

DetECCIÓN DE FALLAS UTILIZANDO MOMENTOS CENTRALES ESTANDARIZADOS DE LA SEÑAL TRIAXIAL DE VIBRACIÓN DE UN MOTOR DE INDUCCIÓN

Fault Detection through Standardized Central Moments of the Triaxial Vibration Signal from an Induction Motor

Karim Garcia-Cortes¹, Luis Eduardo Guzman-Garcia¹, Daniela Vargas-Sanchez¹, Lorena Yazmin Paniagua-Vera¹, Katia Itzel Alcocer-Aguilar¹, Antonio Mora-Castro¹, Geovanni Hernandez-Gomez¹, Eduardo Cabal-Yepez¹

¹Departamento de Estudios Multidisciplinarios, División de Ingenierías, Campus Irapuato-Salamanca, Universidad de Guanajuato. educabal@ugto.mx¹

Resumen

Los motores de inducción son ampliamente utilizados en el sector industrial debido a que su consumo de energía no grande hasta que se presenta una falla. Dada su importancia, se han desarrollado distintas técnicas para la detección temprana de fallas en motores de inducción, con el fin de aprovechar eficientemente la energía eléctrica que se les suministra. Por lo tanto, en este trabajo se propone una metodología basada en los momentos centrales estandarizados de la señal triaxial de vibraciones de un motor de inducción, y la utilización de una red neuronal artificial como clasificador, para detectar con una gran certidumbre la condición de operación del motor. Los resultados obtenidos experimentalmente demuestran que la técnica propuesta alcanza una certidumbre de más del 98% al identificar un motor sano (HLT) o la presencia de una barra rota (1BB), dos barras rotas (2BB) o desbalance mecánico (UNB) en un motor de inducción.

Palabras clave: Motor de Inducción; señales de vibraciones; momentos centrales estandarizados; detección de fallas; redes neuronales artificiales.

Abstract

Induction motors are widely used in the industrial sector due to their low power consumption, until a fault occurs. Because of their importance, distinct techniques have been proposed for early detection of faults in induction motors to use efficiently the electric power supplied to them. Therefore, in this work, a methodology is proposed, which is based on the standardized central moments of the triaxial vibration signal from an induction motor, and an artificial neural network used as classifier to detect with high certainty the induction motor operational condition. Experimentally obtained results demonstrate that the proposed technique guarantees a certainty higher than 98% on identifying a healthy motor (HLT), the presence of one broken rotor bar (1BB), two broken rotor bars (2BB) or mechanical unbalance (UNB) in an induction motor.

Key words: Induction motors; vibration signals; standardized central moments; fault detection; artificial neural networks.

1. Introducción

Los motores de inducción son utilizados debido a que son económicos, en comparación de otro tipo de máquinas rotativas. Su mantenimiento como instalación es sencilla, además de que el consumo de energía que demandan para su funcionamiento no es tan grande; hasta que se presenta una falla. Desafortunadamente, la detección de fallas en motores de inducción no es sencilla dado las severas circunstancias en las que usualmente trabajan, y a que un motor que presenta una falla trabajará de manera normal, como si éste estuviera totalmente sano, con la única diferencia de que el consumo de energía para su funcionamiento se incrementará, aumentando los costos de operación y producción en el proceso industrial en el que el motor se encuentra trabajando (Aguilera et al. 2016).

Dada la importancia de los motores de inducción en el sector industrial, se han desarrollado distintas técnicas para la detección temprana de fallas. Por ejemplo, Al-Musawi et al. (2020) realizan un monitoreo térmico para detectar e identificar fallas en motores de inducción, aplicando un nuevo modelo de color. Talhaoui et al. (2022) proponen un método basado en lógica difusa para diagnosticar barras rotas, utilizando wavelet packet para detectar e identificar la falla en distintas condiciones de operación. Asimismo, Yi et al. (2022) reportan un método basado en el análisis de la señal de corriente de un motor de inducción asíncrono mediante el uso del algoritmo Ant Lion Optimizer. Namdar et al. (2022) introducen un algoritmo para la detección de fallas entre las bobinas, utilizando un filtro Kalman para extraer la firma de las señales de corriente y voltaje de un motor de inducción. Por otro lado, Misra et al. (2022) detectan barras rotas en un motor de inducción, bajo distintas condiciones de carga, aplicando análisis en el dominio del tiempo, en el dominio de la frecuencia y en el dominio tiempo-frecuencia para extraer características de las señales de vibraciones, que permitan clasificar entre rotores sanos y rotores con barras rotas. A su vez, Lee et al. (2022) desarrollan un sistema para la detección de fallas en baleros, cortocircuito en las bobinas y barras rotas. La técnica se basa en un análisis multiresolución, correlación y selección de características de la firma de corriente de un motor de inducción, así como en redes neuronales artificiales. Alimardani et al. (2023) presentan una metodología para diagnosticar fallas de excentricidades mixtas del rotor, basada en el análisis de señales de vibraciones a través de la transformada rápida de Fourier y la diferencia del promedio sincrónico en el tiempo. Sinha y Das (2023), proponen una técnica basada en el análisis de señales vibraciones a través de un análisis estadístico, para determinar la posición óptima del acelerómetro, y la extracción de distintas características en el dominio del tiempo de las señales de vibraciones para detectar fallas en el estator de un motor de inducción. La importancia de detectar fallas de manera temprana radica en aprovechar de manera eficiente la energía consumida por el proceso industrial en el que el motor se encuentra trabajando y reducir al máximo los daños y las pérdidas que se pudieran generar de llegar a una situación crítica.

En este trabajo de investigación se lleva a cabo un análisis experimental para determinar la factibilidad y efectividad de utilizar los momentos centrales estadísticos estandarizados de la señal de vibración triaxial, proporcionadas por un acelerómetro montado sobre un motor de inducción, durante el estado estable, así como un clasificador basado en una red neuronal artificial para detectar de manera temprana y con una gran efectividad fallas como una barra rota (1BB), dos barras rotas (2BB) y desbalance mecánico (UNB) en el motor de inducción.

2. Marco Teórico

2.1 Señales de Vibraciones

En su forma más sencilla, una vibración se puede considerar como la oscilación o el movimiento repetitivo de un objeto alrededor de una posición de equilibrio. La vibración de un objeto es causada por una fuerza de excitación. Esta fuerza se puede aplicar externamente al objeto o puede tener su origen dentro del objeto. (White,2010). La representación más sencilla de vibración se logra analizando el movimiento que se produce cuando una masa suspendida de un resorte es soltada desde una distancia determinada. Los parámetros característicos de una señal de vibraciones se describen a continuación (Olarte,2010):

- **Desplazamiento:** Indica la cantidad de movimiento que la masa experimenta con respecto a su posición de reposo.
- **Periodo:** Es el tiempo que tarda la masa en realizar un ciclo completo.
- **Frecuencia:** Es el número de ciclos que ocurren en una unidad de tiempo.
- **Velocidad:** Se refiere a la proporción del cambio de posición con respecto al tiempo.
- **Aceleración:** Proporciona la medida del cambio de la velocidad con respecto al tiempo.

En una máquina rotatoria, la firma de las señales de vibraciones se refiere a los valores característicos de los parámetros descritos anteriormente; aunque éstos no se pueden predecir de forma instantánea, la probabilidad de que un valor dado caiga dentro de un cierto rango de amplitudes es predecible en un sentido estadístico. Por ejemplo, la velocidad de vibración puede variar en cualquier momento en una manera aleatoria, alrededor de un valor medio. Suponiendo que la escala de medición está dividida en secciones pequeñas; entonces, la probabilidad estadística de que la velocidad de vibración se encuentre en una sección específica, se puede medir, anotando el tiempo que la señal permanece en cada sección, dividido entre el tiempo de monitoreo total de la señal. (White,2010). Gracias a la medición de los valores característicos de

los parámetros de una señal de vibración en máquinas industriales, se puede determinar si éstas se encuentran funcionando correctamente o no, para poder prevenir y reducir sus fallas.

2.2 Momentos Centrales Estadísticos

En estadística, los momentos centrales son indicadores genéricos de la distribución de probabilidad de una variable aleatoria $X = [x_1, x_2, x_3, \dots, x_N]$, sobre su media $\mu = E(X)$. Pueden calcularse como el valor esperado de una potencia entera positiva de la desviación de la variable aleatoria con respecto a su media, como se muestra en (1).

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

Los momentos centrales de orden superior ($k > 2$) se relacionan con la dispersión y la forma de la distribución.

2.3 Momentos Centrales Estandarizados

Un momento estandarizado de una distribución probabilística es un momento (generalmente un momento central de orden superior) que ha sido normalizado, usualmente por una potencia de la desviación estándar σ , haciendo la escala del momento invariante; de esta forma permitiendo comparar la forma de distintas distribuciones probabilísticas a través de los momentos estandarizados.

2.4 Primer Momento Central (Media)

La media o promedio $m_1(X) = \mu(X)$ de un conjunto de datos $X = [x_1, x_2, x_3, \dots, x_N]$ es una medida de la tendencia central del conjunto de números x_i . Se encuentra al sumar todos los números en el conjunto de datos y dividir el resultado entre el número total de valores en el conjunto N , como se describe en (2).

$$m_1(X) = E(X) = \mu(X) = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

2.4 Segundo Momento Central (Varianza)

La varianza σ^2 es una medida de dispersión que representa la variabilidad de un conjunto de datos numéricos respecto a su media. Un valor pequeño de varianza indica que los valores del conjunto de datos tienden a estar cerca de su media; por otro lado, una varianza alta indica que los puntos de datos están muy separados de la media y entre sí, dispersándose en un rango amplio de valores. La varianza se calcula como se describe a continuación:

$$m_2(X) = \sigma^2(X) = \frac{1}{N} \sum_{i=1}^N [x_i - \mu(X)]^2 \quad (3)$$

2.5 Tercer Momento Central (Asimetría)

La asimetría es aquella que, definido un centro (e.g., media aritmética, mediana, centro de amplitud total, etc.) de una distribución probabilística el cual llamaremos eje de simetría, las dos mitades resultantes no se corresponden la una a la otra. Una distribución asimétrica es aquella que tiene un número de valores a la izquierda de la media diferente de los que tiene a su derecha. En cambio, en una distribución simétrica hay el mismo número de valores a la izquierda y a la derecha de la media. El coeficiente de asimetría, el cual se

usa para definir la asimetría de una distribución sin necesidad de graficarla, más preciso es el de Fisher, definido como:

$$m_3(X) = \gamma(X) = \frac{1}{N} \sum_{i=1}^N \frac{[x_i - \mu(X)]^3}{\sigma^3} \quad (4)$$

2.6 Cuarto Momento Central (Curtosis)

La curtosis (o apuntamiento) es un valor de forma que mide cuán escarpada (aguda) o achatada (plana) está la gráfica de una distribución probabilística. 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. El coeficiente de curtosis se calcula de la siguiente manera:

$$m_4(X) = g(X) = \frac{1}{N} \sum_{i=1}^N \frac{[x_i - \mu(X)]^4}{\sigma^4} \quad (5)$$

2.6 k-ésimo Momento Estandarizado

Se pueden calcular momentos estandarizados de cualquier orden para una distribución probabilística; que como ya se mencionó, estos momentos permiten comparar las características de forma de las distribuciones para distintos conjuntos de datos $X = [x_1, x_2, x_3, \dots, x_N]$. El k -ésimo momento estandarizado se puede calcular mediante la formula:

$$m_k(X) = \frac{1}{N} \sum_{i=1}^N \frac{[x_i - \mu(X)]^k}{\sigma^k} \quad (6)$$

2.7 Redes Neuronales Artificiales

Las redes neuronales artificiales (ANN, *artificial neural networks*) se inspiran en los modelos de neuronas vivas y comunicación de redes (Deperlioglu y Kose, 2011). Son redes interconectadas masivamente a través de un gran número de elementos simples llamados neuronas, los cuales se encargan de procesar información por medio de estados dinámicos como respuesta a entradas externas. En una red multi capa del tipo perceptrón, estos elementos se organizan en capa entrada que recibe la información externa, capa oculta compuesta de las neuronas encargadas de procesar la información, y la capa de salida que proporciona respuestas en forma de predicciones o clasificaciones, como se muestra en la Figura 1. Las neuronas en las capas ocultas y la capa de salida reciben información de entrada de las neuronas en la capa previa; esta información se multiplica por pesos asignados durante el proceso de entrenamiento; posteriormente, el producto de cada multiplicación se suma y el resultado se pasa a las neuronas en la siguiente capa. Las neuronas artificiales utilizan una función de activación a su salida antes de pasar el resultado a las neuronas de la siguiente capa. El proceso de entrenamiento de la red comienza asignando valores aleatorios a los pesos de las conexiones entre neuronas; los cuales se ajustan, en varias iteraciones, considerando la información de entrada con sus correspondientes salidas deseadas.

2.8 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 los tres ejes de vibraciones (A_x , A_y y A_z) del motor de inducción se adquieren durante su estado estable. Las señales son acondicionadas y convertidas en señales digitales en el sistema de adquisición de datos (DAS). Las señales discretas resultantes son procesadas para estimar sus primeros seis momentos centrales estandarizados, utilizando la ecuación (6). La selección de los momentos,

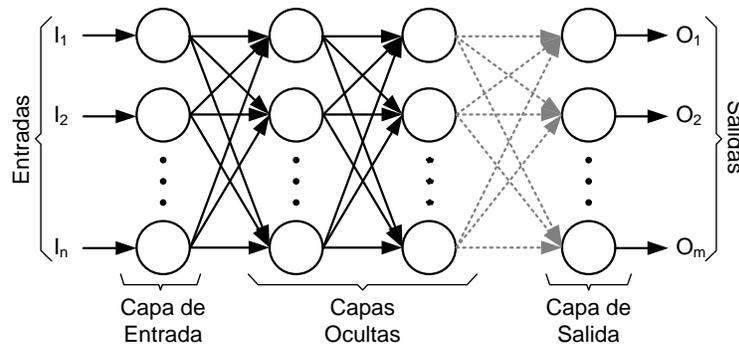


Figura 1. Estructura de una red neuronal artificial del tipo perceptrón multi capa.

utilizados como entrada a la red neuronal artificial (ANN), se realiza solamente una vez, para identificar heurísticamente aquellos momentos centrales que proporcionan la mejor diferenciación entre las distintas condiciones de operación, considerando los tres ejes de vibración del motor de inducción. Finalmente, los momentos centrales seleccionados son utilizados como entradas a un clasificador basado en una ANN del tipo perceptrón, configurada utilizando el software Matlab 2020a, 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).

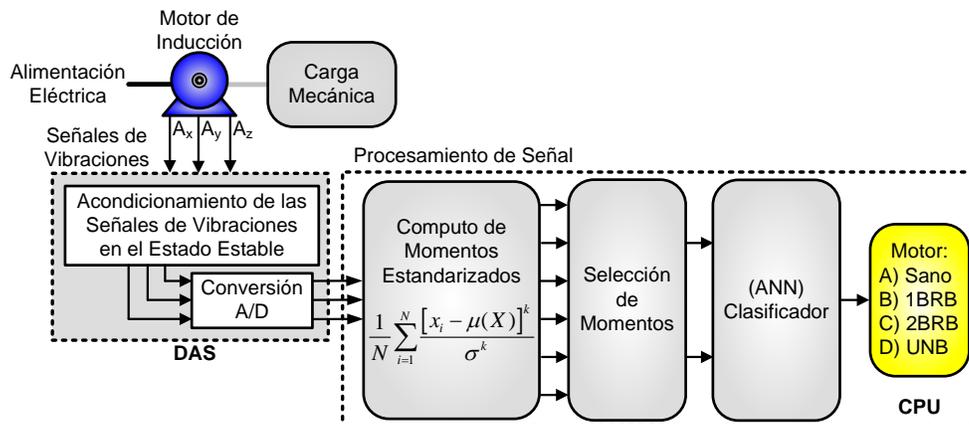


Figura 2. Metodología propuesta para la detección de barras rotas y desbalance mecánico en un motor de inducción, utilizando señales de vibraciones.

3. 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 las señales de vibraciones se efectúa una vez que el motor ha alcanzado su estado estable. Las señales de vibraciones se adquieren utilizando un acelerómetro triaxial de tipo MEMS modelo LIS3L02ASA del fabricante STMicroelectronics. Las señales son convertidas de analógico a digital utilizando un convertidor ADS7841, de 12 bits de la compañía Texas Instruments. Se utiliza una frecuencia de muestreo de 1500 Hz para obtener 4096 muestras durante el estado estable, en cada eje de vibración (A_x , A_y y A_z); de esta forma se adquiere más allá del décimo armónico de la frecuencia fundamental.

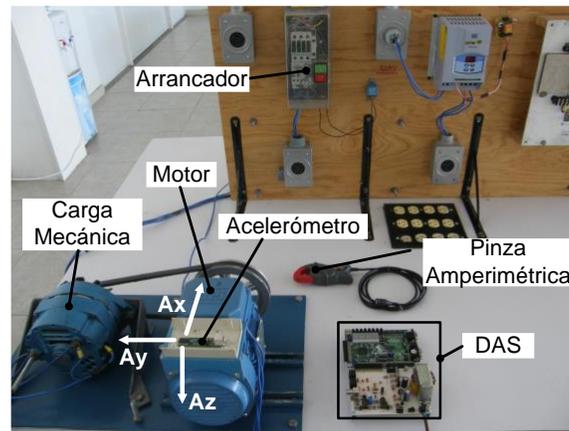


Figura 3. Banco de pruebas utilizado para la validación de la metodología propuesta.

La ruptura de una barra implica una discontinuidad que impide el flujo de corriente eléctrica entre sus dos secciones. En este trabajo, las barras se rompieron de forma artificial, taladrando el rotor con uno (1BB) y dos (2BB) 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 patea, 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.

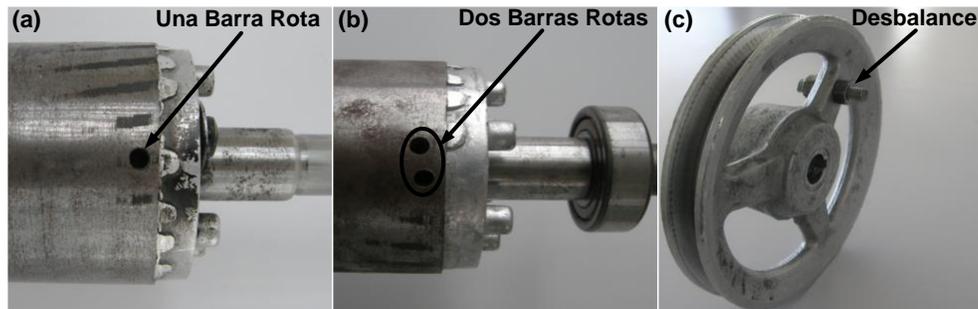


Figura 4. Fallas generadas artificialmente; (a) una barra rota (1BB); (b) dos barras rotas (2BB); (c) desbalance mecánico (UNB).

4. Resultados

La Figura 5 muestra 4 ejemplos representativos de las señales de vibraciones 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 12 bits proporcionada por el convertidor analógico a digital. Se adquirieron las señales de vibraciones durante el estado estable de 40 pruebas distintas para un motor sano y la señal de vibraciones durante el estado estable de 40 pruebas distintas para cada una de las condiciones del motor con falla.

4.1 Análisis Estadístico de los Momentos Centrales Estandarizados

Se realizó un análisis estadístico de cada uno de los momentos centrales obtenidos para las señales de vibraciones de las 40 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 calcularon la media (μ) y la desviación estándar (σ), de acuerdo con las ecuaciones (1) y (2), respectivamente, para cada

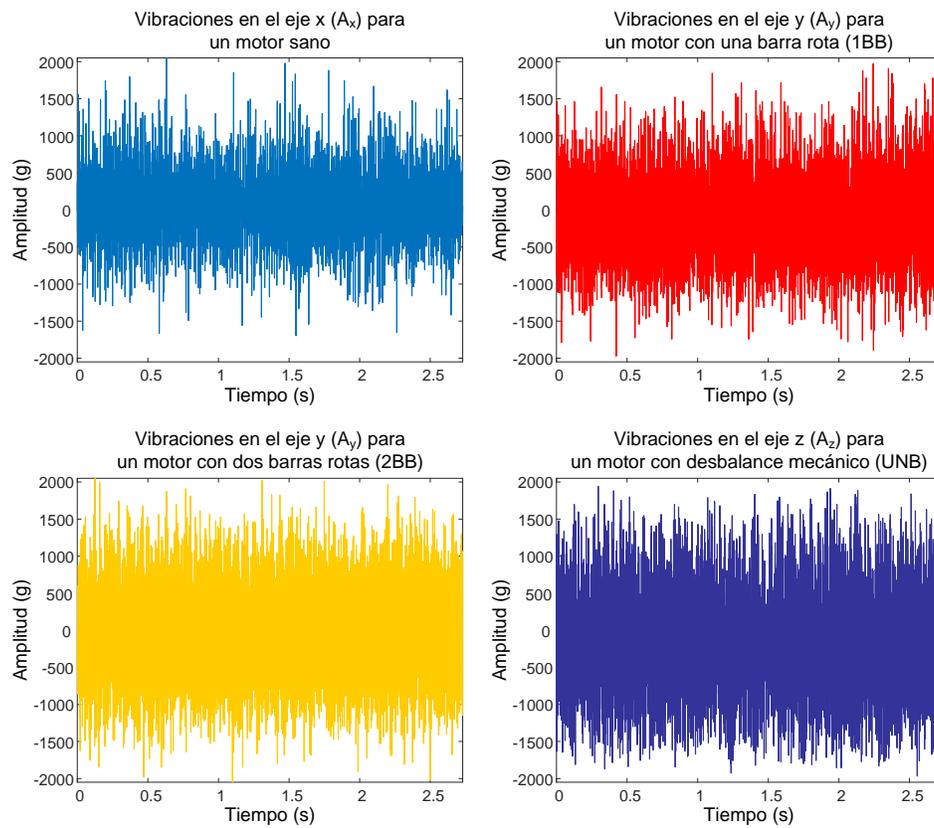


Figura 5. Señales de vibraciones durante el estado estable para un motor sano (eje x), un motor con una barra rota (eje y), un motor con dos barras rotas (eje y) y un motor con desbalance mecánico (eje z).

conjunto de datos que contienen los correspondientes valores de los momentos centrales estandarizados de cada señal de vibraciones en los tres ejes (A_x , A_y , A_z).

La Figura 6 muestra 4 ejemplos representativos de los resultados obtenidos del análisis estadístico para cada una de las condiciones de operación del motor de inducción, en cada uno de sus tres ejes de vibraciones; donde es claro que existe un traslape significativo entre las regiones de pertenencia, representadas mediante distribuciones Gaussianas, de cada uno de los momentos centrales estandarizados en todas las condiciones de operación analizadas; por lo tanto, es indispensable seleccionar los momentos centrales, de los ejes de vibraciones adecuados, que permitan identificar entre las diferentes condiciones de operación (e.i., sano, una barra rota, dos barras rotas o desbalance mecánico) del motor de inducción a través de un clasificador que reciba como entradas los momentos centrales seleccionados, de las correspondientes señales de vibraciones.

De las 18 gráficas resultantes de las distribuciones Gaussianas, para los 6 momentos centrales estandarizados de las tres señales de vibraciones (A_x , A_y y A_z), se observa, a través de un análisis heurístico, que el segundo momento (m_2) de la señal de vibraciones en el eje y (A_y) y el sexto momento (m_6) de la señal de vibraciones en el eje z (A_z), ofrecen una discriminación adecuada que permite identificar con gran certidumbre entre las diferentes condiciones de operación del motor de inducción, utilizando un clasificador basado en una red neuronal artificial (ANN).

4.2 Detección de Fallas

En la técnica propuesta se utilizó un método de partición (hold-out), donde se realizaron 40 pruebas bajo cada condición de operación. Las primeras 20 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:

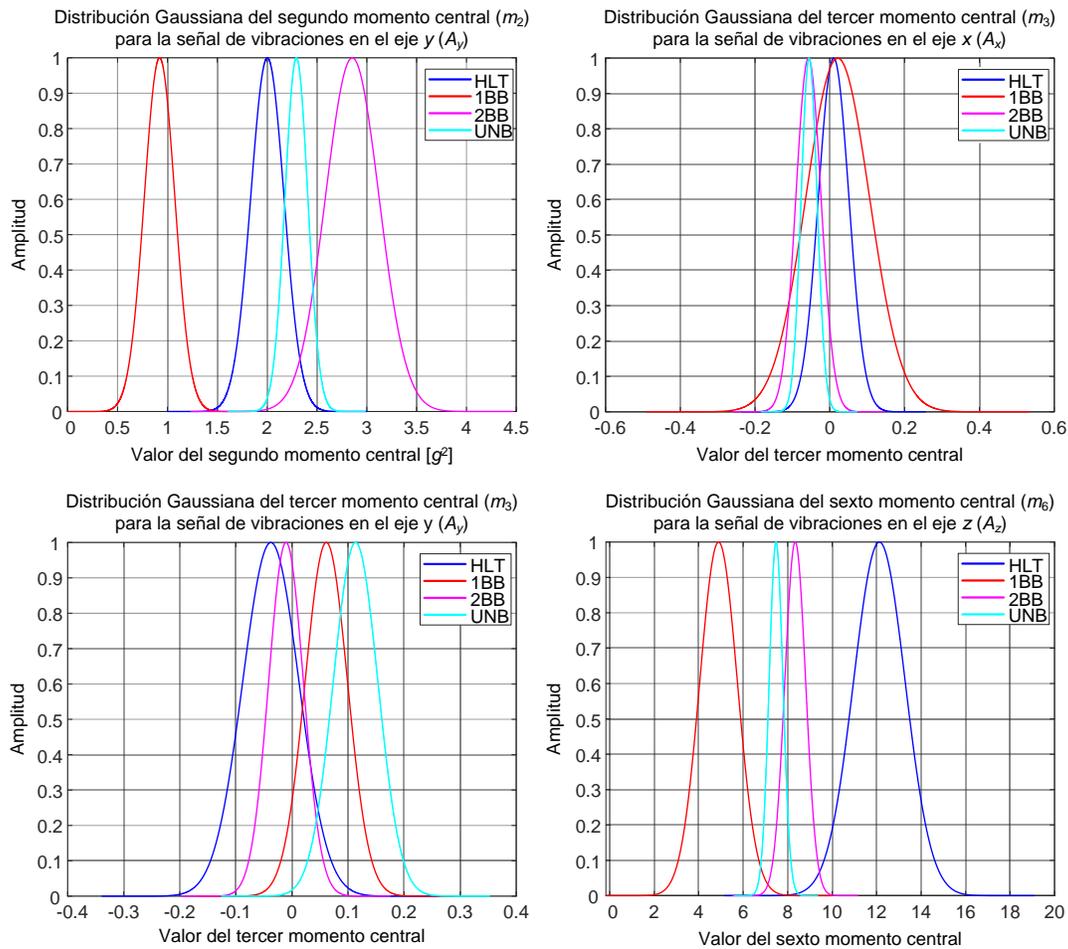


Figura 6. Análisis estadístico de los momentos centrales estandarizados de las señales de vibraciones para las distintas condiciones de operación del motor de inducción consideradas en este estudio.

- Red neuronal prealimentada (feed-forward) con propagación hacia atrás de errores (backpropagation).
- Algoritmo de entrenamiento de gradiente descendente.
- 2 nodos de entrada, uno por cada momento central, segundo momento (m_2) de la señal de vibraciones en el eje y (A_y) y el sexto momento (m_6) de la señal de vibraciones en el eje z (A_z).
- 5 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 (HLT), una barra rota (1BB), dos barras rotas (2BB) 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 97.5%.

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 (HLT), una barra rota (1BB), dos barras rotas (2BB) y desbalance mecánico (UNB), con una efectividad promedio de 98.8%.

De los resultados obtenidos se puede observar que la metodología propuesta para la detección de un motor sano (HLT), un motor con una barra rota (1BB), un motor con dos barras rotas (2BB) y un motor con desbalance mecánico (UNB) tiene una alta efectividad, alcanzando una certidumbre de más del 98% durante la identificación de la condición operación del motor de inducción.

**Matriz de Confusión
Validación**

Clases de Salida	HLT	20 25.0%	0 0.0%	1 1.2%	0 0.0%	95.2% 4.8%
	1BB	0 0.0%	20 25.0%	0 0.0%	0 0.0%	100% 0.0%
	2BB	0 0.0%	0 0.0%	18 22.5%	0 0.0%	100% 0.0%
	UNB	0 0.0%	0 0.0%	1 1.2%	20 25.0%	95.2% 4.8%
		100% 0.0%	100% 0.0%	90.0% 10.0%	100% 0.0%	97.5% 2.5%
	HLT	1BB	2BB	UNB		
	Clase Deseada					

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

**Matriz de Confusión
Prueba**

Clases de Salida	HLT	20 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	1BB	0 0.0%	20 25.0%	0 0.0%	0 0.0%	100% 0.0%
	2BB	0 0.0%	0 0.0%	20 25.0%	1 1.2%	95.2% 4.8%
	UNB	0 0.0%	0 0.0%	0 0.0%	19 23.8%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	95.0% 5.0%	98.8% 1.2%
	HLT	1BB	2BB	UNB		
	Clase Deseada					

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

5. Conclusiones

La detección de fallas en los motores de inducción ha estado en el interés de los investigadores por varios años debido a que son ampliamente utilizados en el sector industrial. Por este motivo, en los últimos años se han propuesto distintas técnicas para la detección temprana de fallas en este tipo de máquinas rotatorias, con la finalidad de hacer un uso eficiente de la energía eléctrica que se les suministra. En este trabajo, se realizó un estudio experimental sobre la utilización de los momentos centrales estandarizados de la señal triaxial de vibraciones de un motor de inducción y una red neuronal artificial como clasificador para detectar si el motor está sano (HLT), tiene una barra rota (1BB), dos barras rotas (2BB) o desbalance mecánico (UNB). La validación práctica de la metodología propuesta mostró que el segundo momento (m_2) de la señal de vibraciones en el eje y (A_y) y el sexto momento (m_6) de la señal de vibraciones en el eje z (A_z), son suficientes para realizar una distinción muy confiable, con una certidumbre mayor al 98%, entre las condiciones de operación del motor de inducción descritas anteriormente, durante su estado estable.

6. Bibliografía/Referencias

1. 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>.
2. Alimardani, R., Rahideh A. & Hedayati-kia, S. (2023). Mixed Eccentricity Fault Detection for Induction Motors based on Time Synchronous Averaging of Vibration Signals. *IEEE Transactions on Industrial Electronics*, (Early Access). <https://doi.org/10.1109/TIE.2023.3266589>.
3. Al-Musawi, A.K., Anayi, F., Packianather, M. (2020). Three-phase induction motor fault detection based on thermal image segmentation. *Infrared Physics & Technology*, 104, 103140. <https://doi.org/10.1016/j.infrared.2019.103140>.
4. Deperlioglu, O. & Kose, U. (2011). An educational tool for artificial neural networks. *Computers and Electrical Engineering*, 37(3), 392–402. <https://doi.org/10.1016/j.compeleceng.2011.03.010>.
5. Lee, C.-Y., Wen, M.-S., Zhuo, G.-L., & Le, T.-A. (2022). Application of ANN in Induction-Motor Fault-Detection System Established with MRA and CFFS. *Mathematics*, 10(13), 2250. <https://doi.org/10.3390/math10132250>.
6. Misra, S., Kumar, S., Sayyad, S., Bongale, A., Jadhav, P., Kotecha, K., Abraham, A., et al. (2022). Fault Detection in Induction Motor Using Time Domain and Spectral Imaging-Based Transfer Learning Approach on Vibration Data. *Sensors*, 22(21), 8210. <https://doi.org/10.3390/s22218210>.
7. Namdar, A., Samet, H., Allahbakhshi, M., Tajdinian, M., & Ghanbari, T. (2022). A robust stator inter-turn fault detection in induction motor utilizing Kalman filter-based algorithm. *Measurement*, 187, 110181. <https://doi.org/10.1016/j.measurement.2021.110181>.
8. Olarte, C., Botero, A. & Canon, Z. (2010). Análisis De Vibraciones: Una Herramienta Clave En El Mantenimiento Predictivo. Google académico. <https://www.redalyc.org/pdf/849/84917249040.pdf>
9. Sinha, A. & Das, D. (2023). Machine Learning-based Explainable Stator Fault Diagnosis in Induction Motor using Vibration Signal. In *Proc. IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, Kuala Lumpur, Malaysia, 1-6, <https://doi.org/10.1109/I2MTC53148.2023.10175931>.
10. Talhaoui, H., Ameid, T., Aissa, O. & Kessal, A. (2022). Wavelet packet and fuzzy logic theory for automatic fault detection in induction motor. *Soft Computing*, 26(1), 11935–11949. <https://doi.org/10.1007/s00500-022-07028-5>.
11. White, G. (2010). Introducción al Análisis de Vibraciones. Google Académico. <https://termogram.com/images/pdf/analisis-vibraciones/introduccion-al-analisis-de-vibraciones-azima-dli.pdf>.
12. Yi, L., Xu, X., Zhao, J. Duan, R. Guo, Y. Sun, T. (2022). Fault Detection of Induction Motor Based on ALO Optimized TKSVDD. *Journal of Electrical Engineering & Technology*, 17(1), 381–393. <https://doi.org/10.1007/s42835-021-00883-6>.