

## DetECCIÓN DE FALLAS DE ROTOR EN MOTORES DE INDUCCIÓN MEDIANTE ESTIMACIÓN DE CONTRASTE

### Rotor Fault Detection in Induction Motors Through Contrast Estimation

Edna Rocío Ferrucho Álvarez<sup>1</sup>

<sup>1</sup>Universidad de Guanajuato, División de Ingenierías, Departamento de Estudios Multidisciplinarios.  
er.ferruchoalvaez@ugto.mx

#### Resumen

Los motores de inducción son máquinas eléctricas de gran utilidad para la industria. Su uso en esta, ha incrementado debido a su robustez y bajo costo. Sin embargo, debido a múltiples factores, estas máquinas pueden desarrollar diferentes tipos de fallas asociadas al rotor. En el presente trabajo se propone el diseño de una metodología novedosa para la detección y clasificación de algunos tipos de fallas en motores de inducción de rotor tipo jaula de ardilla y de rotor devanado. Dicha metodología estaba basada en la estimación de una característica de textura de la señal de corriente de alimentación, para este caso contraste. Posteriormente se diseña una red neuronal artificial para la clasificación de cada uno de los estados de la máquina. Los resultados obtenidos presentan alta efectividad en la detección de fallas en rotor de ambos tipos de máquinas.

**Palabras clave:** Motor de inducción; rotor bobinado; rotor jaula de ardilla; corriente; contraste; red neuronal artificial.

#### Introducción

Los Motores de Inducción son máquinas eléctricas encargadas de transformar energía eléctrica en energía mecánica o viceversa si se usan como motor o como generador respectivamente. Actualmente, son el tipo de máquina eléctrica más utilizada en la industria debido a su robustez, bajo costo (Mohammed et al., 2006), además de ser máquinas fiables y eficientes. Aproximadamente el 90% de los motores actualmente utilizados en la industria son Motores de Inducción, con una capacidad de consumo del 50% de la energía generada en un país industrializado (Puche-Panadero et al., 2009). Este tipo de motores se clasifica de acuerdo a la construcción del rotor como motores de inducción de rotor tipo jaula de ardilla y motores de inducción de rotor devanado. Debido a su alto uso, ambos tipos de motores pueden presentar diferentes tipos de estrés como estrés eléctrico, mecánico, térmico y medioambiental (Nakamura et al., 2006) trayendo como consecuencias paradas de producción, daño de sistemas asociados, y en el peor caso, daño total de la máquina; el resultado directo de lo anteriormente mencionado es las pérdidas económicas generadas. El motor de inducción tipo jaula de ardilla es actualmente el tipo de accionamiento mecánico comúnmente más usado para diferentes aplicaciones tanto industriales como domésticas (Hassan et al., 2018). Las fallas de barras rotas de rotor abarcan entre un 10% y 20% (Wang et al., 2021) de las fallas totales que se pueden presentar en el motor. Dicha falla puede iniciar desde un estado incipiente y evolucionar hasta un estado devastador, aun cuando la máquina se encuentra en funcionamiento. Por otra parte, los motores de inducción de rotor devanado son ampliamente utilizados en sistemas de energía eólica (Abdel-Wahab et al., 2016). Este tipo de motores, debido a su construcción, puede presentar fallas de pérdidas de fase en el rotor (Henao et al., 2005). Como consecuencia de las fallas en los rotores de motores de inducción, señales de baja frecuencia son añadidas a la señal sinusoidal de corriente que alimenta el mismo. Numerosas metodologías han sido diseñadas para la detección y diagnóstico en ambas construcciones de motores de inducción. Muchas de estas metodologías se basan en el análisis de señales de corriente de alimentación en el dominio de la frecuencia durante el estado transitorio de arranque (Ibrahim et al., 2018; Vedreno-Santos et al., 2014; Garcia-Bracamonte et al., 2019; Abd-el-Malek et al., 2018), dejando de lado el hecho de que las máquinas de inducción permanecen mayor parte del tiempo en funcionamiento constante.



En el presente trabajo, se propone una metodología novedosa basada en el análisis de corriente de alimentación, en estado estable para la detección de barras rotas de rotor en motores de inducción tipo jaula de ardilla, y detección de fases de rotor abierta en motores de inducción de rotor devanado. La metodología propuesta se basa en una extrapolación del análisis de características de textura, normalmente aplicadas a imágenes. Para este caso la característica analizada es contraste. Posteriormente se diseña una red neuronal artificial para la clasificación eficaz de cada uno de los estados de los motores. Los resultados demuestran alta efectividad en la detección y clasificación de fallas de rotor.

## Metodología Propuesta

### Análisis de corriente

La base teórica para el análisis de la señal de corriente del motor está basada en la influencia que tiene una falla presente en el rotor sobre el flujo magnético del mismo. El flujo magnético del rotor está directamente relacionado con el flujo del estator, el cual es generado por la corriente de alimentación. Como consecuencia la falla se verá reflejada en dicha corriente. El análisis de la señal de corriente eléctrica es la técnica más utilizada en el mantenimiento predictivo para detectar y diagnosticar los fallos de los motores de inducción debido a su naturaleza no invasiva (Jung et al., 2006). Su esencia consiste en adquirir y analizar una o varias fases de la señal de corriente eléctrica suministrada al estator del motor de inducción.

### Estimación de contraste

El contraste es comúnmente utilizado para el análisis de textura en el procesamiento de imágenes, sin embargo, su procesamiento no se limita a 2D, sino que es posible estimar el contraste de señales de 1D. Está definido desde una acepción de perspectiva, como la diferencia de tonalidad con la que se registran, perciben o reproducen un par de puntos, uno blanco (255) y uno negro (0). Robert Haralick (Haralick et al., 1973) propone una definición de contraste, basada en matrices de coocurrencia  $P_{ij}$ . La información de textura de una señal  $I$  está detallada por la matriz de frecuencias relativas  $P_{ij}$  en la cual dos celdas de resolución vecinas están separadas por la distancia  $d$  en la señal, una con tono de nivel gris  $i$  otra con tono de nivel de gris  $j$ . Tales matrices son función de la relación angular entre las celdas de resolución vecinas, así como la distancia entre ellas. El análisis entre celdas de resolución vecinas aplicado a una señal 1D para obtener la matriz de coocurrencia, puede ser aplicado únicamente con un ángulo de análisis entre celdas de  $0^\circ$  por su naturaleza horizontal. La matriz de coocurrencia se define como se presenta en la Ec. 1.

$$P(i, j, d, 0^\circ) = \#\{(k, l), (m, n) \in L_x \mid k - m = 0, |l - n| = d\} \quad \text{Ec. 1}$$

Donde  $\#$  denota el número de elementos en el conjunto,  $L_x$  el dominio espacial horizontal y  $(k, l), (m, n)$  las coordenadas de la pareja de celdas analizadas.

La definición de contraste está dada por:

$$F_{cont} = \sum_{n=0}^{N_g-1} n^2 * \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \right\}, |i - j| = n \quad \text{Ec. 2}$$

Donde  $p(i, j)$  hace referencia a la matriz de coocurrencia normalizada

Michel Unser (Unser, 1986) propone una alternativa a las matrices de coocurrencia basada en la estimación de funciones de probabilidad de primer orden, llamada histogramas de diferencias. Los histogramas diferencia con los parámetros  $(d_1, d_2)$  sobre el dominio una señal  $I$  se definen de una manera muy similar a la coocurrencia del nivel de gris espacial como se muestra en la Ec. 3 para el histograma de diferencias:

$$h_d(j; d_1, d_2) = h_d(j) = \text{Card} \{(k, l) \in I, d_{k,l} = j\} \quad \text{Ec. 3}$$

La diferencia no normalizada, asociada con el desplazamiento relativo  $(d_1, d_2)$ , se definen como se muestra en la Ec. 4:

$$d_{k,l} = I_{k,l} - I_{k+d_1, l+d_2} \quad \text{Ec. 4}$$

Donde los valores de  $k$  y  $k + d_1$  deben ser igualados a 1 por la naturaleza horizontal de la señal para este caso. La definición de contraste está dada por:

$$F_{cont} = \sum_j j^2 \times \widehat{P}_d(j) \quad \text{Ec. 5}$$

Donde  $\widehat{P}_d(j)$  representa el histograma de diferencias normalizado

### Redes Neuronales Artificiales

Las redes neuronales artificiales se han convertido en una herramienta eficaz para problemas de clasificación. La Figura 1 muestra el diseño básico de una red neuronal con dos capas donde cada neurona produce un número único. Las entradas de cada neurona se multiplican por los pesos correspondientes y se suman. A la salida de cada neurona se agrega un nivel de sesgo y posteriormente se transforma mediante una función de activación no lineal. La arquitectura de perceptrón multicapa es usada para el presente trabajo, la cual presenta un modelo feed-forward compuesto por una capa de entrada, una o más capas internas y una capa de salida. El número de capas internas y de neuronas en cada capa se determina con base en el problema de clasificación.

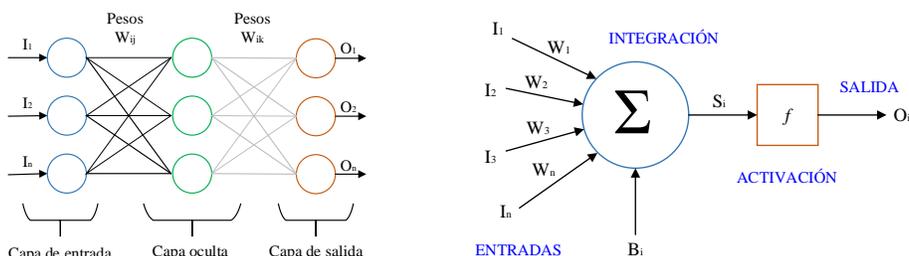


Figura 1. Diseño básico de una red neuronal artificial perceptrón multicapa.

### Resultados y conclusiones

Para el presente trabajo se utilizan las señales de corriente adquiridas de motores tipo jaula de ardilla de 1 HP, con dos polos y 28 barras. Estos reciben una alimentación de 220 V ac a 60 Hz. Para este tipo de motor de inducción se adquieren las señales bajo 3 condiciones: Sano (HLT), una barra rota (1BB), y dos barras rotas (2BB). Además de las señales de corriente de un motor de rotor devanado de 1430 rpm, 90 W, 380 V y 50 Hz también son adquiridas. Las condiciones del motor de inducción de rotor devanado son: Sano (HLT) y una fase de rotor abierta (1ORP). Para cada una de las condiciones, 60 muestras son obtenidas. Las señales de corriente deben ser escaladas a niveles de gris entre 0 y 255 mediante una transformación lineal. Una vez transformadas las señales en niveles de gris, se obtiene el valor de contraste correspondiente para cada señal, bajo las dos definiciones de contraste propuestas. Dos redes neuronales artificiales de arquitectura feed-forward son diseñadas. Cada una para un tipo de motor diferente. Para la red neuronal del motor de inducción tipo jaula de ardilla, la capa de entrada cuenta con dos neuronas. Cada una está compuesta por los valores de contraste de una definición bajo las tres condiciones de adquiridas, HLT, 1BB y 2BB. De igual forma, la red neuronal para el motor de inducción de rotor devanado, cuenta con 2 neuronas en la capa de entrada, que están compuestas por los valores de contraste de cada definición bajo las dos condiciones del motor obtenidas: HLT y 1ORP. Como se mencionó anteriormente, de cada estado del motor se obtienen 60 pruebas. Mediante el método de evaluación de datos Hold-on se utilizan 40 pruebas para el entrenamiento de la metodología y 20 para la evaluación de la misma. Los resultados son presentados en matrices de confusión a continuación.

**Tabla 1.** Matriz de confusión HLT-1BB-2BB

		CLASIFICACIÓN		
		HLT	1BB	2BB
DATOS ACTUALES	HLT	20	0	0
	1BB	0	20	0
	2BB	0	0	20

**Tabla 2.** Matriz de confusión HLT-1ORP

		CLASIFICACIÓN	
		HLT	1ORP
DATOS ACTUALES	HLT	20	0
	1ORP	0	20

Los resultados obtenidos muestran la efectividad de la metodología, donde se obtiene 100% en la clasificación de las fallas para cada uno de los motores de inducción. Al realizar una comparación, se puede observar que la estimación del contraste como parámetro de identificación de falla, presenta resultados satisfactorios, además es una metodología de bajo costo computacional dado que el análisis de las corrientes de alimentación de cada uno de los motores, se lleva a cabo en el dominio del tiempo. Al ser una metodología de bajo costo computacional, puede ser gran candidata a implementación para monitoreo on-line.

## Referencias

- Abdel-Wahab, R. R., Abdo, T. M., & Hanafy, H. H. (2016). Performance analysis of wound rotor induction motor subjected to rotor windings asymmetry. *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*, 1721–1726. <https://doi.org/10.1109/IECON.2016.7793454>
- García-Bracamonte, J. E., Ramírez-Cortés, J. M., de Jesús Rangel-Magdaleno, J., Gómez-Gil, P., Peregrina-Barreto, H., & Alarcon-Aquino, V. (2019). An Approach on MCSA-Based Fault Detection Using Independent Component Analysis and Neural Networks. *IEEE Transactions on Instrumentation and Measurement*, 68(5), 1353–1361. <https://doi.org/10.1109/TIM.2019.2900143>
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Hassan, O. E., Amer, M., & Abdelsalam, A. K. (2018). Induction Motor Broken Rotor Bar Fault Detection Techniques Based on Fault Signature Analysis. *IET Electric Power Applications*, 12(7), 895–907. <https://doi.org/10.1049/iet-epa.2018.0054>
- Henao, H., Martis, C., & Gapolino, G. A. (2005). Analytical approach of the frequency response for the wound rotor induction machine for diagnosis purpose. *2005 5th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, 1–6. <https://doi.org/10.1109/DEMPED.2005.4662535>
- Ibrahim, R. K., Watson, S. J., Djurovic, S., & Crabtree, C. J. (2018). An Effective Approach for Rotor Electrical Asymmetry Detection in Wind Turbine DFIGs. *IEEE Transactions on Industrial Electronics*, 65(11), 8872–8881. <https://doi.org/10.1109/TIE.2018.2811373>



- Jung, J.-H., Lee, J.-J., & Kwon, B.-H. (2006). Online Diagnosis of Induction Motors Using MCSA. *IEEE Transactions on Industrial Electronics*, 53(6), 1842–1852. <https://doi.org/10.1109/TIE.2006.885131>
- Mohammed, O. A., Abed, N. Y., & Ganu, S. (2006). Modeling and Characterization of Induction Motor Internal Faults Using Finite-Element and Discrete Wavelet Transforms. *IEEE Transactions on Magnetics*, 42(10), 3434–3436. <https://doi.org/10.1109/TMAG.2006.879091>
- Nakamura, H., Yamamoto, Y., & Mizuno, Y. (2006). Diagnosis of electrical and mechanical faults of induction motor. *2006 IEEE Conference on Electrical Insulation and Dielectric Phenomena*, 521–524. <https://doi.org/10.1109/CEIDP.2006.311984>
- Puche-Panadero, R., Pineda-Sanchez, M., Riera-Guasp, M., Roger-Folch, J., Hurtado-Perez, E., & Perez-Cruz, J. (2009). Improved Resolution of the MCSA Method Via Hilbert Transform, Enabling the Diagnosis of Rotor Asymmetries at Very Low Slip. *IEEE Transactions on Energy Conversion*, 24(1), 52–59. <https://doi.org/10.1109/TEC.2008.2003207>
- Unser, M. (1986). Sum and Difference Histograms for Texture Classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(1), 118–125. <https://doi.org/10.1109/TPAMI.1986.4767760>
- Vedreno-Santos, F., Riera-Guasp, M., Henao, H., Pineda-Sanchez, M., & Puche-Panadero, R. (2014). Diagnosis of Rotor and Stator Asymmetries in Wound-Rotor Induction Machines Under Nonstationary Operation Through the Instantaneous Frequency. *IEEE Transactions on Industrial Electronics*, 61(9), 4947–4959. <https://doi.org/10.1109/TIE.2013.2288192>
- Wang, W., Song, X., Liu, G., Chen, Q., Zhao, W., & Zhu, H. (2021). Induction Motor Broken Rotor Bar Fault Diagnosis Based on Third-Order Energy Operator Demodulated Current Signal. *IEEE Transactions on energy conversion*, 8.

