

Clasificación de estados operativos en motores de inducción utilizando el algoritmo Random Forest

Martín. P. Puertaz ^{a*}, Manuel A. Mazzoletti ^a

^a LIDEE – Facultad de Ingeniería, UNaM

e-mails: martin.puertaz@fio.unam.edu.ar, amazzoletti@fio.unam.edu.ar

Resumen

En este trabajo se presenta la validación experimental del estado de funcionamiento de un motor de inducción (MI) trifásico con un cortocircuito entre espiras (CEE) en sus bobinados. Este tipo de avería produce un rápido deterioro del aislamiento de los conductores si no es detectada en su etapa temprana. Con el fin de evitar las fallas de mayor gravedad se realiza la clasificación de patrones de funcionamiento aplicando el algoritmo de Random Forest. Este algoritmo permite clasificar entre los estados de funcionamiento normal y con avería a partir de las corrientes instantáneas medidas en bornes de un motor de 2 Hp. Se demuestra que el algoritmo de Random Forest es una buena herramienta para clasificar los estados operativos a partir de series temporales.

Palabras Claves – *Machine learning, Random Forest, Motor de inducción, Cortocircuitos entre espiras, Diagnóstico de averías.*

1 Introducción

Los cortocircuitos entre espiras (CEEs) son las averías de estator con mayor probabilidad de ocurrencia de los motores de inducción (MI) [1]. Un CEE comienza por el deterioro del aislamiento de los conductores contiguos y se propaga rápidamente hacia todo el bobinado. Para estudiar diferentes tipos de averías, en el año 2018 se comenzó con la construcción de un banco de ensayos en el marco de un proyecto de investigación 16/I162 acreditado por la la Secretaria Gral. de Ciencia y Tecnología de la Universidad Nacional de Misiones [2]. Este banco se utilizó para el montaje de dos motores de inducción trifásicos cuyos parámetros, eléctricos y mecánicos, fueron calculados y validados con experimentos en laboratorio [3]. Con el objetivo de generar un CEE de forma controlada, el devanado de un MI fue modificado, posibilitando el acceso a las espiras de un bobinado de fase. A partir de este MI prototipo, se analizaron y propusieron nuevos métodos de detección y diagnóstico de falla. En [4] se utilizó un modelo de simulación dinámico con falla, configurado con los parámetros del motor prototipo para el seguimiento de componentes armónicas en tiempo real mediante el filtro de Vold-Kalman. En [5, 6] se analizaron los efectos de los CEEs utilizando la teoría de la potencia instantánea [7]. Los métodos de clasificación de patrones basados en Machine learning para identificar distintos tipos de averías han tenido un gran impulso en estas últimas décadas. En [8] se utiliza el algoritmo Random Forest (RF) para el diagnóstico de fallas en MI. En este caso se realiza un diagnóstico de fallas basado en RF utilizando tres corrientes de línea y señales de vibración de los ejes horizontal, vertical y axial. En [9] utiliza el vector de Park de corrientes y tensiones como señales de entrenamiento para el proceso de extracción de características. Una propuesta reciente basada en RF [10], utiliza las diferencias de amplitudes y de fase angular entre las corrientes de línea en el proceso de entrenamiento.

*martin.puertaz@fio.unam.edu.ar

En este trabajo se presenta la aplicación del algoritmo RF para la clasificación de dos estados de operación de un motor de inducción trifásico. En primer lugar se presenta la validación experimental de un modelo dinámico para el MI con cortocircuitos entre espiras. A partir del funcionamiento normal y con falla se aplica el algoritmo RF para lograr la clasificación de ambos estados de operación. Este clasificador fue entrenado mediante un conjunto de señales de corrientes temporales en el marco de referencia $\alpha\beta$. Se presentan resultados de simulación obtenidos a partir de un modelo dinámico del MI que incluyen los efectos de la avería. Los resultados experimentales fueron realizados utilizando un motor de inducción trifásicos de 2 Hp con bobinados de estator modificados para generar distintas severidades de falla. En base las pruebas de entrenamiento y testing de RF se demuestra la correcta clasificación y categorización de los distintos estados de funcionamiento.

2 Modelos analíticos utilizados

2.1 Modelo dinámico del MI

En esta sección se presenta el modelo analítico del MI que incluye un cortocircuito entre espiras en los bobinados del estator. El modelo del MI es bien conocido en la literatura [11, 12] y se utiliza en este trabajo para evaluar el comportamiento del MI, estudiada en [3], ante distintas severidades de falla. A continuación se presentan las ecuaciones de tensión en el marco de referencia $dq0$:

$$\mathbf{v}_{qds} = r_s \mathbf{i}_{qds} + p \boldsymbol{\lambda}_{qds} - \frac{2}{3} \boldsymbol{\mu}_{qd} r_s i_f \quad (1)$$

$$\mathbf{v}_{qdr} = r_r \mathbf{i}_{qdr} + p \boldsymbol{\lambda}_{qdr} - \omega_r \mathbf{J} \boldsymbol{\lambda}_{qdr} \quad (2)$$

y los flujos de estator y rotor definen como,

$$\boldsymbol{\lambda}_{qds} = L_s \mathbf{i}_{qds} + L_m \mathbf{i}_{qdr} - \frac{2}{3} \boldsymbol{\mu}_{qd} L_s i_f \quad (3)$$

$$\boldsymbol{\lambda}_{qdr} = L_r \mathbf{i}_{qdr} + L_m \mathbf{i}_{qds} - \frac{2}{3} \boldsymbol{\mu}_{qd} L_m i_f \quad (4)$$

donde el subíndice s y r indican las magnitudes referidas al estator y rotor. $\mathbf{v}_{qd} = [v_q \ v_d]^T$, $\mathbf{i}_{qd} = [i_q \ i_d]^T$ y $\boldsymbol{\lambda}_{qd} = [\lambda_q \ \lambda_d]^T$ representan los vectores de tensión, corrientes y flujos magnéticos, respectivamente. $L_s = L_{ls} + L_m$ es la inductancia del estator y $L_r = L_{lr} + L_m$ del rotor. $L_m = \frac{3}{2} L_{ms}$ es la inductancia magnetizante y L_l la inductancia de dispersión. Por otro lado, i_f es la corriente de falla que circula por las espiras en cortocircuito. ω_r es la velocidad angular del rotor. p representa el operador derivada respecto del tiempo y $\mathbf{J} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$.

La avería que se genera en bobinados debido a las espiras en cortocircuito produce un lazo de falla, cuyo modelo se expresa de la siguiente manera,

$$\mathbf{v}_{qd}^T \boldsymbol{\mu}_{qd} = \left[\left(1 - \frac{2}{3} \|\boldsymbol{\mu}_{qd}\| \right) \|\boldsymbol{\mu}_{qd}\| \right] (r_s + L_{ls} p) i_f + r_f i_f \quad (5)$$

donde $\boldsymbol{\mu}_{qd} = \mu [n_q \ n_d]^T$. $\|\boldsymbol{\mu}_{qd}\|$ es la relación que existe entre las espiras dañadas respecto del total que contiene un devanado de fase y $\angle \boldsymbol{\mu}_{qd}$ indica la localización de la avería en las fases del estator. De esta manera, una avería en la fase a se define cuando $[1 \ 0]^T$, para la fase b será $[-1/2 \ -\sqrt{3}/2]^T$ y $[-1/2 \ \sqrt{3}/2]^T$ para la fase c . El estado sin falla se define cuando $\|\boldsymbol{\mu}_{qd}\| = 0$ y, para esta condición, se obtiene el modelo dinámico convencional [13].

2.2 Corrientes de estator

En esta sección se presentan las señales de corrientes en el dominio del tiempo utilizadas para el entrenamiento del algoritmo RF. A partir de las tensiones y las corrientes de fase en el marco de referencia abc , se aplica la transformación de Clarke [13] para obtener las funciones temporales (corrientes, tensiones, flujos, etc) en el marco de referencia $\alpha\beta$. Entonces, para transformar las corriente de línea se obtiene:

$$i_\alpha = \frac{2}{3}i_a - \frac{1}{3}i_b - \frac{1}{3}i_c \quad (6)$$

$$i_\beta = -\frac{1}{\sqrt{3}}i_b - \frac{1}{\sqrt{3}}i_c \quad (7)$$

Por otro lado, utilizando la teoría de la potencia instantánea se calculan las corrientes $\alpha\beta$ relacionadas con la potencia activa y reactiva, de la siguiente manera [7]:

$$i_{\alpha p} = \frac{v_\alpha}{\|\mathbf{V}\|^2} \cdot p \quad (8)$$

$$i_{\beta p} = \frac{v_\beta}{\|\mathbf{V}\|^2} \cdot p \quad (9)$$

$$i_{\alpha q} = \frac{v_\beta}{\|\mathbf{V}\|^2} \cdot q \quad (10)$$

$$i_{\beta q} = -\frac{v_\alpha}{\|\mathbf{V}\|^2} \cdot q \quad (11)$$

donde, $\|\mathbf{V}\|^2 = v_\alpha^2 + v_\beta^2$. Las potencias se definen según: $p = i_\alpha \cdot v_\alpha + i_\beta \cdot v_\beta$ y $q = i_\alpha \cdot v_\beta - i_\beta \cdot v_\alpha$.

3 Evaluación dinámica y validación experimental

En esta sección se presentan los resultados de simulaciones utilizando el modelo con falla presentado en la sección 2. Seguidamente se muestran las corrientes medidas de forma experimental, que son comparadas con las obtenidas por simulación, para validar los resultados del modelo analítico. En este trabajo se evalúa el funcionamiento de un motor de inducción trifásico de 2 Hp, cuyos parámetros característicos se muestran en la Tabla 1.

3.1 Análisis de simulaciones

Los resultados de simulaciones utilizando el modelo con falla se muestran en la Fig. 1 y Fig. 2. En la Fig. 1(a) se muestran las corrientes trifásicas en marco de referencia abc para el estado de operación sin falla. En la Fig. 1(b) se presentan las corrientes de línea y la corriente de falla, i_f , producto de un cortocircuito entre 3 espiras, calculada por el modelo a partir de (5). Para este último estado de falla puede observarse que la amplitud de la corriente de falla, a partir de los $t = 0,25$ s, supera ampliamente las amplitudes de las corrientes de línea. Mientras que no se observan cambios notables en las amplitudes de las corrientes de línea.

Los resultados para mayores severidades se muestran en la Fig. 2. En ambos casos, el estado de falla se produce a partir de $t = 0,25$ s. Las corrientes para el motor con 5 espiras en cortocircuito se muestra en la Fig. 2(a). Por otro lado, la Fig. 2(b) muestran las señales de corrientes para una mayor severidad de falla. Comparando estos últimos estados, se observa que la amplitud de i_f se incrementa significativamente a medida que aumenta la severidad del cortocircuito, incrementando el desequilibrio de las corrientes de líneas pero sin cambios notables en sus amplitudes.

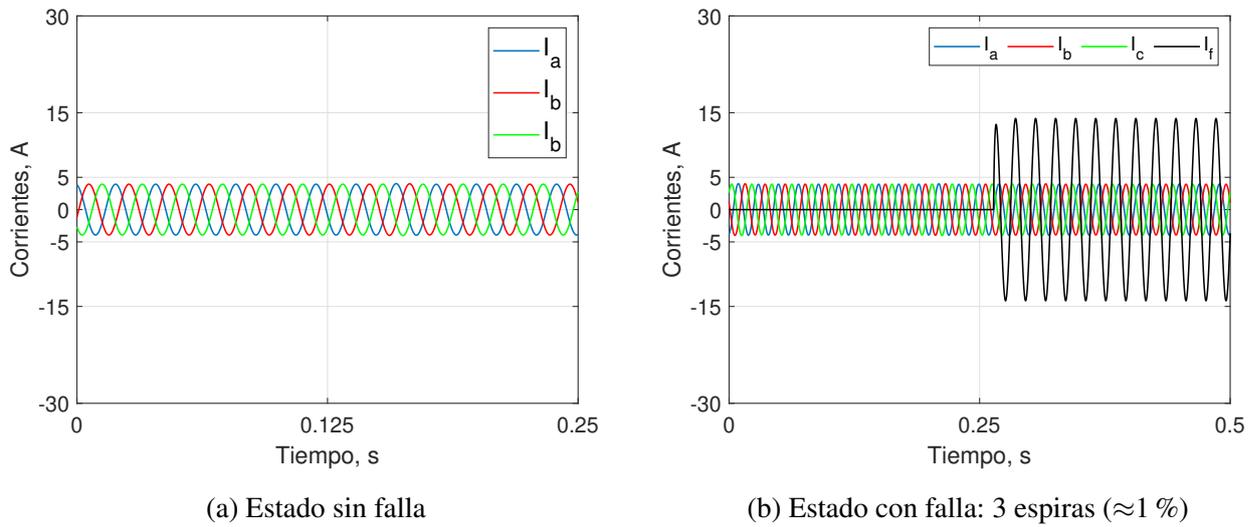


Fig. 1: MI en estado de operación normal y con falla

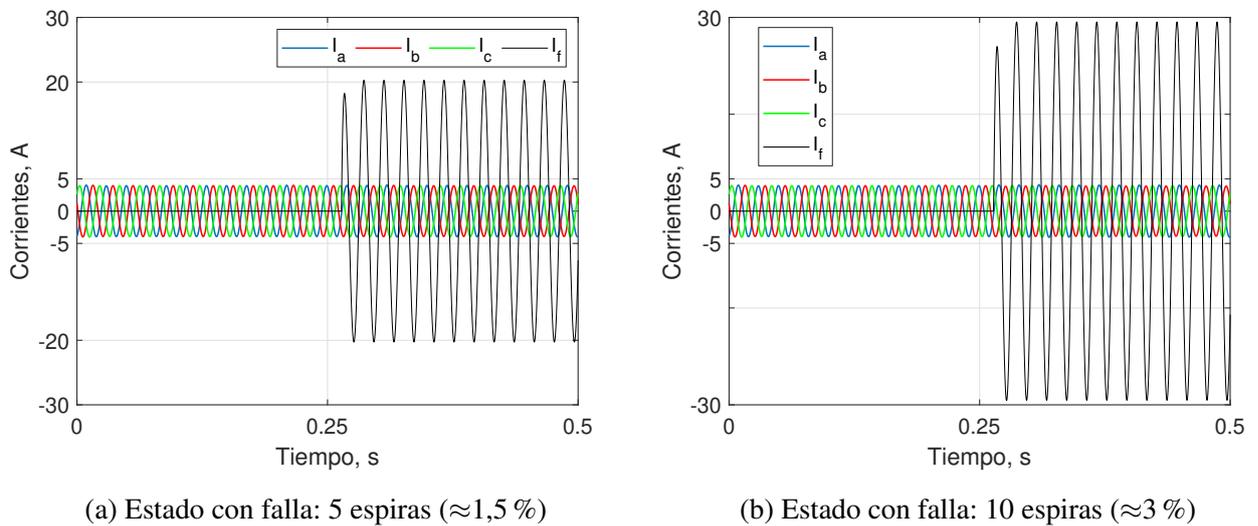


Fig. 2: MI en estados de operación con falla

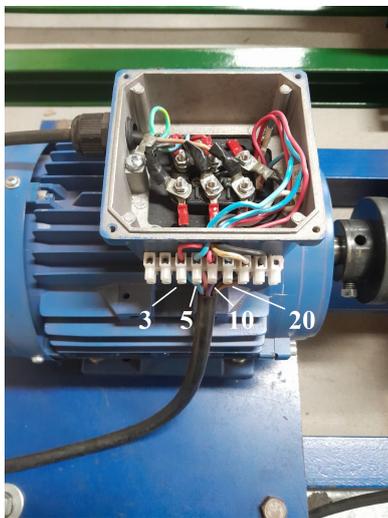
3.2 Ensayos experimentales

Para comparar las señales de corrientes obtenidas con el modelo dinámico se utiliza un motor de inducción prototipo de 2 Hp. En la Fig. 3 se muestra el banco de ensayos construido en el laboratorio [2]. Este banco soporta un motor de inducción con bobinados de estator modificado para generar los CEEs. En la Fig. 3(a) se muestran terminales adicionales correspondientes a la 3^o, 5^o, 10^o y 20^o espiras del bobinado de la fase *a*. Desde estas salidas adicionales es posible generar cortocircuitos controlados de diferentes severidades, entre el 1 % y 6 % aprox., respecto del total de las espiras. De esta manera, es posible medir la corriente de falla que se genera por el lazo que forman las espiras en cortocircuito. En la Fig. 3(b) se muestra el MI prototipo con los instrumentos de medición y registro.

En la Fig. 4 se muestra las corrientes medidas en bornes del MI para dos estados de operación. En la Fig. 4(a) se muestran las corrientes trifásicas para el estado de operación sin falla. En la Fig. 4(b) se presentan las corrientes de línea y de falla producto de un cortocircuito entre 3 espiras. Para este último estado de falla puede observarse que la amplitud de la corriente de falla, i_f , supera ampliamente las amplitudes de las corrientes de línea.

Tabla 1: Características del MI

Parámetros	Magnitud	Unidad
Tensión nominal	380	V
Corriente nominal	3,75	A
Frecuencia	50	Hz
Velocidad nominal	1410	rpm
P	4	polos
r_s	3,65	Ω
r_r	5,24	Ω
$L_{ls} = L_{lr}$	20	mH
L_m	240	mH
Bobinas por fase	4	-
Espiras por bobina	80	-
Espiras por fase	320	-



(a) Bobinado con salidas adicionales



(b) MI prototipo con falla

Fig. 3: Banco de ensayos experimental

Finalmente, en la Fig. 5 se muestran las corrientes medidas para estados con otras severidades de falla. La Fig. 5(a) muestra las corrientes para 5 espiras en cortocircuito, mientras que en la Fig. 5(b) para un cortocircuito entre 10 espiras. El incremento de la severidad produce el aumento notable de la amplitud de la corriente de falla, sin embargo, las corrientes de línea experimentan leves cambios de amplitudes. Debido a estos efectos que provoca una avería sobre las corrientes de línea, las protecciones convencionales para motores están limitadas para su detección. Si comparamos las amplitudes de las señales de corrientes medidas con las obtenidas por simulación, Fig. 1 y Fig. 2, puede observarse que el modelo configurado con los parámetros de la Tabla 1 reproduce los efectos de un CEE de manera correcta.

4 Clasificación mediante Random Forest

En esta sección del artículo se describe la técnica de Machine Learning utilizada para clasificar los estados operativos del MI.

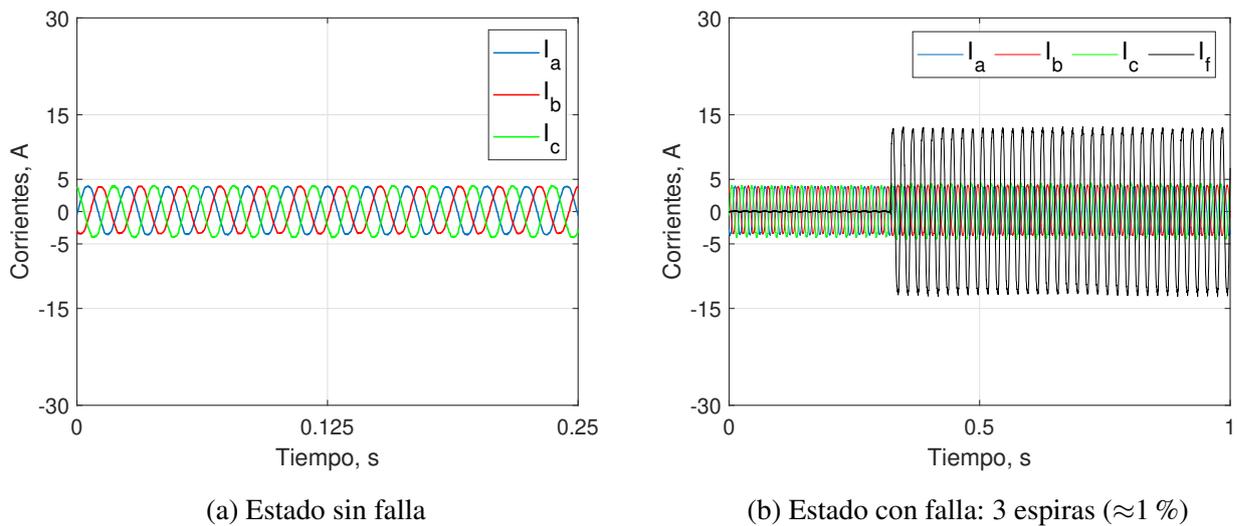


Fig. 4: MI prototipo de operación normal y con falla

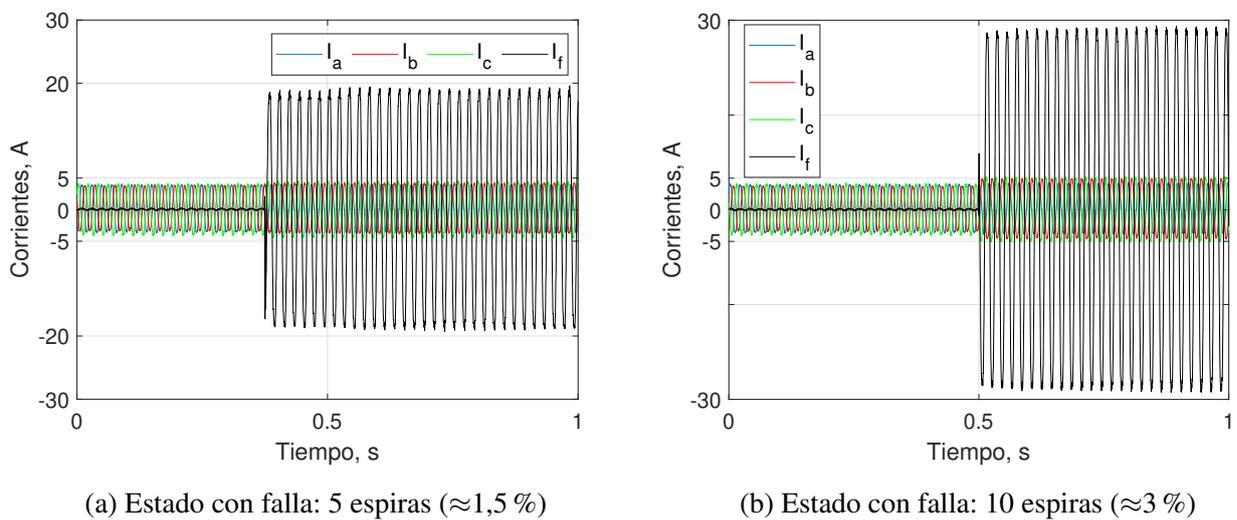


Fig. 5: MI prototipo en estado de operación con falla

4.1 Método utilizado

El algoritmo de Random Forest es la herramienta de Machine Learning utilizada para la clasificación de fallas, la cual ha demostrado ser efectiva para la clasificación de estados de funcionamiento de máquinas eléctricas. Para esta aplicación en particular se obtiene, mediante pruebas continuas, una mejor precisión del modelo de entrenamiento-testeo cuando la cantidad de muestras extraídas para el entrenamiento es menor a la mitad de las muestras del estado de falla. Es decir, cuando el conjunto de datos o dataset de entrenamiento es menor al dataset de testeo. Una vez decidido el set a procesar se procede con el entrenamiento del modelo. El entrenamiento del modelo se realiza de forma iterativa. En cada iteración se modifican los hiper-parámetros del modelo hasta obtener resultados aceptables en la clasificación.

4.2 Set de datos

Las señales presentadas en la sección 3.2 se utilizan para armar un set de datos. Por cuestiones de simplicidad el vector de tiempo es desestimado en esta propuesta y se lo reemplaza por un vector

de muestras. Las magnitudes utilizadas para entrenar y probar el modelo son las siguientes: i_a , i_b , i_c , $i_{\alpha p}$, $i_{\alpha q}$, $i_{\beta p}$, $i_{\beta q}$, definidas en (6)-(11) de la sección 2. Las magnitudes mencionadas se utilizan para alimentar al modelo cuyo objetivo es clasificar la severidad. En la Fig. 6 se muestran la corriente RMS de falla para 5 espiras en corto (a) y la categorización de dicha falla. Para este caso se distinguen dos estados: “Sin falla” y “5 espiras”. Este procesamiento sienta las bases para definir el objetivo del clasificador utilizado el cual debe distinguir entre distintos estados de funcionamiento del MI.

4.3 Definición de características

Las señales se procesan por separado teniendo tres sets de datos en los cuales se realiza la separación por categorías de los estados de la máquina. A partir de conocer el comportamiento del MI en estado de falla, se calcula el valor RMS de la corriente de falla y en base a estas magnitudes se realiza una imputación de categorías donde se clasifican en 4 estados: “sin falla”, “3 espiras”, “5 espiras”, “10 espiras”. La imputación de categorías se realiza observando el valor RMS de la corriente de falla. Si la corriente de falla supera 1 A se considera el estado de falla y se imputa una de las 3 categoría definidas. El cálculo de los valores RMS de las corrientes se realiza con el método de ventana deslizante tomando 1000 muestras de ancho de ventana. Una vez que se tienen los valores RMS de las corrientes de falla para cada caso (3, 5 o 10 espiras en cortocircuito) se procede a concatenar todos los datos para formar un solo set. En la Fig. 7 se muestran las corrientes RMS de falla para el entrenamiento y la categorización de dichas corrientes. El set de datos de categorización es el que recibe el modelo como objetivo (target) durante el entrenamiento. Una vez obtenido el modelo se realizan predicciones con el set de prueba el cual tiene características similares al set de entrenamiento.

4.4 Resultados obtenidos

Los resultados muestran un buen nivel de precisión de entrenamiento y testing, $\approx 98\%$ y $\approx 97\%$ respectivamente. En la Fig. 8 se muestran la precisión y los indicadores de desempeño para entrenamiento y prueba. Puede apreciarse que para el caso de 10 espiras en cortocircuito el modelo mejora su precisión. Esto ultimo sugiere que cuanto mayor sea la falla más fácil será detectarla. No sucede lo mismo con fallas de menor severidad (entre 3 y 5 espiras). A medida que disminuye la severidad de la falla los fenómenos electromagnéticos dificultan la clasificación, por lo que hace aun mas complejo

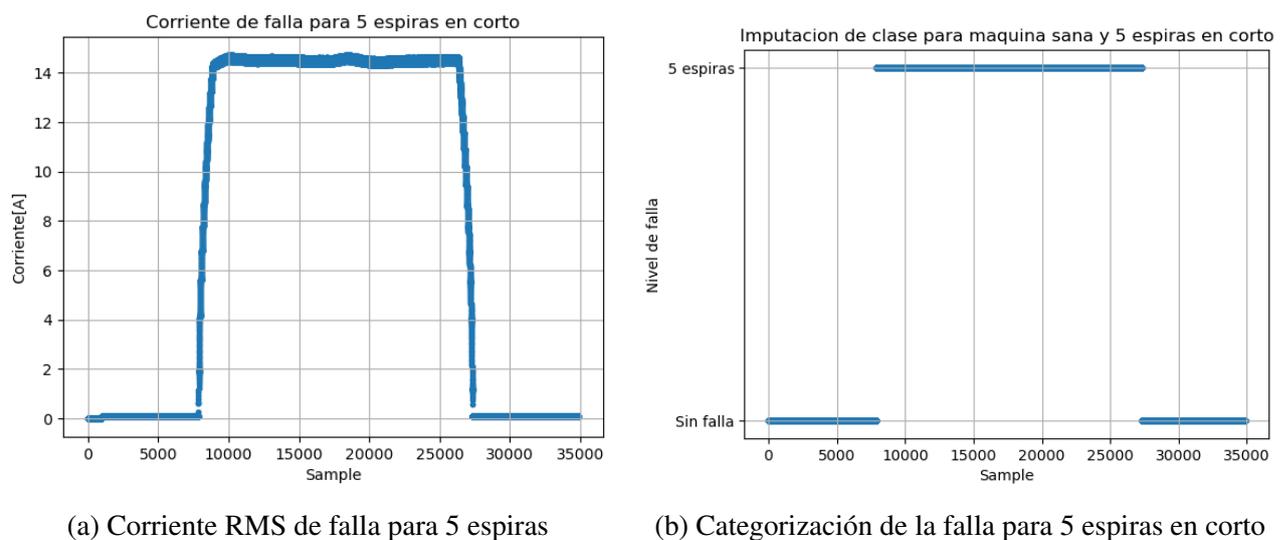
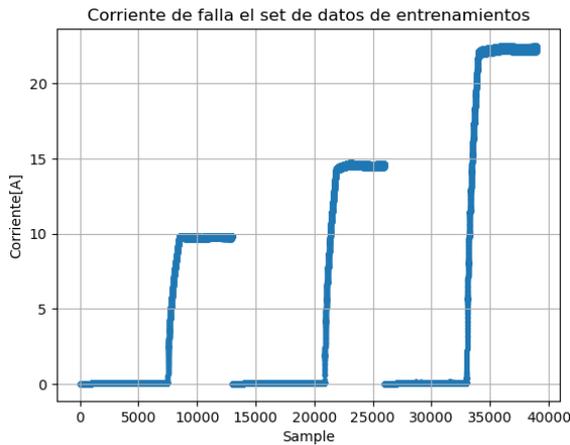
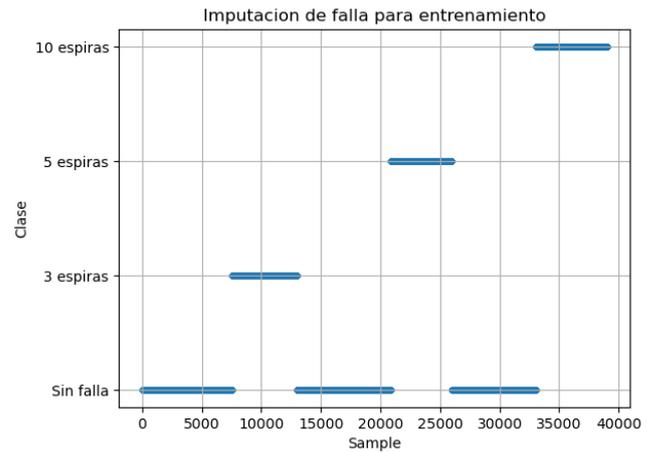


Fig. 6: Datos para clasificación de 5 espiras en cortocircuito



(a) Corriente RMS de falla. 5 Espiras



(b) Categorización de estados de falla

Fig. 7: Datos para clasificación de 5 espiras en cortocircuito

detectar fallas incipientes. No obstante se puede apreciar en los resultados que la precisión obtenida para el caso de máquina sana (categoría "Sin falla") es de un valor alto. Esto último sugiere que si bien el modelo podría ser erróneo al clasificar 3 o 5 espiras dañadas de todas formas estaría detectando un caso de falla lo que resulta acertado desde el punto de vista de determinar el estado operativo del MI.

Training Accuracy: 0.9772564102564103					Test Accuracy: 0.9690649346689232				
Training Classification Report:					Test Classification Report:				
	precision	recall	f1-score	support		precision	recall	f1-score	support
10 espiras	1.00	1.00	1.00	5976	10 espiras	1.00	0.99	0.99	14964
3 espiras	0.90	0.96	0.93	5476	3 espiras	0.93	0.93	0.93	12282
5 espiras	0.98	0.87	0.92	5118	5 espiras	0.94	0.94	0.94	14328
Sin falla	0.99	1.00	0.99	22430	Sin falla	0.99	0.99	0.99	24015
accuracy			0.98	39000	accuracy			0.97	65589
macro avg	0.97	0.96	0.96	39000	macro avg	0.96	0.96	0.96	65589
weighted avg	0.98	0.98	0.98	39000	weighted avg	0.97	0.97	0.97	65589

(a) Performance del modelo para entrenamiento

(b) Performance del modelo para testeo

Fig. 8: Resultados obtenidos por el modelo RF

5 Conclusiones

En este trabajo se aplicó el algoritmo de Random Forest para la clasificación de estados operativos de un motor de inducción (MI) trifásico. En primer lugar, se utilizó un modelo analítico del MI para evaluar el estado de operación normal y con un cortocircuito entre espiras (CEEs) en bobinados de estator. La validación del modelo se realizó en laboratorio mediante un motor de inducción trifásicos de 2 Hp con bobinados modificados. Mediante la comparación entre las señales de corrientes simuladas y medidas, se comprobó que el modelo analítico reproduce de manera correcta los efectos que producen los CEEs sobre las corrientes de líneas. En base a un conjunto de señales de corrientes medidas en bornes del motor se aplicó el algoritmo de Random Forest para clasificar patrones de funcionamiento y categorizar los estado de falla. Los resultado arrojados por el algoritmo demostraron buenos niveles de entrenamiento y testing, $\approx 98\%$ y $\approx 97.3\%$ respectivamente, logrando clasificar correctamente los

estados de operación normal y con falla. El algoritmo RF mejora su precisión para los casos de mayor severidad de falla (más de 5 espiras en cortocircuito). En trabajos futuros se propone incluir otros estados de operación del MI y evaluar el comportamiento frente a otras averías que producen asimetrías de los bobinados.

Agradecimientos

Este trabajo fue realizado en el marco del Proyecto de Investigación PICT-2021-I-INVI-00681 denominado Desarrollo de estrategias para la detección de averías en accionamientos eléctricos basado en WSN para la industria 4.0, financiado por el Fondo para la Investigación Científica y Tecnológica (FONCYT) y acreditado por la Secretaria General de Ciencia y Tecnología (SGCyT) de la Universidad Nacional de Misiones (UNaM).

Referencias

- [1] P. Zhang, Y. Du, T. G. Habetler, and B. Lu, "A survey of condition monitoring and protection methods for medium-voltage induction motors," *IEEE Transactions on Industry Applications*, vol. 47, no. 1, pp. 34–46, 2011.
- [2] G. D. Yuchechen, L. E. Lede, G. C. Hermann, L. A. Barruffaldi, J. A. Potschka, and M. A. Mazzoletti, "Banco de ensayos experimental para la validación de técnicas de detección y diagnóstico de fallas en las máquinas eléctricas rotativas," in *IX Jornada de Investigación, Desarrollo Tecnológico, Extensión y Vinculación, Facultad de Ingeniería, UNaM.*, vol. 1, 2019, pp. 1–7.
- [3] A. M. Alvez, A. N. Davalos, and M. A. Mazzoletti, "Métodos de estimación de parámetros en máquinas eléctricas rotativas," in *IX Jornada de Investigación, Desarrollo Tecnológico, Extensión y Vinculación, Facultad de Ingeniería, UNaM.*, vol. 1, 2019, pp. 1–10.
- [4] M. A. Mazzoletti, F. R. Gentile, M. P. Puertaz, P. D. Donolo, and G. R. Bossio, "Estimación de componentes de secuencia mediante el filtro de vold-kalman para la detección de averías en el estátor de la MI," in *XI Jornada de Investigación, Desarrollo Tecnológico, Extensión y Vinculación, Facultad de Ingeniería, UNaM.*, vol. 1, 2021, pp. 1–11.
- [5] G. D. Yuchechen, M. A. Mazzoletti, and G. R. Bossio, "Effects of stator winding interturn short-circuit faults of the im by using intantaneous power theory," in *2018 Argentine Conference on Automatic Control (AADECA)*, 2018, pp. 1–6.
- [6] G. D. Yuchechen and M. A. Mazzoletti, "Análisis del cortocircuito entre espiras en bobinados de la máquina de inducción utilizando la teoría de la potencia instantánea," + *INGENIO Revista de Ciencia Tecnología e Innovación*, vol. 2, no. 1, pp. 54–65, 2021.
- [7] H. Akagi, E. H. Watanabe, and M. Aredes, *Instantaneous Power Theory and Applications to Power Conditioning*, 2nd ed. Wiley-IEEE Press, 2017.
- [8] B.-S. Yang, X. Di, and T. Han, "Random forests classifier for machine fault diagnosis," *Journal of Mechanical Science and Technology*, vol. 22, pp. 1716–1725, 2009.
- [9] T. dos Santos, F. J. T. E. Ferreira, J. M. Pires, and C. Damásio, "Stator winding short-circuit fault diagnosis in induction motors using random forest," in *2017 IEEE International Electric Machines and Drives Conference (IEMDC)*, 2017, pp. 1–8.

- [10] J. Ma, Y. Li, L. Wang, J. Hu, H. Li, J. Fei, L. Li, and G. Zhao, “Stator ITSC fault diagnosis for EMU induction traction motor based on goertzel algorithm and random forest,” *Energies*, vol. 16, no. 13, 2023. [Online]. Available: <https://www.mdpi.com/1996-1073/16/13/4949>
- [11] C. H. De Angelo, G. R. Bossio, S. J. Giaccone, M. I. Valla, J. A. Solsona, and G. O. Garcia, “Online model-based stator-fault detection and identification in induction motors,” *IEEE Transactions on Industrial Electronics*, vol. 56, no. 11, pp. 4671–4680, 2009, doi: 10.1109/TIE.2009.2012468.
- [12] M. A. Mazzoletti, F. R. Gentile, P. D. Donolo, and G. R. Bossio, “Online detection of interturn short-circuit fault in induction motor based on 5th harmonic current tracking using Vold-Kalman filter,” *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 13, no. 4, pp. 3593–3605, 2023.
- [13] P. Krause, O. Wasynczuk, s. Sudhoff, and S. Pekarek, *Analysis of Electric Machinery and Drive Systems*, 3rd ed. New Jersey, USA: IEEE Press, 2013.