

Detección de faltas en motores eléctricos con base en índices de potencias y redes neuronales

Electric motor failure detection based on indexes of powers and neural networks

Luis D. Murillo-Soto¹, Cindy Calderón-Arce², Giovanni Figueroa-Mata³

Fecha de recepción: 15 de mayo de 2017
Fecha de aprobación: 21 de julio de 2017

Murillo-Soto, L; Calderón-Arce, C; Figueroa-Mata, G. Detección de faltas en motores eléctricos con base en índices de potencias y redes neuronales. *Tecnología en Marcha*. Vol. 31-1. Enero-Marzo 2018. Pág 81-97.

DOI: 10.18845/tm.v31i1.3499



- 1 Escuela de Ingeniería Electromecánica. Instituto Tecnológico de Costa Rica, Cartago, Costa Rica. Correo electrónico: lmurillo@itcr.ac.cr
- 2 Escuela de Matemática. Instituto Tecnológico de Costa Rica, Cartago, Costa Rica. Correo electrónico: ccalderon@itcr.ac.cr
- 3 Escuela de Matemática. Instituto Tecnológico de Costa Rica, Cartago, Costa Rica. Correo electrónico: gfigueroa@itcr.ac.cr

Palabras clave

Índices de pérdidas; detección de faltas; motor de inducción; redes neuronales.

Resumen

Se presenta un método alternativo para determinar condiciones de operación anómalas en un motor trifásico de inducción, basado en un conjunto de índices adimensionales, calculados a partir de sus pérdidas de potencia. Estos índices son sensibles a variaciones en las condiciones en que opera el motor y por lo tanto se valorará si, en conjunto, son capaces de discriminar entre un desbalance de voltaje, un subvoltaje o una variación térmica, entre otros. En este trabajo se desarrollan las ecuaciones necesarias para calcular las pérdidas eléctricas que permiten el cálculo de los índices propuestos. Es importante destacar que estos índices unifican la interpretación de variables eléctricas, mecánicas y térmicas con la intención de su utilización en el diseño de un sistema automático de detección de faltas que opere en tiempo real, por medio de un prototipo basado en redes neuronales. Adicionalmente, se describen los experimentos realizados a un motor trifásico de inducción de dos caballos de fuerza, 230 Voltios - 60 Hertz, el banco de pruebas construido y en la parte final del trabajo se representa de forma gráfica la variabilidad de los índices ante distintas condiciones anormales, lo que permite valorar su sensibilidad y relación con las faltas asociadas.

Keywords

Loss indices; fault detection; induction motor; neural networks.

Abstract

We present an alternative method to determine anomalous operating conditions in a three-phase induction motor, based on a set of dimensionless indices, they calculated from their power losses. These indices are sensitive to variations in the conditions under which the motor operates and will therefore be assessed if, on the whole, they are capable of discriminating between an unbalance of voltage, under-voltage or a thermal variation, among others. In this work the equations necessary to calculate the electrical losses that allow the calculation of the proposed indexes are developed. It is important to note that these indices unify the interpretation of electrical, mechanical and thermal variables with the intention of using them in the design of an automatic fault detection system that operates in real time, through a prototype based on neural networks. In addition, experiments are carried out on a three - phase two - horsepower induction motor, 230 Volt - 60 Hertz, the testbed constructed and the final part of the work graphically depicts the variability of the indices under different conditions Abnormal, which makes it possible to assess their sensitivity and relation to the associated faults.

Introducción

El motor eléctrico es un convertidor no ideal de energía eléctrica a mecánica, los motores modernos de alta eficiencia alcanzan valores de conversión de energía de hasta 95% para potencias superiores a los 50 caballos de fuerza (hp) y para motores con potencias no menores de 3 hp sus eficiencias son superiores a un 90%. La deficiente conversión de energía provoca el incremento de temperatura interna en la máquina tal y como lo explican los modelos térmicos descritos por [1], [2], [3], [4]. La ecuación (1) muestra que un incremento de las pérdidas en la máquina provoca un decrecimiento de la eficiencia de forma proporcional.

$$\eta = 1 - \frac{P_{loss}}{P_{in}} \quad (1)$$

donde η es la eficiencia y P_{loss} , P_{in} son las potencias por pérdidas y potencia de entrada del motor, respectivamente. El mínimo cambio en las pérdidas de la máquina no solo afecta la eficiencia, sino que esa energía adicional desperdiciada es convertida en calor. Medir la temperatura interna no es suficiente para explicar de dónde proviene ese calor.

Se propone utilizar índices que relacionan los distintos tipos de pérdidas de potencia del motor con el fin de utilizarlos para determinar el fallo² o la alteración en la condición de operación del motor, es decir, un fallo en la máquina repercute en su eficiencia y por lo tanto en los índices propuestos. Este trabajo se organiza de la siguiente forma: la sección II hace una descripción de las pérdidas del motor y los índices propuestos. En la sección III se muestra el banco de pruebas y las pruebas realizadas al motor, la sección IV muestra los experimentos realizados utilizando los cinco índices para la construcción de un prototipo de sistema de diagnóstico basado en redes neuronales artificiales, además se realiza un análisis de la variabilidad de los índices bajo condiciones tanto normales como anormales del motor, tomando en cuenta la sensibilidad y similitud entre los índices propuestos para identificar y categorizar faltas en el motor. La sección V presenta un análisis de resultados general y, finalmente, la sección VI las conclusiones.

Pérdidas del motor de inducción y definición de índices

Las potencias por pérdidas son resultado de un deficiente proceso de conversión de energía eléctrica a mecánica. Así, la potencia total de pérdida se calcula como la diferencia entre la potencia de entrada P_{in} y la de salida P_{out} , tal y como se muestra en la ecuación (2)

$$P_{loss} = P_{in} - P_{out} = P_s + P_r + P_{mi} \quad (2)$$

donde P_s representa la pérdida del estator, P_r la del rotor y P_{mi} las potencias mecánica y misceláneas. Además, la potencia por pérdidas del estator P_s se calcula por medio de la ecuación (3), donde P_{cs} es la potencia de pérdida por efecto Joule en los devanados estatóricos y P_{ns} la potencia por pérdidas en el núcleo debido a corrientes parásitas e histéresis.

$$P_s = P_{cs} + P_{ns} \quad (3)$$

$$P_{cs} = R_s(I_a^2 + I_b^2 + I_c^2)(1 + 0.00389(\Delta\theta)) \quad (4)$$

La potencia P_{cs} se calcula como en la ecuación (4), donde R_s es la resistencia estatórico medida a la temperatura ambiente, los términos I_a , I_b , I_c son las corrientes por fase, el término $\Delta\theta$ representa la diferencia de temperatura del devanado estatórico y la temperatura ambiente.

Por otro lado, las potencias por pérdidas del rotor P_r se determinan según la ecuación (5), donde s es un número adimensional que se calcula según la ecuación (6), n_{scr} es la velocidad sincrónica y n_{mec} es la velocidad mecánica del motor

$$P_r = (P_{in} - P_{cs} - P_{ns}) s \quad (5)$$

$$s = \frac{n_{scr} - n_{mec}}{n_{scr}} \quad (6)$$

2 Entiéndase falta y fallo como equivalentes, en el contexto de este trabajo.

Luego, la pérdida P_{mis} se puede estimar como en la ecuación (7)

$$P_{mis} = \chi(P_{in} - P_{out}) \quad (7)$$

donde χ oscila entre $[0, 0.11]$ según datos de [5], se puede calcular de forma experimental por medio de las pérdidas mecánicas y misceláneas.

Dado que las ecuaciones (3) y (5) dependen de P_{ns} , es necesario estimarla. Para ello, se sustituye (3), (5) y (7) en (2) para obtener la potencia del núcleo P_{ns} en términos de parámetros medidos

$$P_{ns} = \frac{(1 - s - \chi)P_{in} - (1 - s)P_{cs} - (1 - \chi)P_{out}}{(1 - s)} \quad (8)$$

Nuevamente, al sustituir (8) en (3) y (5) se obtienen expresiones que solamente dependen de las mediciones realizadas. De esta forma las expresiones para P_s y P_r , tomando $\chi = 0$, son aproximadas por las expresiones en (9) y (10).

$$P_s \approx P_{in} - \frac{P_{out}}{(1 - s)} \quad (9)$$

$$P_r \approx s \frac{P_{out}}{(1 - s)} \quad (10)$$

Definición de índices

En esta sección se definen cinco índices calculados por medio de las pérdidas del motor expuestas anteriormente. En conjunto, estos índices logran determinar si hay cambios en la carga del motor, alteraciones en el voltaje de alimentación o un calentamiento por pobre ventilación.

Los índices que se proponen son

$$I_{cs} = \frac{P_{cs}}{P_{loss}}, \quad I_{ns} = \frac{P_{ns}}{P_{loss}}, \quad I_r = \frac{P_r}{P_{loss}} \quad (11)$$

$$I_{rcs} = \frac{P_r}{P_{cs}}, \quad I_{rs} = \frac{P_r}{P_s}$$

El índice I_{cs} establece una relación entre las pérdidas que ocurren por efecto Joule entre el devanado estático y las pérdidas totales, este índice varía de acuerdo a los cambios en el voltaje de alimentación. A su vez I_{ns} calcula la relación entre la potencia disipada en el núcleo de la máquina y la total desperdiciada. El índice I_r relaciona las pérdidas del rotor entre el total de pérdidas. Los índices I_{rcs} y I_{rs} buscan establecer las relaciones específicas entre dos tipos de pérdidas de potencia, el primer caso establece la relación entre potencias perdidas en el rotor y cobre del estator y el segundo índice relaciona las pérdidas del rotor y el estator.

Banco de pruebas

El banco de pruebas para motores trifásicos que se construyó se compone de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres auto transformadores monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances. En la figura 1a se muestra una fotografía parcial del banco de pruebas implementado.

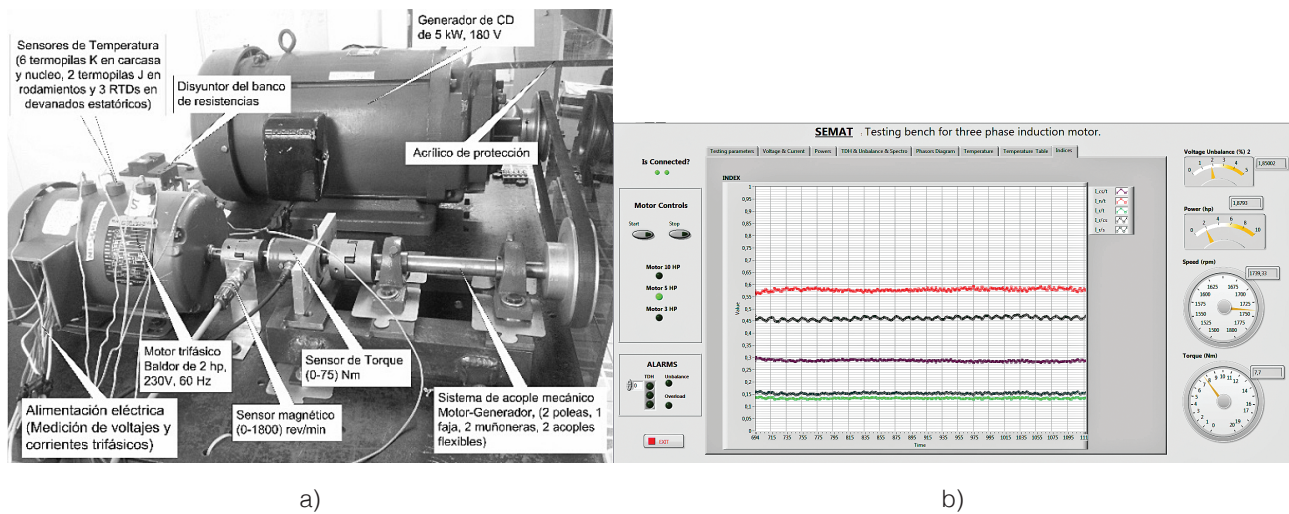


Figura 1. a) Banco de pruebas implementado. Tomado de [6] b) Interfaz gráfica con los índices calculados en tiempo real.

Para interconectar el banco de pruebas con el sistema de adquisición de datos, se desarrolló una aplicación informática [6] que gestiona el banco de pruebas y somete los motores a experimentos controlados en donde se definen los parámetros de la prueba. La aplicación controla los estímulos del motor (carga del motor, tiempos de encendido o apagado), monitorea su reacción y se registra todas las variables de interés.

El programa implementa, en tiempo real, el cálculo de los cinco índices propuestos tal como se muestra en la figura 1b. Cada segundo se publica la media móvil de los últimos diez valores con la finalidad de suavizar las curvas. Cuando la prueba finaliza, la aplicación guarda, en archivo de texto, todas las variables eléctricas, mecánicas y los índices propuestos. Así, el archivo contiene los índices calculados en cada segundo durante la prueba.

Pruebas realizadas

El motor en estudio es de la marca Baldor modelo M3558 de 2hp, 230 V, 60 Hz. Los fallos a los que se somete el motor se realizaron durante su transitorio térmico. Un buen modelo que aproxima este comportamiento lo plantea [7], indicando que la respuesta térmica del motor se modela como un sistema de primer orden cuyo resultado se presenta en la ecuación (12).

$$\theta = P_{loss} \cdot R_{th} \cdot \left(1 - e^{-\frac{t}{R_{th}C_{th}}}\right) + \theta_A \quad (12)$$

Donde θ y θ_A son las temperaturas interna y la ambiental respectivamente, el término P_{loss} representa la totalidad de pérdidas del motor como se mostró en la sección 2, el término R_{th} representa una resistencia térmica equivalente del motor, C_{th} representa la capacitancia térmica equivalente del motor y el término t representa el tiempo.

El estado estable de la máquina sin fallos asociados se alcanza en 5τ , donde $\tau = R_{th}C_{th}$. Sin embargo, para efectos experimentales se considera que se alcanza el equilibrio térmico cuando dos cambios consecutivos de la temperatura interna, separados por un lapso de cinco minutos, no varía en menos de un grado centígrado, esto es

$$|\theta_t - \theta_{t-5min}| \leq 1^\circ C \quad (13)$$

Para el motor en cuestión, el transitorio térmico experimental se alcanzó aproximadamente en los 8000 segundos bajo el criterio anterior. Durante todo el transitorio térmico se somete el motor a una condición anormal, ya sea subvoltaje, desbalance o un cobertor que simula poca ventilación, dichas condiciones se denominan fallos tipo uno, dos o tres, respectivamente, el cuadro 1 muestra la descripción de los mismos.

De forma similar al 100% de carga, se realizaron pruebas al 75% y al 50% de carga, en el código de la prueba se sustituye el término C100 por C75 y C50, según corresponda.




Figura 2. Comportamiento térmico de experimentos realizados al motor con 100% de carga

La figura 2 muestra el comportamiento de la temperatura del motor ante los tres tipos de fallos indicados anteriormente y la curva de funcionamiento normal, al 100% de carga. En dicha figura se puede observar que la diferencia entre el comportamiento de cada fallo y el comportamiento normal es mínima, por lo que detectar alguno de esos fallos en el motor no es una tarea sencilla.

Cuadro 1. Resumen de condiciones de fallo al 100% de carga

Fallo	Carga	Voltaje (V)	Desbalance	Cobertor.	Código
Sin fallo	100%	230	<1%	No	C100
Tipo 1	100%	200	<1%	No	C100V115 ¹
Tipo 2	100%	230	3%	No	C100D3
Tipo 3	100%	230	<1%	Si	C100Cobertor

1. $200V \approx 1.73 \cdot 115V$.

Experimentos realizados y valoración de índices

Esta sección muestra los experimentos realizados y sus resultados con el fin de determinar la viabilidad de los índices para el diagnóstico de fallos. Primeramente, se utilizó una red neuronal

artificial como prototipo de un sistema de diagnóstico automático. Posteriormente, se utilizan mapas autoorganizados para analizar si los índices poseen redundancia. Finalmente, se realiza un análisis gráfico de los índices para distintas pruebas en donde se confirma que existe duplicidad en la información que aportan algunos indicadores.

Redes neuronales

Una red neuronal artificial es un modelo simplificado del sistema neuronal humano [8],[9]. La unidad más simple de una red neuronal es la neurona artificial, la cual posee dos etapas, la primera suma los productos de la entrada $I(j)$ por el factor de su peso de arco $W(j)$, luego se le suma un factor de polarización llamado bias b .

La segunda etapa consiste en utilizar el resultado de la suma anterior y realizar la activación de la neurona mediante una función de transferencia. Existen varios tipos de funciones de activación [10], entre ellas *Sigmoid(a)*, *Logsig(a)*, *Purelin(a)*, para este trabajo se utiliza la llamada *Tansig(a)*. La figura 3a muestra una representación gráfica del modelo descrito anteriormente y la ecuación (14) su representación algebraica.

$$a = \sum_{j=1}^n [W(j)I(j)] + b$$

$$y = \text{Tansig}(a) = \frac{2}{1 + e^{-2a}} - 1 \quad (14)$$

Clasificador basado en red neuronal

Se diseñó una red neuronal artificial (RNA) tipo “feedforward” para decidir si un motor eléctrico presenta alguno de los tres tipos de fallos descritos en el cuadro 1 o si se encuentra en funcionamiento normal. La red posee diez entradas distribuidas de la siguiente forma: cinco entradas una para cada índices calculado en un instante específico y las otras cinco entradas para los valores anteriores a las muestras actuales. La red posee una capa oculta de diez neuronas y una capa de salida con cuatro neuronas, una por cada fallo más la salida para el funcionamiento normal. Cada una de las neuronas son idénticas y poseen el funcionamiento de la ecuación (14). Las neuronas de la capa oculta se definieron con la siguiente regla heurística

$$\text{Neuronas} \geq \frac{N_e + N_s}{2} \quad (15)$$

donde N_e y N_s representa cantidad de entradas y salidas respectivamente. Se definieron diez neuronas ocultas con el fin de incrementar la exactitud y disminuir el error cuadrático medio.

La figura 3b muestra la descripción anterior, los rombos representan los puertos de entrada y el término Z^{-1} indica que esa entrada específica ingresa la muestra anterior del *dataset*, W_1 representa la matriz de pesos de la capa oculta, esta matriz posee dimensión 10×10 y la matriz de pesos de las neuronas de salida se representa como W_2 y posee una dimensión de 4×10 . La salida vectorial F de la red neuronal queda descrita por la ecuación (16).

$$\mathbf{F} = \text{Tansig}(\mathbf{W}_2 \cdot \text{Tansig}(\mathbf{W}_1 \cdot \mathbf{I} + \mathbf{b}_1) + \mathbf{b}_2) \quad (16)$$

donde I es el vector de entradas, b_1 es el vector de bias de las neuronas de la capa oculta de tamaño 10×1 y b_2 es el bias de las neuronas de la capa de salida que posee un tamaño 4×1 .

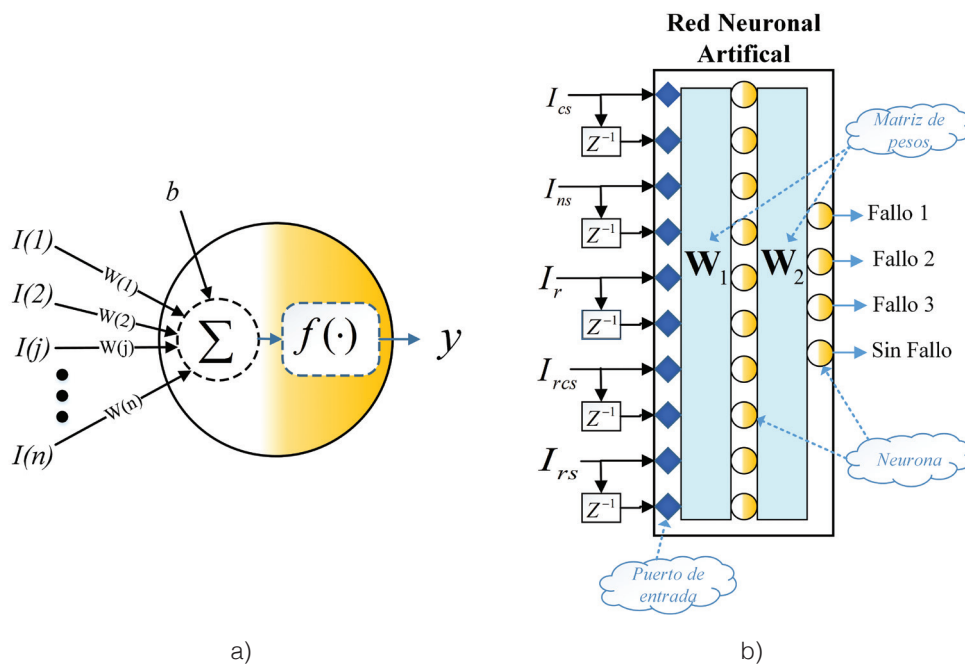


Figura 3. a) Neurona artificial b) RNA para clasificación de fallos de un motor eléctrico.

Entrenamiento de red

A fin de ajustar los pesos almacenados en las matrices W_1 , W_2 y en los vectores b_1 y b_2 se realizaron varios entrenamientos supervisados de la red. El mejor resultado se logró con el algoritmo Levenberg–Marquardt con aprendizaje basado en gradiente descendente y momento. La tasa de aprendizaje usada fue de 0.01 y la constante del momento usada fue de 0.9.

Tal y como se mencionó, el motor en estudio se expuso a los fallos descritos en el cuadro 1 y se almacenaron en cada segundo, los cinco índices definidos en la sección 2.1. El fallo a que se somete el motor está presente durante el transitorio térmico.

Para construir el conjunto de datos de prueba (*dataset*) se unificaron las tres pruebas y la prueba en funcionamiento sin fallo, dicho *dataset* posee más de 36000 registros. Posteriormente, se muestreó de forma uniforme cada 180 muestras y se construyó el *dataset* definitivo que posee 200 registros, cada 50 registros corresponde a una prueba específica. Es importante señalar que los 50 registros calculan los índices en distintos instantes del transitorio térmico del motor.

Con la arquitectura de la red neuronal y el *dataset* definitivo se procedió, primeramente, a realizar el entrenamiento supervisado con el algoritmo de retropropagación. La retropropagación es una técnica en la que la red es entrenada con un conjunto de entradas y salidas conocidas y para cada iteración del algoritmo, los pesos de las matrices W y b son auto ajustados, con el fin de minimizar el error entre la salida actual y su valor esperado. Este ajuste se aplica desde las capas de salida hasta las capas de entrada, de ahí el nombre de retropropagación. Para el presente trabajo este algoritmo no brindó los resultados esperados dado que el error cuadrático medio presentó valores alrededor de 0.22, considerado alto por los autores. Por esta razón se optó por utilizar el algoritmo Levenberg–Marquardt que se utiliza para minimizar funciones por mínimos cuadrados no lineales [9].

La figura 4 muestra la gráfica de error cuadrático medio (mse) versus la cantidad de entrenamientos completos con el *dataset* definitivo. Se observa un mse de 0.03197 en veintiocho *epochs*.




Figura 4. Error cuadrático medio vs entrenamiento y validación

Una vez entrenada la red, se construyó un segundo *dataset* con la finalidad de probarla. Se definió un valor umbral de aceptación de fallos mayor a 0.85. Así, cuando la RNA arroja, en una salida, un valor superior al umbral se considera que la red ha detectado una condición particular, ya sea funcionamiento normal o fallo tipo uno, dos o tres.

Un valor muy alto del umbral hace que el sistema de clasificación genere muchos falsos negativos, es decir, que no detecte cuando hay fallos específicos. Por otro lado, con bajos valores del umbral se corre el riesgo de generar falsos positivos, es decir que el sistema indique que hay un fallo específico cuando en realidad no existe.

La figura 5 muestra los resultados de la RNA con el segundo *dataset* construido. Al igual que el primero, este *dataset* posee 200 registros, y cada 50 muestras corresponde a un tipo de fallo, las primeras 50 muestras pertenecen al fallo tipo uno, los siguientes 50 registros al fallo tipo dos y así sucesivamente. Se señala nuevamente que las 50 muestras para cada prueba realizada poseen un espaciado temporal uniforme de 180 segundos. Esto a su vez implica que los cinco índices fueron calculados durante el régimen transitorio de temperatura.

Además, se observa en la figura 5 que, con los índices propuestos, la RNA detecta los fallos tipo 1 en cualquier instante del transitorio térmico en que ocurra. Esto concuerda con la primera gráfica de correlación de la figura 6, que muestra la correlación del resultado de la red versus el valor real. Para este caso el valor de correlación es de $R = 0.98889$.

Para la prueba del motor con el fallo inducido tipo dos, este presenta tanto falsos negativos como falsos positivos. Este se ve reflejado en el índice de correlación de resultados versus valores reales que es de $R = 0.8483$. Para las pruebas tipo tres, la RNA no diagnostica algunos casos de este fallo cuando el motor lo sufre (falso negativo), su índice de correlación es de 0.86592. Finalmente, cuando la red no presenta fallo la RNA logra determinar la gran mayoría de los casos, el índice de correlación es de 0.93703.

Mapas autoorganizados

Un mapa autoorganizado (SOM) es un tipo de red neuronal artificial, que se entrena utilizando un aprendizaje no supervisado para producir una representación discreta del espacio de las muestras de entrada [8], [9]. Organizándolas o agrupándolas de acuerdo a patrones o características comunes, tomando en cuenta tanto la competitividad, como la cooperatividad.

entre dichas muestras. En la etapa de competitividad, para cada muestra $I(j)$ se selecciona la neurona con la distancia euclídea más pequeña, según la ecuación (21), donde cada neurona representa una región en el espacio de entrada.

$$i^* = \operatorname{argmin}_i \|w_i - I(j)\| \quad (17)$$

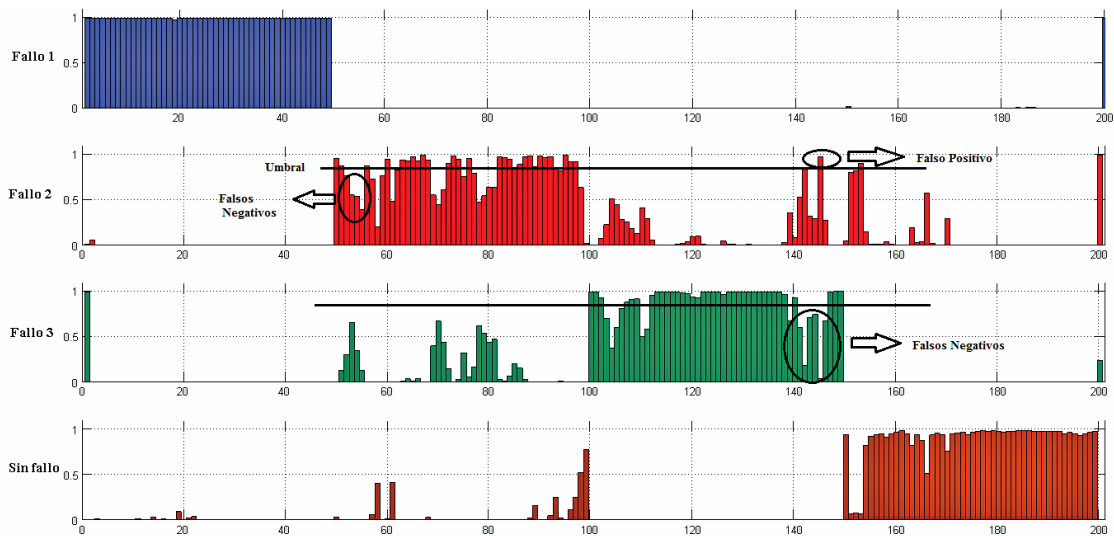


Figura 5. Clasificación por índices.

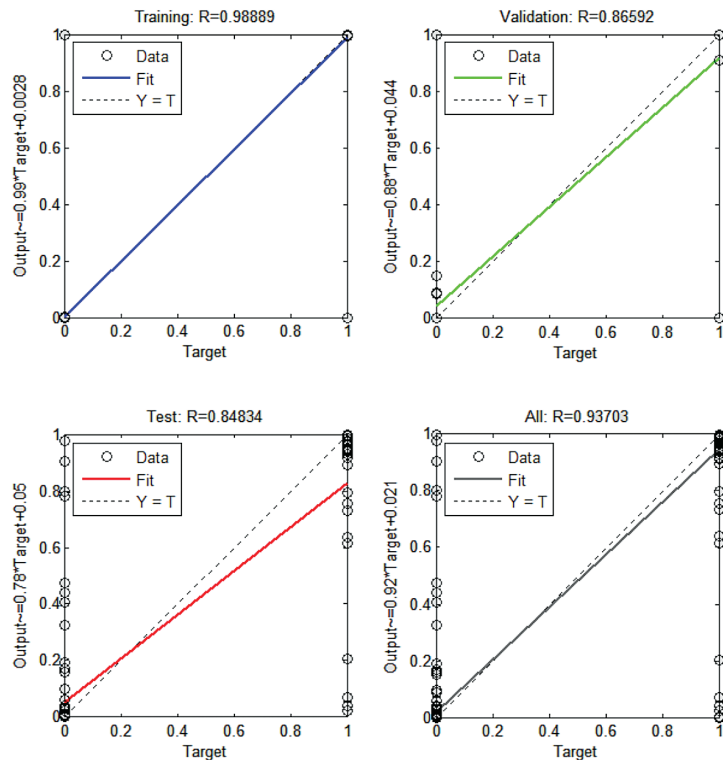


Figura 6. Correlaciones de los resultados de la RNA vs el valor real.

La neurona con vector de pesos más similar a la entrada es la ganadora. Por otro lado, en la etapa de cooperatividad, cada neurona se compara con sus neuronas vecinas, en la cual tanto el vector de pesos de la neurona ganadora es actualizado, por medio de una regla de actualización Δw_p , como el mallado de su vecindario. Para ello se utiliza una función Gaussiana de vecindad Λ , centrada en la neurona ganadora y decreciente respecto a la distancia de la neurona ganadora.

$$\Delta w_i = \alpha \Lambda(i, i^*, \sigma_\Lambda(t)) (I(j) - w_i)$$

$$\Lambda(i, i^*) = \exp\left(-\frac{\|r_i - r_{i^*}\|^2}{2\sigma_\Lambda^2}\right) \quad (18)$$

donde r_i y r_{i^*} representan los nodos del mallado discreto con una topología regular [11].

Similitud de índices con pruebas al 100% de carga por medio de SOM

Con la finalidad de analizar y detectar similitudes entre el comportamiento de los cinco índices definidos en la sección 2.1, se entrenó un SOM de 4×4 neuronas, con una tasa de aprendizaje $\eta=0.02$ y desviación estándar $\sigma_\Lambda=0.45$, tomando como entradas los valores de los cinco índices en las pruebas definidas en el cuadro 1.

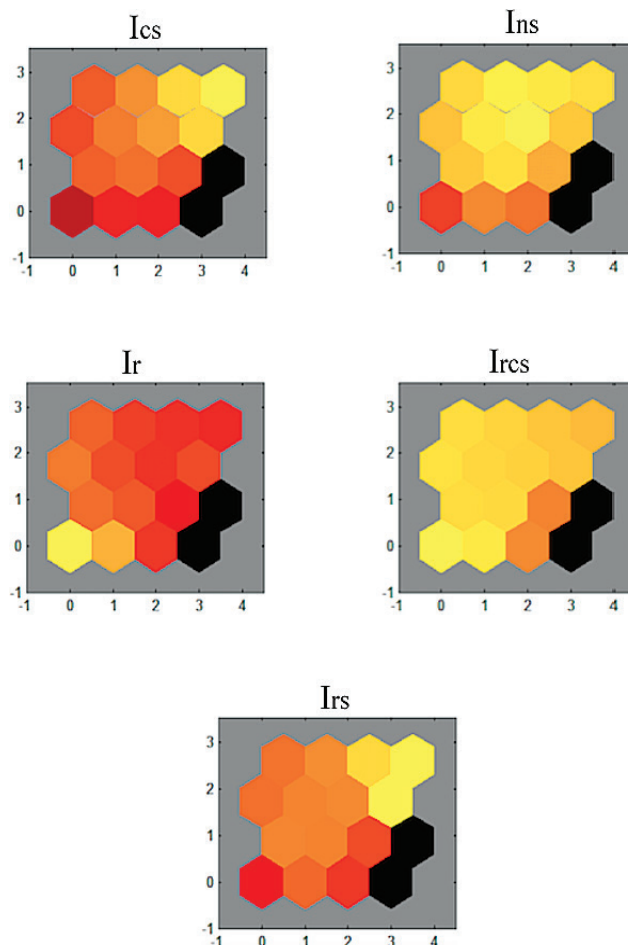


Figura 7. SOM de 4×4 .

La figura 7 muestra los resultados del entrenamiento del mapa autoorganizado con una malla de 4×4 , donde las neuronas en negro indican que no hay valores asociados a las mismas. Además, la escala de colores amarillo-rojo indica que entre más intenso u oscuro es el tono hay más valores asociados a la neurona, el amarillo representa menor intensidad y el rojo mayor intensidad. Así, según el patrón obtenido con el SOM, los cinco índices propuestos se pueden organizar en tres grupos



suponiendo que mapas similares indican características y comportamiento similares de los índices. Por lo que se podría reducir la cantidad de índices a solamente tres, uno por grupo



Tomando los tres anteriores como representativos o significativos, y además suficientes, para entrenar la RNA de la sección 4.1. y así intentar describir el comportamiento con fallo del motor.

Variabilidad de índices

Siguiendo los resultados obtenidos por medio del SOM para el caso de pruebas al 100% de carga, se realizó un análisis de los índices por tipo de fallo, de manera independiente, y además se generalizó para pruebas al 75% y al 50% de carga. Con el objetivo de validar la agrupación y selección de índices realizada en la sección 4.2.1. y además analizar la variación de los mismos por tipo de prueba (100%, 75% y 50% de carga) y por tipo de fallo (condiciones normales del motor, subvoltaje, desbalance y cobertor).

En las figuras 8 se muestra la distribución de los valores de cada índice bajo condiciones nominales del motor y para cada uno de los tres fallos con los que se entrenó la RNA de la sección 4.1. (subvoltaje con 200V, 3% de desbalance y cobertor) y además se analizó un caso más de desbalance al 4%.

Tomando como referencia el valor de los índices en el tiempo y en cada una de las pruebas de manera independiente, cada color representa un índice y cada uno de los recuadros está centrado en la media de los valores de cada índice, según corresponda. Por lo que se puede observar la variación de cada índice respecto a su media y respecto a la variación de los demás índices en cada una de las pruebas.

La figura 8 muestra como los recuadros en azul, negro y rojo mantienen un patrón similar, en rango, en cada una de las pruebas, en contraposición a los recuadros verde y amarillo que presentan una variación más marcada en sus posiciones de una prueba a otra. Por otro lado, se puede observar como el par de recuadros amarillo-negro se complementan en dimensión y el amarillo siempre contiene al negro. Asimismo el par verde-rojo siempre se traspone de la misma manera, con una intersección significativa entre ellos.

Además, la figura 9a muestra los índices al 100% de carga por medio de una representación lineal, donde el centro de cada franja de color está dado por la media de cada índice en el tiempo, según corresponda. Con lo que es posible reafirmar lo observado en la figura 8.

Los resultados anteriores coinciden con los obtenidos por medio del SOM en la figura 7, dado que en el mapa autoorganizado se toman en cuenta los índices de manera conjunta, en condiciones nominales y con los tres tipos de fallos (subvoltaje, desbalance y cobertor) para realizar su

representación gráfica. Ubicando a I_{CS} y a I_{rs} bajo un mismo patrón de comportamiento, lo mismo para I_{ns} y I_{rcs} , y categorizando los índices en tres grupos.

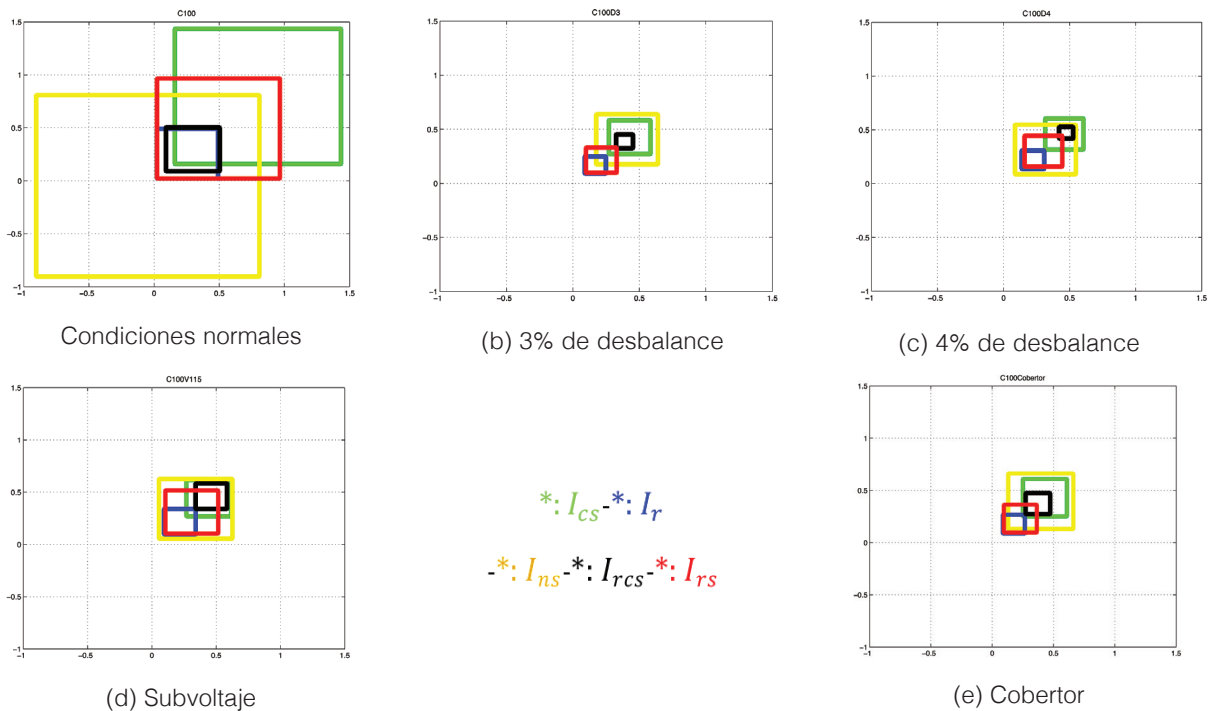


Figura 8. Índices al 100% de carga.




Figura 9. a) Índices al 100% de carga b) Índices representativos al 100% de carga. I_{CS} , I_r , I_{ns} , I_{rcs} , I_{rs}

Así, tomando como referencia un índice por grupo, I_r , I_{rcs} y I_{rs} son suficientes para entrenar la RNA de la sección 4.1., utilizándola para caracterizar el comportamiento del motor y ubicarlo en alguno de los cinco estados analizados: condición nominal del motor, subvoltaje con 200V, 3% de desbalance, 4% de desbalance y cobertor, tal y como se muestra en la figura 9b.

Generalizando los resultados anteriores para los casos al 75% y al 50% de carga, se toman en cuenta las pruebas en condiciones nominales del motor, con fallo tipo 1 (subvoltaje con 200V) y fallo tipo 3 (cobertor) al 75% de carga, ver figuras 10-11.

Para el caso de 50% de carga, se toman en cuenta las pruebas en condiciones nominales del motor, con fallo tipo 1 (subvoltaje con 200V) y con fallo tipo 2 (3% de desbalance), ver figuras 12-13.

Similarmente al caso con 100% de carga, en las figuras 10-11a y 12-13a se puede observar como la complementariedad del par de índices $I_{ns} - I_{rcs}$ (amarillo-negro) y el patrón de comportamiento del par $I_{cs} - I_r$ (verde-azul) se mantiene para los casos al 75% y al 50% de carga, según corresponda. Así, en las figuras 11b y 13b se muestra la representación gráfica lineal de los índices que se toman como representativos para entrenar la RNA de la sección 4.1. y así intentar caracterizar y categorizar el funcionamiento del motor, ahora al 75% y al 50% de carga.




Figure 10. Índices al 75% de carga , I_{cs}^* I_r^* I_{ns}^* I_{rcs}^* I_{rs}^*




Figura 11. a) Índices al 75% de carga b) Índices representativos al 75% de carga I_{cs}^* I_r^* I_{ns}^* I_{rcs}^* I_{rs}^*




Figure 12. Índices al 50% de carga, $*$: I_{CS} - $*$: I_r - $*$: I_{NS} - $*$: I_{rCS} - $*$: I_{rS}




Figura 13. a) Índices al 50% de carga b) Índices representativos al 50% de carga $*$: I_{CS} - $*$: I_r - $*$: I_{NS} - $*$: I_{rCS} - $*$: I_{rS}

Análisis de resultados

Los resultados de la RNA muestran que los índices propuestos logran discriminar los fallos inducidos al motor durante su transitorio térmico con 100% de carga. Es decir estos índices son capaces de operar en régimen transitorio como en régimen estable, lo que permite ser utilizados e implementados en el diagnóstico en tiempo real de los motores eléctricos.

Además, los resultados que arroja la RNA pueden ser fácilmente mejorados si se realizan acciones como:

- Aumentar al tamaño del *dataset* con pruebas similares en otro momento.
- Aumentar la cantidad de las capas ocultas de la RNA y/o neuronas en cada capa.
- Incrementar las entradas de la RNA retardadas, es decir, agregar entradas con doble retardo Z^2 para cada índice
- Explorar con otros algoritmos entrenamiento adaptativos / evolutivos.
- Realizar estudios más detallados variando los parámetros de inicio de los algoritmos.
- Explorar otras topologías de redes neuronales tales como RNA dinámicas, etc.

Por otro lado, el análisis en la similitud y variación de los índices realizado por medio de SOM indica que es suficiente con tomar solamente tres índices, dado que es posible agruparlos en

tres grupos de acuerdo a sus patrones de comportamiento en el tiempo, bajo tres porcentajes de carga (100, 75 y 50) y ante distintos tipos de fallo (subvoltaje, desbalance y cobertor). Así, se toman $I_r - I_{rcs} - I_{rs}$ como índices representativos o significativos para entrenar la RNA, categorizar el comportamiento del motor en el tiempo y así detectar algunos de los fallos definidos en el cuadro 1.

En la figura 14 se muestra el resumen de los índices representativos, en todos los casos presentados en la sección 4.3., donde se puede notar que dichos índices pueden ser capaces de discriminar no solo por tipo de fallo sino que también por porcentaje de carga.

Conclusiones

En este trabajo se valoraron cinco índices basados en las distintas pérdidas de motor con la intención de diagnosticar fallos específicos en la máquina. Se realizó un análisis teórico de sensibilidad para observar si los índices son capaces de diagnosticar nueve tipos de fallos distintos. Se requiere realizar más análisis al respecto pero se vislumbra que los índices en conjunto pueden mapear distintos fallos que afectan la máquina.




Figura 14. Índices representativos, I_r , I_{rcs} , I_{rs}

La viabilidad de utilizar los índices, para constituir un sistema que diagnostique fallos en tiempo real, se ha demostrado utilizando una red neuronal artificial entrenada con los índices calculados en distintos instantes del régimen transitorio. Esto permite que cuando un fallo particular aparezca, ya sea en régimen transitorio o estable, el sistema con pocas muestras sea capaz de determinar el tipo de fallo que afecta al motor.

Agradecimientos

Se agradece a la Vicerrectoría de Investigación y Extensión del Tecnológico de Costa Rica por el apoyo brindado al proyecto VIE 5402-1801-0505. Se agradece al Ing- Osvaldo Guerrero-Castro y a sus asistentes por las pruebas realizadas al motor trifásico con el fin de generar datos para el análisis.

Referencias

- [1] A. Boglietti, A. Cavagnino, M. Lazzari, and M. Pastorelli, "A Simplified Thermal Model for Variable-Speed Self-Cooled Industrial Induction Motor," *IEEE Transactions on Industry Applications*, vol. 39, no. 4, pp. 945–952, 2003.
- [2] M. Duran and J. Fernandez, "Lumped Parameter Thermal Model for Induction Machines," 2004.
- [3] G. Figueroa-Mata and L. D. Murillo-Soto, "Algoritmo bioinspirado aplicado a la estimación de los parámetros de un modelo térmico para un motor trifásico de inducción," in *12º Congreso iberoamericano de ingeniería mecánica (CIBIM XII)*, (Guayaquil), 2015.
- [4] L. D. Murillo-Soto, G. Figueroa-Mata, and O. Guerrero-Castro, "Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos," *Revista Tecnología en Marcha*, vol. 29, no. 5, pp. 25–41, 2016.
- [5] W. Cao, "Comparison of IEEE 112 and new IEC standard 60034-2-1," *Energy Conversion, IEEE Transactions on*, vol. 24, no. 3, pp. 802–808, 2009.
- [6] L. D. Murillo-Soto, "Aplicación informática para el monitoreo de variables eléctricas, mecánicas y térmicas en motores trifásicos de inducción," in *Latin American and Caribbean Conference for Engineering and Technology (LACCEI'2014)*, (Guayaquil), 2014.
- [7] S. E. Zocholl, "Comparing motor thermal models," in *In 31st Annual Western Protective Relay Conference*, (WA), pp. 1–10, Schweitzer Engineering Laboratories, Inc., 2004.
- [8] R. Lippmann, "An introduction to computing with neural nets," *IEEE Assp magazine*, vol. 4, no. 2, pp. 4–22, 1987.
- [9] S. S. Haykin, S. S. Haykin, S. S. Haykin, and S. S. Haykin, *Neural networks and learning machines*, vol. 3. Pearson Upper Saddle River, NJ, USA., 2009.
- [10] M. Dorofki, A. H. Elshafie, O. Jaafar, O. A. Karim, and S. Mastura, "Comparison of artificial neural network transfer functions abilities to simulate extreme runoff data," *International Proceedings of Chemical, Biological and Environmental Engineering*, vol. 33, pp. 39–44, 2012.
- [11] M. M. Van Hulle, *Self-organizing Maps*, pp. 585–622. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012.