilera et al. 2016). El análisis de la firma de corriente del motor es una de las técnicas más utilizadas para la detección de fallas en motores de inducción, debido a su naturaleza no invasiva (Li et al., 2020; Shin et al. 2021). Consiste en la adquisición de la señal de corriente eléctrica suministrada al motor de inducción para detectar cualquier alteración. Por otro lado, la detección de fallas utilizando el análisis de la firma de corriente durante el transitorio de arranque del motor es mucho más simple que durante su estado estable, debido a que las componentes frecuenciales características de algunas fallas se intensifican durante su transitorio de arranque; sin embargo, los motores de inducción suelen trabajar bajo un régimen de operación estable, haciendo de la detección de fallas en este estado de operación un verdadero reto (Rafaq et al. 2022; Asad et

al. 2021). Como se mencionó, el análisis de firma de corriente de un motor de inducción se basa en la detección de pequeños cambios inducidos por las condiciones de falla; por lo tanto, es posible detectar distintas condiciones de operación de un motor analizando las características de su señal de corriente en tiempo debido a que la información contenida en la señal cambia bajo distintas condiciones de operación (Chang et al. 2022; Ferrucho-Alvarez et al. 2021). En consecuencia, en este trabajo se realiza un examen experimental para estudiar la factibilidad de utilizar los 4 momentos centrales estadísticos (media, desviación estándar, asimetría y curtosis) de la señal de corriente de un motor de inducción durante su estado estable, en conjunto con un clasificador basado en una red neuronal artificial simple, para la detección de fallas como barras rotas y desbalance.

Marco Teórico

En la teoría de probabilidad y estadística, un momento central se refiere a una característica de una distribución probabilística de una variable aleatoria respecto a su media. Este momento es el valor esperado de la potencia entera específica de la diferencia (desviación) de la variable aleatoria respecto a su media. Estos momentos forman un conjunto de valores mediante los cuales las propiedades de una distribución probabilística de una variable aleatoria pueden ser caracterizadas (Grimmett and Stirzaker, 2020; Eriksson et al. 2009).

Media (Primer momento central)

La media o promedio μ de un conjunto de datos es una medida de la tendencia central de un conjunto de números. Se encuentra al sumar todos los números en el conjunto de datos ($X = x_1, x_2, x_3, \dots, x_N$) y dividir el resultado entre el número total de valores en el conjunto N , como se describe en (1).

$$\mu(X) = \frac{1}{N} \sum_{i=1}^N x_i \quad (1)$$

Desviación Estándar (Segundo momento central)

En estadística, la desviación estándar σ es una medida que se utiliza para cuantificar la variación o la dispersión de un conjunto de datos numéricos. Una desviación estándar pequeña indica que los valores del conjunto de datos tienden a estar cerca de su media; por otro lado, una desviación estándar alta indica que los datos se dispersan en un rango más amplio de valores. La desviación estándar se calcula como se describe a continuación:

$$\sigma(X) = \sqrt{\frac{1}{N-1} \sum_{i=1}^N [x_i - \mu(X)]^2} \quad (2)$$

Asimetría (Tercer momento central)

En probabilidad y estadística, la asimetría μ_3 es una medida de la desviación de la distribución probabilística de un conjunto de datos ($X = x_1, x_2, x_3, \dots, x_N$) aleatorios, respecto a su media. La asimetría probabilística puede tomar valores positivos, negativos, cero o indefinidos. Si la asimetría es cero significa que las colas de ambos lados de la media en una distribución normal están balanceadas en general, teniendo una distribución simétrica. Un valor negativo de asimetría indica que los valores de los datos están desviados hacia la izquierda, generando una cola más pronunciada del lado izquierdo de la media. Por otro lado, un valor positivo de asimetría indica que los datos están desviados hacia la derecha de la media, generando una cola más

pronunciada del lado derecho de la media. La asimetría de un evento aleatorio $X = x_1, x_2, x_3, \dots, x_N$, se define como:

$$\mu_3(X) = \frac{\frac{1}{N} \sum_{i=1}^N [x_i - \mu(X)]^3}{\left(\sqrt{\frac{1}{N} \sum_{i=1}^N [x_i - \mu(X)]^2} \right)^3} \quad (3)$$

Curtosis (Cuarto momento central)

La curtosis μ_4 es una medida de que tan aguda (puntiaguda) o plana es la dispersión de los datos en una distribución normal. Los conjuntos de datos con una curtosis alta tienden a tener un pico muy distintivo alrededor de su media, decrecen rápidamente y tiene colas muy largas. Los conjuntos de datos con baja curtosis tienden a tener una cresta muy plana en las proximidades de su media. La curtosis de un evento aleatorio $X = x_1, x_2, x_3, \dots, x_N$, se define como:

$$\mu_4(X) = \frac{\frac{1}{N} \sum_{i=1}^N [x_i - \mu(X)]^4}{\left(\frac{1}{N} \sum_{i=1}^N [x_i - \mu(X)]^2 \right)^2} \quad (4)$$

Redes Neuronales Artificiales

Las redes neuronales artificiales (ANN, *artificial neural networks*) se inspiran en los modelos de neuronas vivas y comunicación de redes (Deperlioglu and Kose, 2011). Una neurona es un nodo en una ANN que lleva a cabo la suma de una función no lineal para procesar información. Las conexiones de las neuronas (conexiones sinápticas) se representan a través de factores de peso en las interconexiones de la red; los cuales se ajustan durante el proceso de entrenamiento de la red, mediante el cual datos de entrada junto con sus salidas correspondientes o deseadas son proporcionados a la red en varias iteraciones. En cada repetición los pesos se ajustan para obtener una salida cercana a los valores deseados. En una red multi capa del tipo perceptrón, como se muestra en la Figura 1, hay neuronas específicas para los parámetros de entrada y para las funciones de salidas, y existen neuronas internas a la red (capa oculta) para llevar a cabo un procesamiento exhaustivo de la información.

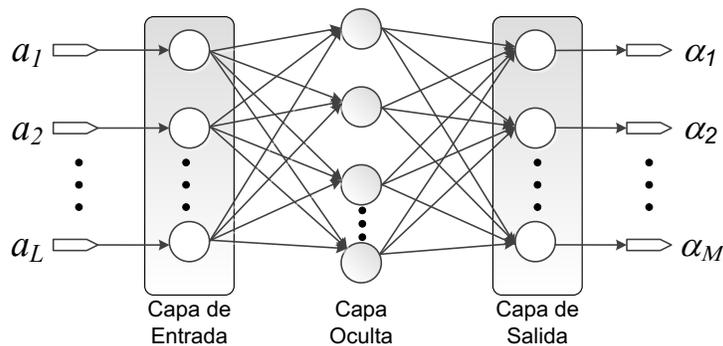


Figura 1. Arquitectura de una red neuronal artificial del tipo perceptrón multi capa.

Metodología Propuesta

La Figura 2 muestra la metodología propuesta para el diagnóstico de barras rotas y desbalance mecánico en motores de inducción. La señal de corriente de alimentación se adquiere durante el estado estable del motor de inducción, para evaluar la metodología propuesta. La señal de corriente se adquiere utilizando una pinza amperimétrica; después, la señal es acondicionada y convertida en una señal digital en el sistema de adquisición de datos (DAS). La señal discreta resultante es procesada para estimar los cuatro momentos centrales, la media μ , desviación estándar σ , asimetría μ_3 y curtosis μ_4 , de sus muestras en una computadora personal (CPU), utilizando el software Matlab 2020a. Finalmente, los cuatro momentos centrales calculados son utilizados como entradas a un clasificador basado en una ANN del tipo perceptrón, que se encarga de identificar y clasificar la condición del motor como sano, con una barra rota (1BRB), con dos barras rotas (2BRB) o con desbalance mecánico (UNB).

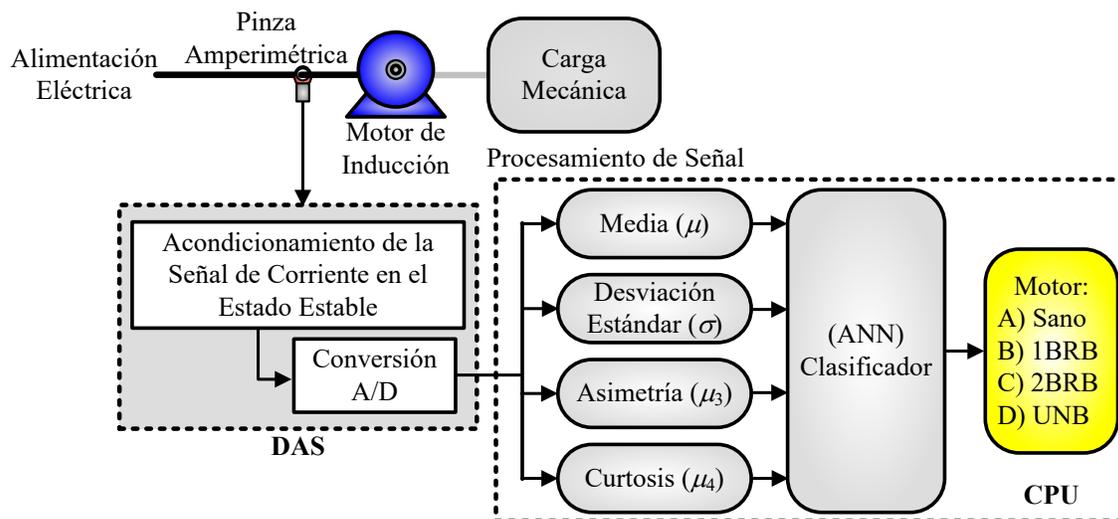


Figura 2. Metodología propuesta para la detección de barras rotas y desbalance mecánico en un motor de inducción.

Experimentación

La Figura 3 muestra el banco de pruebas utilizado para realizar la experimentación y evaluación de la metodología propuesta para la detección de barras rotas y desbalance en un motor de inducción. Se utilizaron 4 motores distintos, uno en estado sano, otro con una barra rota, uno más con dos barras rotas y un cuarto motor con desbalance mecánico; todos ellos de la marca WEG, modelo 00136APE48T, de 1 Hp, con 28 barras y 2 polos. Los motores se conectan a la línea de alimentación de 220 V ca, 60 Hz. La carga mecánica que se aplica es la de un alternador ordinario que representa un cuarto de la carga nominal del motor. La toma de muestras de la señal de corriente de una de las fases de alimentación al motor se efectúa una vez que el motor ha alcanzado su estado estable. La señal de corriente se adquiere utilizando una pinza amperimétrica modelo i200s de la marca Fluke. La señal es convertida de analógico a digital utilizando un convertidor ADS7809, de 16 bits de la compañía Texas Instruments. Se utiliza una frecuencia de muestreo de 1500 Hz para obtener 4096 muestras durante el estado estable; de esta forma se adquiere más allá del décimo armónico de la frecuencia fundamental.

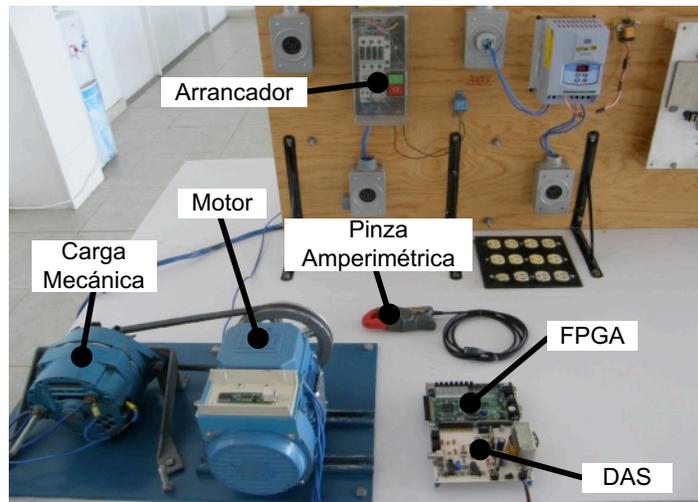


Figura 3. Banco de pruebas utilizado para la validación de la metodología propuesta.

La ruptura de una barra implica una discontinuidad, por lo que no se puede conducir corriente eléctrica entre sus dos secciones. En este trabajo las barras se rompieron de forma artificial taladrando uno (1BRB) y dos (2BRB) orificios de 7.938 mm de diámetro hasta romper completamente las barras sin dañar la flecha del motor. Por otro lado, la condición de desbalance (UNB) se presenta cuando la carga mecánica del motor no está uniformemente distribuida, generando que el centro de masa quede fuera del eje de giro de la flecha del motor. Para generar esta condición, se perforó un orificio de 8mm de diámetro en uno de los brazos de soporte de la polea, donde se colocó un tornillo con dos tuercas por cada lado. La masa agregada genera la condición de desbalance. Las condiciones de falla mecánica generadas artificialmente se muestran en la Figura 4.

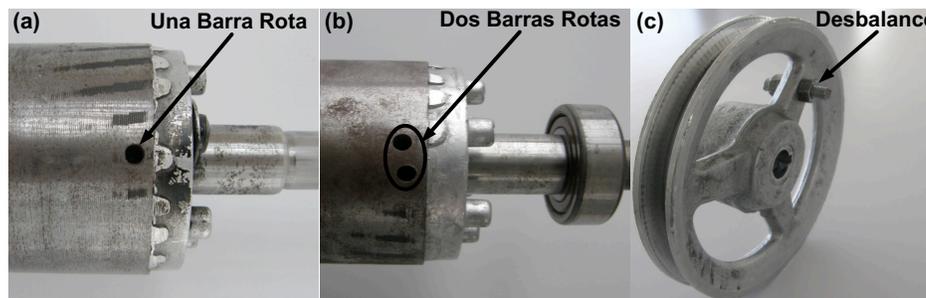


Figura 4. Fallas generadas artificialmente; (a) una barra rota (1BRB); (b) dos barras rotas (2BRB); (c) desbalance mecánico (UNB).

Resultados

La Figura 5 muestra las señales de corriente durante el estado estable para un motor sano, un motor con una barra rota, un motor con dos barras rotas y un motor con desbalance mecánico. Las señales fueron normalizadas y escaladas para abarcar la representación de 16 bits proporcionada por el convertidor analógico a digital. Se adquirió la señal de corriente durante el estado estable de 50 pruebas distintas para un motor sano y la señal de corriente durante el estado estable de 50 pruebas distintas para cada una de las condiciones del motor con falla.

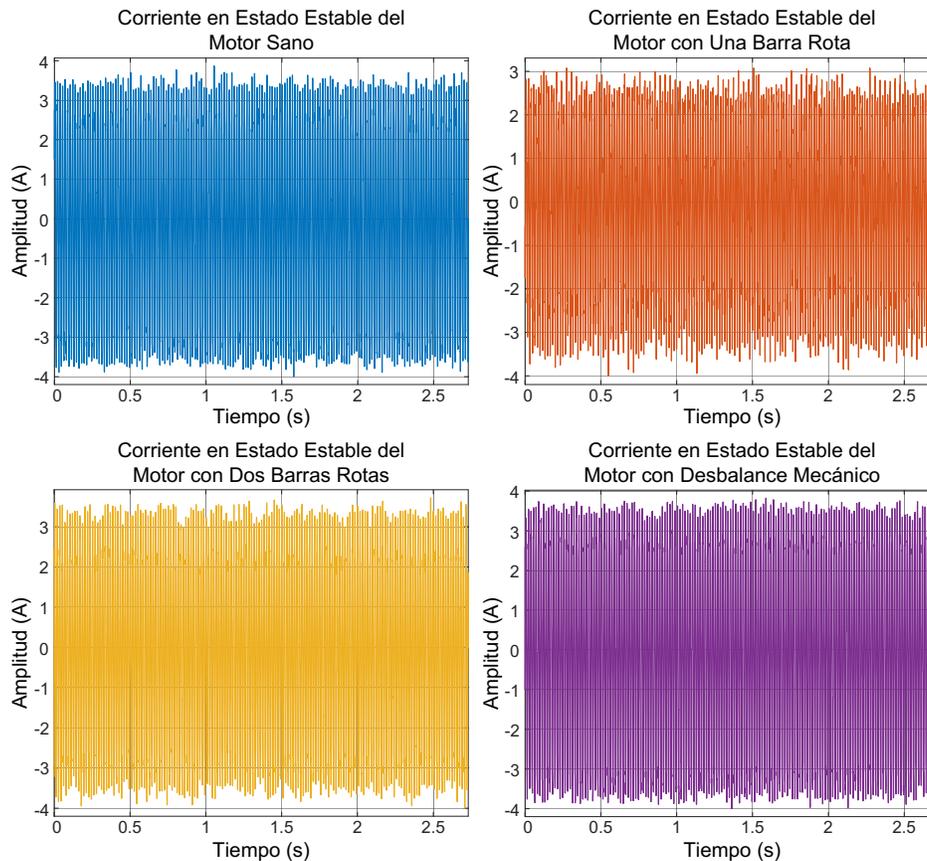


Figura 5 Señales de corriente durante el estado estable para un motor sano, un motor con una barra rota, un motor con dos barras rotas y un motor con desbalance mecánico.

Análisis Estadístico de los Momentos Centrales

Se realizó un análisis estadístico de cada uno de los momentos centrales obtenidos para las señales de corriente de las 50 pruebas realizadas para cada una de las condiciones de operación del motor: sano, una barra rota, dos barras rotas y desbalance mecánico, durante el transitorio de arranque. Se calculó la media (μ) y la desviación estándar (σ) para cada conjunto de datos que contiene los correspondientes valores de los momentos centrales de cada señal de corriente, de acuerdo con las ecuaciones (1) y (2), respectivamente.

Los resultados de los correspondientes análisis estadísticos para cada una de las condiciones de operación del motor de inducción se muestran en la Figura 6; donde es claro que existe un traslape significativo entre las regiones de pertenencia, representadas mediante distribuciones Gaussianas, de cada uno de los momentos centrales en todas las condiciones de operación analizadas; por lo tanto, es indispensable la utilización de un clasificador que ayude a discernir entre las diferentes condiciones de operación recibiendo como entradas los momentos centrales de la señal de corriente analizada.

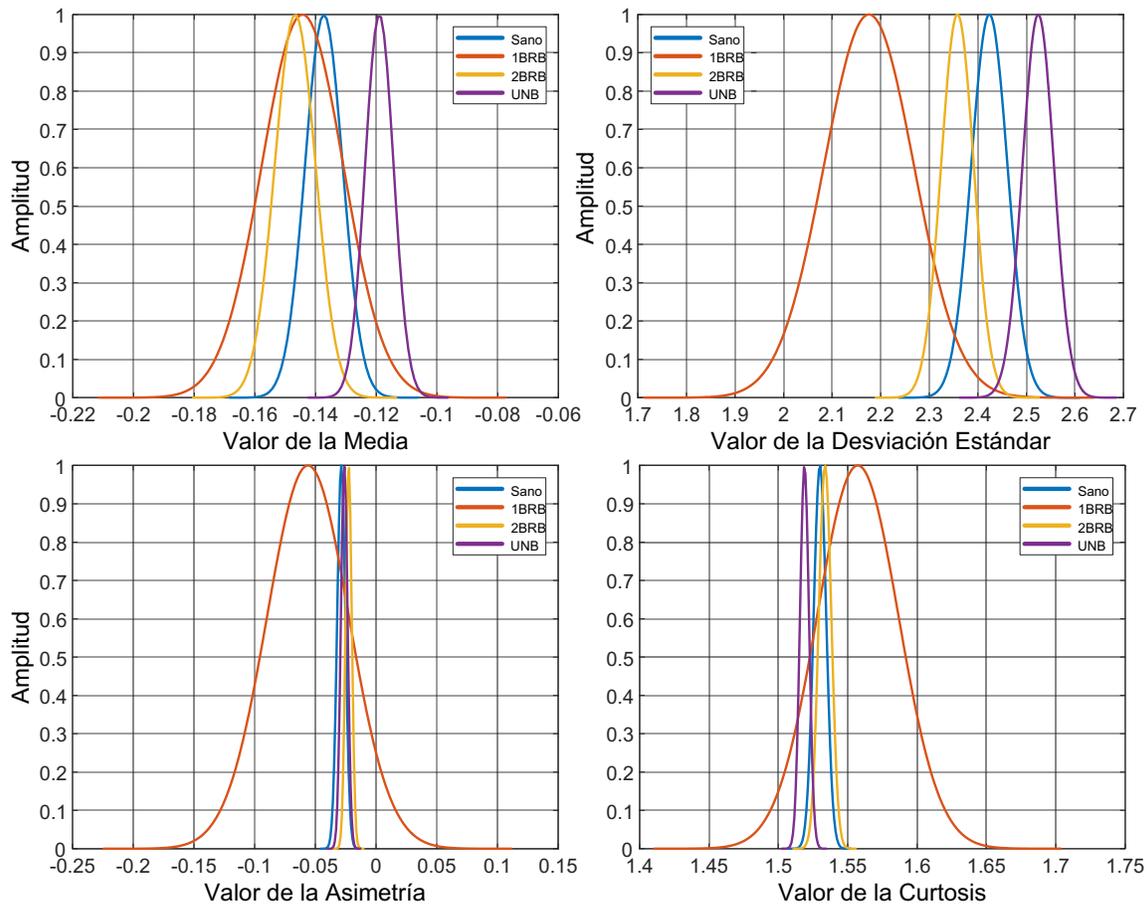


Figura 6 Análisis estadístico de los momentos centrales de la señal de corriente para cada una de las condiciones de operación del motor de inducción consideradas en este estudio.

Detección de Fallas

En la técnica propuesta se utilizó un método de partición (hold-out), donde se realizaron 50 pruebas bajo cada condición de operación. Las primeras 30 pruebas de cada conjunto de datos se utilizaron para entrenar y validar la red neuronal. Las 20 pruebas restantes en cada condición se utilizaron para probar la efectividad del sistema. Las características de la red neuronal implementada son:

- Red neuronal prealimentada (feed-forward) con propagación hacia atrás de errores (backpropagation).
- Algoritmo de entrenamiento de gradiente descendente.
- 4 nodos de entrada, uno por cada momento central, media, desviación estándar, asimetría y curtosis, de la señal de corriente.
- 6 neuronas en la capa oculta con una función de activación sigmoideal logarítmica (Log-sigmoid).
- 4 neuronas en la capa de salida con una función de activación lineal; una por cada condición de operación; Sano, una barra rota (1BRB), dos barras rotas (2BRB) y desbalance mecánico (UNB).

La Figura 7 muestra la matriz de confusión para la validación del entrenamiento de la red neuronal artificial propuesta con una efectividad promedio de 96.7%.

**Matriz de Confusión
Validación**

Cases de Salida	Sano	28 23.3%	0 0.0%	1 0.8%	1 0.8%	93.3% 6.7%
	1BRB	0 0.0%	30 25.0%	0 0.0%	0 0.0%	100% 0.0%
	2BRB	2 1.7%	0 0.0%	29 24.2%	0 0.0%	93.5% 6.5%
	UNB	0 0.0%	0 0.0%	0 0.0%	29 24.2%	100% 0.0%
		93.3% 6.7%	100% 0.0%	96.7% 3.3%	96.7% 3.3%	96.7% 3.3%
	Sano	1BRB	2BRB	UNB		
	Clase Deseada					

Figura 7 Matriz de confusión de la validación del entrenamiento de la red neuronal artificial propuesta.

La Figura 8 muestra la matriz de confusión para la etapa de prueba de la red neuronal artificial propuesta, en la identificación de las distintas condiciones de operación del motor de inducción: Sano, una barra rota (1BRB), dos barras rotas (2BRB) y desbalance mecánico (UNB), con una efectividad promedio de 95%.

**Matriz de Confusión
Prueba**

Casos de Salida	Sano	18 22.5%	0 0.0%	2 2.5%	0 0.0%	90.0% 10.0%
	1BRB	0 0.0%	20 25.0%	0 0.0%	0 0.0%	100% 0.0%
	2BRB	1 1.3%	0 0.0%	18 22.5%	0 0.0%	94.7% 5.3%
	UNB	1 1.3%	0 0.0%	0 0.0%	20 25.0%	95.2% 4.8%
			90.0% 10.0%	100% 0.0%	90.0% 10.0%	100% 0.0%
	Clase Deseada	Sano	1BRB	2BRB	UNB	

Figura 8 Matriz de confusión durante la prueba de la red neuronal artificial propuesta.

De los resultados obtenidos se puede observar que la metodología propuesta para la detección de un motor sano, un motor con una barra rota (1BRB), un motor con dos barras rotas (2BRB) y un motor con desbalance mecánico (UNB) tiene una alta efectividad, alcanzando una certidumbre de al menos 90% durante la identificación de la condición operación del motor de inducción.

Conclusiones

Los motores de inducción representan aproximadamente el 70% del consumo de energía eléctrica en el sector industrial a nivel mundial. La detección temprana de fallas ha atraído la atención de investigadores durante varios años ya que los motores de inducción son un elemento fundamental en la cadena productiva. Por otro lado, la detección de fallas en etapas tempranas es difícil ya que los motores continúan trabajando sin dar algún indicio de daño, y de no ser atendidas oportunamente, pueden ocasionar daños a otros equipos, incrementar los costos de producción e incluso poner en riesgo la integridad física de las personas. En este trabajo se desarrolló un estudio experimental para detectar fallas como barras rotas y desbalance mecánico en motores de inducción mediante el análisis de los 4 momentos centrales estadísticos de la señal de corriente durante el estado estable. Se implementó un clasificador basado en una red neuronal simple, del tipo perceptrón multicapa, que se utilizó para realizar la clasificación de la condición de operación del motor. Los resultados obtenidos demuestran que la metodología propuesta es altamente eficiente detectando y clasificando la condición de operación del motor como sano, con una barra rota, con dos barras rotas o con desbalance mecánico, alcanzando una eficiencia global del 95%. En trabajos posteriores se espera extender el método propuesto para lograr la identificación de otro tipo de fallas como daños en baleros, además de las que ya han sido tratadas en este estudio.

Referencias

- Aguilera, F., de-la-Barrera, P.M., De-Angelo, C.H. & Espinoza-Trejo, D.R. (2016). Current-sensor fault detection and isolation for induction-motor drives using a geometric approach. *Control Engineering Practice*, 53(1), 35-46. <https://doi.org/10.1016/j.conengprac.2016.04.014>.
- Asad, B., Vaimann, T., Belahcen, A., Kallaste, A., Rassolkin, A., Ghafarokhi, P. S., & Kudelina, K. (2021). Transient modeling and recovery of non-stationary fault signature for condition monitoring of induction motors," *Applied Sciences-Basel*, 11(6), 2-17. <https://doi.org/10.3390/app11062806>.
- Chang, Q., Zheng, M., Luo, J., Li, L., Man, J., Shen, Y. & Liu, Y. (2022). Intelligent diagnosis model of traction seat of urban rail vehicle based on Harris Hawks optimization. *Journal of Sensors*, 2022, 2087809: 1-23. <https://doi.org/10.1155/2022/2087809>.
- Deperlioglu, O. & Kose, U. (2011). An educational tool for artificial neural networks. *Computers and Electrical Engineering*, 37(3), 392–402. DOI: <https://doi.org/10.1016/j.compeleceng.2011.03.010>.
- Eriksson, J., Ollila, E., Koivunen, V. (2009). Statistics for complex random variables revisited. *IEEE International Conference on Acoustics, Speech and Signal Processing, Taipei, Taiwan*, 3565–3568. <https://doi.org/10.1109/ICASSP.2009.4960396>.
- Ferreira-de-Souza, D., Marino-Salotti, F. A., Sauer, I. L., Tatizawa, H., Traca-de-Almeida, A. & Gakiya-Kanashiro, A. (2022). A Performance Evaluation of Three-Phase Induction Electric Motors between 1945 and 2020. *Energies*, 15(6), 2002: 1-31. <https://doi.org/10.3390/en15062002>.
- Ferrucho-Alvarez, E. R., Martinez-Herrera, A. L., Cabal-Yepey, E., Rodriguez-Donate, C., Lopez-Ramirez, M. and Mata-Chavez, R. I. (2021). Broken Rotor Bar Detection in Induction Motors through Contrast Estimation. *Sensors*, 21, 7446: 1-14. <https://doi.org/10.3390/s21227446>.
- Grimmett, G. R. & Stirzaker, D. R. (2020). *Probability and random processes*. 4th ed. Oxford University Press, New York, NY, USA.
- Kucuker, A. & Bayrak, M. (2013). Detection of mechanical imbalances of induction motors with instantaneous power signature analysis. *Journal of Electrical Engineering and Technology*, 8(5), 1116-1121. <https://doi.org/10.5370/JEET.2013.8.5.1116>.
- Li, H., Feng, G., Zhen, D., Gu, F. & Ball, A. D. (2020). A normalized frequency-domain energy operator for broken rotor bar fault diagnosis. *IEEE Transactions on Instrumentation and Measurement*, 70:3500110, 1-10. <https://doi.org/10.1109/TIM.2020.3009011>.
- Liu, C., Cichon, A., Krolczyk, G. & Li, Z. (2022). Technology development and commercial applications of industrial fault diagnosis system: a review. *The International Journal of Advanced Manufacturing Technology*, 118(11-12), 3497-3529. <https://doi.org/10.1007/s00170-021-08047-6>.
- Lu, J., Wang, P., Duan, S., Shi, L., & Han, L. (2018). Detection of broken rotor bars fault in induction motors by using an improved MUSIC and least-squares amplitude estimation. *Mathematical Problems in Engineering*, 2018:5942890, 1-13. <https://doi.org/10.1155/2018/5942890>.
- Rafaq, M. S., Faizan-Shaikh, M., Park, Y. & Lee, S. B. (2022). Reliable airgap search coil based detection of induction motor rotor faults under false negative motor current signature analysis indications. *IEEE Transactions on Industrial Informatics*, 18(5), 3276-3285. <https://doi.org/10.1109/TII.2020.3042195>.
- Shin, J., Park, Y. & Lee, S. B. (2021). Flux-based detection and classification of induction motor eccentricity, rotor cage, and load defects. *IEEE Transactions on Industry Applications*, 57(3), 2471-2480. <https://doi.org/10.1109/TIA.2021.3066960>.
- Terron-Santiago, C., Martinez-Roman, J., Puche-Panadero, R. & Sapena-Bano, A. (2021), A review of techniques used for induction machine fault modelling. *Sensors*, 21(14), 4855: 1-18. <https://doi.org/10.3390/s21144855>.