

Feature extraction of stator current in induction motors for the detection of bearings damage using support vectors machines

Rubén Terán^{*,a}, Ledy Guerra^a, Carlos Jiménez^b

^aDpto. de Potencia, Escuela de Ingeniería Eléctrica, Universidad de Carabobo, Venezuela.

^bDpto. de Circuitos y Mediciones, Escuela de Ingeniería Eléctrica, Universidad de Carabobo, Venezuela.

Abstract.-

The analysis of the armature current is one of the methods used to detect the incipient faults in different parts of the induction motor. In the nineties, this analysis was performed by a spectral analysis to the current and then it was compared the amplitude of the harmonics with a reference; through this, it could be inferred if the motor had faults or no. Currently, the trend is the use of classifiers based on the machine intelligence paradigm, such as: neural networks, support vector machines and fuzzy logic. This paper introduces a procedure for detecting incipient faults in ball bearings of induction motors using the aforementioned paradigm. Principally, the armature current of a three phase induction motor is acquired, which operates in normal condition and later with the defective bearings. Then to the current signal are extracted definite characteristics or features and, finally, the use of the support vector machines as classifiers. The results show that it can get diagnostics of faults in bearings with a high precision especially if the motor works in the condition of full charge.

Keywords: Support vector machine; feature extraction; failures in bearings; induction motor; predictive maintenance.

Extracción de rasgos de la corriente de armadura en motores de inducción para la detección de fallas en cojinetes utilizando máquinas de vectores de soporte

Resumen.-

El análisis de la corriente de armadura es uno de los métodos que se utilizan para la detección de fallas incipientes en las distintas partes del motor de inducción. En la década de los 90 este análisis se realizaba haciendo un análisis espectral a la corriente y luego se comparaban las amplitudes de los armónicos con unos de referencia, a partir de esto se podía inferir si el motor presentaba fallas o no. Actualmente la tendencia es el uso de clasificadores basados en el paradigma de inteligencia de máquinas, tales como: redes neuronales, máquinas de vectores soporte y lógica difusa. En este trabajo se muestra un procedimiento para la detección de fallas incipientes en cojinetes de bolas de motores de inducción usando el paradigma antes mencionado. Primeramente se adquiere la corriente de armadura de un motor de inducción trifásico, el cual opera en condición normal y luego con los cojinetes defectuosos. Luego a la señal de corriente se le extraen ciertas características o rasgos y, finalmente, el uso de las máquinas de vectores soporte como clasificador. Los resultados demuestran que se pueden obtener diagnósticos de fallos en cojinetes con una alta exactitud especialmente si el motor opera en la condición de plena carga.

Palabras clave: máquinas de vectores de soporte; extracción de características; fallas en cojinetes; motor de inducción; mantenimiento predictivo.

Recibido: agosto 2016

Aceptado: marzo 2017

*Autor para correspondencia

Correo-e: rubenteran@hotmail.com (Rubén Terán)

1. Introducción

Los cojinetes son componentes críticos en las maquinas rotatorias. Su degradación en el tiempo es una de las principales razones para que ocurra una falla [1]. En un estudio realizado por la IEEE se tiene que un 40 % de las fallas en los motores eléctricos son de cojinetes. Para detectar esta falla se pueden utilizar técnicas no invasivas, entre las que se tienen, el monitoreo de la corriente de armadura. Esta señal eléctrica contiene componentes de corriente, que están asociadas a componentes únicas de flujo rotatorio causadas por fallas tales como rotura de barras, excentricidades y daños en cojinetes [2].

En el análisis de la corriente de armadura se puede usar la señal en el dominio del tiempo, en el dominio de la frecuencia o una mezcla de ambas.

Con el propósito de disminuir la cantidad de información se pueden extraer métricas estadísticas o rasgos de la corriente, usadas hoy en día en el monitoreo de las condiciones de las máquinas, tales como: valor medio, desviación estándar, curtosis, asimetría entre otras. En este trabajo se muestra primeramente el proceso de adquisición de la corriente de armadura, luego la extracción de ciertas características o rasgos y, finalmente, el uso de las máquinas de vectores de soporte, para determinar si el motor de inducción presenta falla en cojinetes o no.

2. Fallas en cojinetes

La mayoría de los motores eléctricos usan cojinetes, estos consisten en dos anillos, uno exterior y otro interior que contienen un conjunto de bolas o elementos rodantes, puestas en unas pistas dentro de los anillos como se muestra en la Figura 1. Las fallas se clasifican de acuerdo a los elementos afectados: falla en pista externa, falla en pista interna y falla en bola [3].

Las fallas nombradas producen vibraciones causando que el entrehierro de la máquina varíe. Esta variación afecta el flujo magnético introduciendo componentes únicas de frecuencia en la corriente medida, las cuales, dependen de la geometría del cojinete y de su velocidad de giro dada por [3, 4, 5]

$f_{cojinete} = |f_1 \pm m f_{1,0}|$ donde $m = 1, 2, \dots$ f_1 es la frecuencia de la corriente y $f_{1,0}$ es una frecuencia característica que depende de la geometría del rodamiento ver Figura 1 y viene dada por la ecuación (1).

$$f_{1,0} = \frac{N_b}{2} f_r \left(1 \pm \frac{D_b}{D_j} \cos \beta \right) \quad (1)$$

donde: N_b es el número de bolas del cojinete, f_r la frecuencia mecánica del rotor en Hertz, D_b el diámetro de la bola, D_j el de la jaula y β el ángulo de contacto de las bolas con las pistas

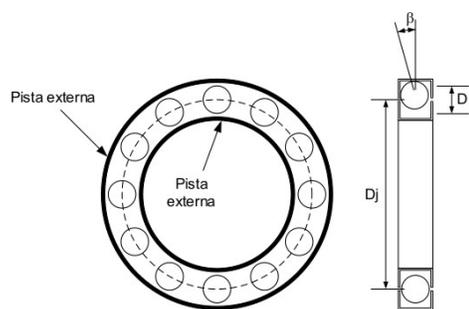


Figura 1: Dimensiones del rodamiento

3. Monitoreo de las condiciones del motor de inducción

Los motores de inducción trifásicos son máquinas simétricas que funcionan en estado normal con campos magnéticos sinusoidales en el entrehierro. Cualquier falla que ocurra alterará de alguna manera estos campos y producirá uno o más de los siguientes síntomas [6]: desbalance de tensión y corriente, aumento en las pulsaciones de par, disminución del par promedio, disminución de la eficiencia, calentamiento excesivo.

Con el monitoreo de las condiciones del motor se puede determinar el estado actual de la máquina. Este consiste en la medición de uno a varios parámetros relacionados con la condición mecánica del motor, estos se mencionan a continuación [6]: monitoreo eléctrico, monitoreo de vibraciones, monitoreo del par, monitoreo de temperatura, monitoreo químico.

En este trabajo las variables se obtuvieron con este tipo de monitoreo específicamente, por medio

de medición de la corriente del estator. El análisis espectral de la corriente del motor es una de las técnicas más usadas para la detección de la falla del motor, este consiste en la observación de las componentes del espectro de corriente en donde al ocurrir alguna falla esta producirá cambios en las componentes. Este tipo de análisis requiere la presencia de un experto el cual distinguirá el tipo, la ubicación, la magnitud y el tiempo de la falla.

4. Extracción de rasgos de la corriente de armadura

Los rasgos son valores que se obtienen de las variables medidas y que se usan como información para la realización del diagnóstico y son una parte crucial en el proceso de monitoreo de las señales, el diagnóstico final depende de la precisión y exactitud de estos. Los rasgos extraídos deben contener la información necesaria acerca de la falla y que sea suficiente para la toma de decisiones[7].

Se pueden extraer rasgos tanto de las señales medidas en el dominio del tiempo como, en el espectro en frecuencia, e inclusive una combinación de ambas. En este trabajo se obtienen de la señal en el dominio del tiempo.

En el mantenimiento predictivo se han usado métodos estadísticos para obtenerlos, arrojando buenos resultados, y estos pueden reflejar el contenido físico de la señal en el tiempo. Las siguientes métricas estadísticas se extraen en el proceso de monitoreo [7, 8]:

- Media (μ): conocida como media aritmética, es la suma de los valores divididos entre el número de valores $\mu = \frac{\sum X}{n}$
- Raíz media cuadrática (RMS): es la raíz de la media de los cuadrados de los valores $RMS = \sqrt{\frac{\sum X^2}{n}}$
- Media cuadrática (MC): es la media de la raíz cuadrada de la suma de los datos $MC = \frac{\sqrt{\sum X^2}}{n}$
- Mediana (MD): es el valor central de un conjunto de datos obtenido una vez que

estos se han ordenado de forma ascendente o descendente.

- Varianza (σ^2): es la media de los cuadrados de la distancia de cada valor con respecto a su media $var = \sigma^2 = \frac{\sum (x-\mu)^2}{n-1}$.
- Desviación estándar (σ): es una medida de la energía del contenido de la señal. Es la raíz cuadrada de la varianza $sd = \sigma = \sqrt{\frac{\sum (x-\mu)^2}{n-1}}$.
- Valor pico (X_{peak}): es la media de dos picos (máximo y mínimo) de todos los ciclos medidos $X_{peak} = \sum_{i=1}^N \left(\frac{|max_i| + |min_i|}{2N} \right)$ donde N es el número de ciclos.
- Error estándar de la media (sdm): es la desviación estándar de la distribución de errores o fluctuaciones aleatorias $sdm = \frac{sd}{\sqrt{n}}$
- Curtosis: mide cuan puntiaguda es una distribución con respecto a un estándar $curtosis = \frac{\frac{1}{n} \sum (x-\mu)^4}{\left(\frac{1}{n} \sum (x-\mu)^2 \right)^2}$.
- Asimetría (SK): mide el grado de asimetría de la distribución respecto a su media $SK = \frac{n}{n-1} \frac{\sum (x-\mu)^3}{sd}$.
- Factor de cresta (FC): es la razón entre el valor pico y el valor rms $FC = \frac{X_{peak}}{RMS}$.
- Mínimo valor: es el mínimo valor de un conjunto de datos.
- Máximo valor: es el valor máximo valor de un conjunto de datos.
- Suma: es la suma de todos los valores de una señal.
- Rango: es la diferencia entre el máximo valor y el mínimo valor.

5. Transformación de datos reduciendo su dimensión

Al tener datos con un número alto de rasgos es probable que se tenga exceso de información o inclusive redundancia, para estos casos existen

métodos para reducir la dimensión de los datos con la mínima pérdida de información. En el caso de datos numéricos, como ocurre en este trabajo, entre las técnicas más usadas se tienen: Análisis de Componentes Principales, Análisis Factorial y Transformada de Wavelet [9].

Suponga que los datos consisten en un conjunto de vectores con n atributos, el Análisis de Componentes Principales PCA (de sus siglas en ingles, Principal Components Analysis) busca vectores ortogonales de k dimensiones (con $k \leq n$) que puedan ser usados para representarlos. Los datos originales quedan así proyectados en un espacio reducido resultando en una reducción de su dimensión. El procedimiento básico es el siguiente [9]:

1. Se normalizan los datos. Esto garantiza que los atributos de mayor valor no prevalezcan sobre los de menor valor.
2. Se determinan los vectores ortogonales. Estos se conocen como componentes principales (PC_1, PC_2, \dots, PC_n). Los datos de entrada se expresan como combinación lineal de estos vectores. En un principio, la dimensión de las componentes principales es igual a la de los datos originales.

$$\begin{aligned}
 PC_1 &= a_{11}X_1 + a_{12}X_2 + \dots + a_{1n}X_n \\
 &\quad \vdots \\
 PC_n &= a_{n1}X_1 + a_{n2}X_2 + \dots + a_{nn}X_n
 \end{aligned}
 \tag{2}$$

donde: PC_i son las componentes principales, X_i los rasgos originales y a_{ij} los pesos de las variables

3. Las componentes principales se ordenan en orden decreciente. La primera componente será la de mayor varianza, la segunda será la siguiente con mayor varianza y así sucesivamente.
4. El tamaño de los datos se puede reducir eliminando las componentes de menor varianza.

La primera componente (PC_1) se obtiene de forma que su varianza sea máxima sujeta a la restricción de que la suma de los pesos a_{1j} al cuadrado sea igual a la unidad: $\max V(PC_1)$ sujeto a $\sum_{j=1}^n a_{1j}^2 = 1$

Se puede demostrar que para maximizar $V(PC_1)$ se toma el mayor valor propio (λ_1) de la matriz de varianza V , para maximizar $V(PC_2)$ se toma el segundo mayor valor propio (λ_2) y así sucesivamente.

Cuando las variables originales están muy correlacionadas entre sí, la mayor parte de su variabilidad se puede expresar con muy pocas componentes. Si las variables originales estuvieran completamente no correlacionadas entre sí, entonces el PCA no tendría ningún sentido, ya que las componentes principales coincidirían con las originales.

Para escoger las componentes a retener se seleccionan aquellas que tengan las varianzas mas altas, de manera de que el intervalo de confianza sea mayor al 95 %.

6. Máquinas de vectores de soporte

La máquina de vectores de soporte SVM (por sus siglas en ingles, Support Vector Machines) es un método general para la resolución de problemas de clasificación, regresión y estimación. La idea principal de las SVM es separar los datos por medio de una función, la cual es obtenida de una muestra de estos. A manera de ejemplo la Figura 2 muestra como se separan datos de distinta clase por medio de una recta.

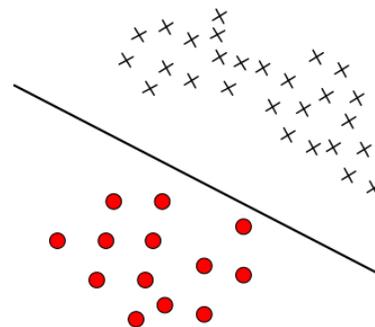


Figura 2: Los datos están separados por un plano clasificador [10]

El problema puede formularse de la siguiente manera se tiene un conjunto de datos los cuales pueden dividirse en dos grupos, a cada grupo se le asigna un valor o etiqueta; en la práctica se le asignan valores de +1 (para datos positivos) y

-1 (para datos negativos). Para un conjunto de datos cada uno se representa por el vector (\mathbf{x}, y) en donde la componente \mathbf{x} tiene n atributos, y la componente y corresponderá a la etiqueta. Los valores de \mathbf{x} se les conocen como patrones o entradas. La clasificación se puede lograr usando la función $f : X \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$ de la manera siguiente: a la entrada $\mathbf{x} = (x_1, x_2, \dots, x_n)$ se le asignará la etiqueta +1 si $f(\mathbf{x}) \geq 0$, en caso contrario se le asignará la etiqueta -1 [10].

Considerando el caso en que $f(\mathbf{x})$ es una función lineal de $\mathbf{x} \in X$, se puede expresar de la siguiente forma:

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$$

donde \mathbf{w} es el vector de pesos y b los ajustes. El vector \mathbf{w} y el escalar b son usados para definir la posición de un hiperplano separador. Para separar los datos en positivos y negativos se usa la función $\text{sign } f(\mathbf{x})$. El hiperplano de separación óptimo es aquel que hace máxima la distancia entre el plano y las entradas mas cercanas de las distintas clases como se muestra en la Figura 3. Esta distancia se le llama margen de clasificación y viene dado por:

$$m_D(\mathbf{w}) = \frac{2}{\|\mathbf{w}\|}$$

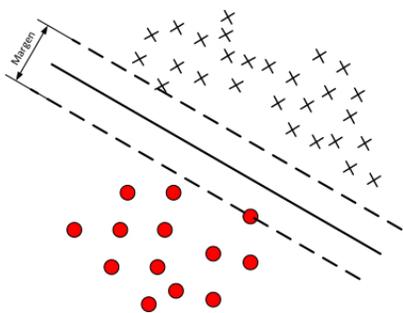


Figura 3: Clasificación con hiperplano. El margen de clasificación viene dado por la distancia entre los puntos de cada clase que son más cercanos al hiperplano [10]

Para determinar el mínimo margen de clasificación se debe resolver el siguiente problema de optimización, minimizar

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i$$

condicionado a $y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i$, $i = 1, \dots, n$ donde ξ_i es la distancia medida entre el margen y el punto \mathbf{x}_i que se encuentra en el lado incorrecto de este, C es un factor de penalización.

Usando el método de los multiplicadores de Lagrange, podemos obtener la formulación *dual*, la cual es expresada en términos de la variable α_i [11], maximizar

$$\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j \mathbf{x}_i^T \mathbf{x}_j$$

condicionado a $\sum_{i=1}^n y_i \alpha_i = 0$, $0 \leq \alpha_i \leq C$

La formulación dual conduce a una expansión del vector de pesos en función de los datos de entrada:

$$\mathbf{w} = \sum_{i=1}^n y_i \alpha_i \mathbf{x}_i$$

En la mayoría de las aplicaciones los datos no son linealmente separables, sin embargo se puede seguir usando un clasificador lineal el cual, es deseable porque, tiene la ventaja de algoritmos de entrenamiento rápidos. La clasificación se logra ahora transformando los datos del espacio de entrada X al espacio de características F de igual o mayor dimensión, en el que se supone una mayor separación entre las clases, usando la función no lineal ϕ [12].

Una vez que los datos están en el espacio F la función discriminante es:

$$f(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b$$

Con el propósito de reducir memoria y tiempo de cálculo el vector de pesos se expresa como una combinación lineal de los ejemplos de entrenamiento esto es $\mathbf{w} = \sum_{i=1}^l \alpha_i \phi(\mathbf{x}_i)$ entonces:

$$f(\mathbf{x}) = \sum_{i=1}^l \alpha_i k(\mathbf{x}, \mathbf{x}_i) + b$$

donde $k(\mathbf{x}, \mathbf{z})$ se define como función kernel que para todo los $\mathbf{x}, \mathbf{z} \in X$ viene dada por:

$$k(\mathbf{x}, \mathbf{z}) = \phi(\mathbf{x})^T \phi(\mathbf{z})$$

Algunas funciones kernel comunes son:

1. kernel lineal:

$$k(\mathbf{x}, \mathbf{x}_i) = \mathbf{x}^T \cdot \mathbf{x}_i$$

2. kernel polinómico de grado d :

$$k(\mathbf{x}, \mathbf{x}_i) = (\gamma \mathbf{x}^T \cdot \mathbf{x}_i + r)^d \quad \text{con } \gamma > 0$$

3. Función básica radial (RBF):

$$k(\mathbf{x}, \mathbf{x}_i) = e^{-\gamma \|\mathbf{x} - \mathbf{x}_i\|^2} \quad \text{con } \gamma > 0$$

7. Procedimiento metodológico

El procedimiento utilizado para diagnosticar fallas en los rodamientos del motor de inducción consta de cuatro pasos a saber: adquisición de los datos, extracción de rasgos, selección de rasgos y clasificación, esto se muestra en la Figura 4.

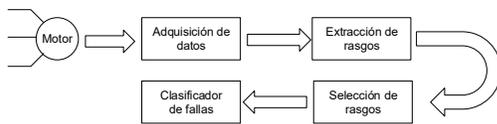


Figura 4: Arquitectura de diagnóstico de falla en cojinetes

Se adquirieron los datos de dos motores de inducción, trifásicos, jaula de ardilla de 220 V; 60 Hz; 1,2 kW 1700 rpm

La técnica que se utilizó para la recolección de datos está constituida por la medición de la corriente estatórica de un motores de inducción trifásico jaula de ardilla, el cual se encuentra ubicado en el laboratorio de mantenimiento predictivo de la Universidad de Carabobo, tal señal de corriente fue acondicionada por medio de transformadores de corriente, de tensión y arreglos de resistencia, para luego ser recolectadas a través de una tarjeta de adquisición de datos modelo USB–1208FS desarrollado por la empresa National Instruments usando el software LabView 7.0.

Para la simulación de las fallas en las pistas interna y externa se tomaron dos cojinetes en buen estado y se realizó una perforación en la pista interna de uno y en la pista externa del otro cojinete. Por otro lado la falla en los elementos rodantes se obtiene tomando un cojinete en buen

estado y lubricarlo con una grasa especial que contiene virutas de hierro, lo cual genera roce y desgaste en el cojinete a medida que el motor aumenta su velocidad.

De los parámetros de métricas estadísticas, nombradas entre las ecuaciones 3 a la 12, que se pueden tomar de la señal de corriente de armadura en el dominio del tiempo se seleccionaron: la mediana, valor medio, valor rms, varianza, desviación estándar, valor pico, curtosis, asimetría, factor de cresta, máximo valor y rango; mientras que: la media cuadrática, el error estándar, el mínimo valor y la suma se descartaron por ser combinación lineal de las anteriores.

En esta fase se entrenan las Máquinas de Vectores Soporte. El kernel escogido es la función básica radial gaussiana o por sus siglas en ingles RBF, la constante de penalización C y el parámetro de la función kernel γ se obtienen usando la técnica de validación cruzada. Para este fin se dividen los datos de entrenamientos en p subconjuntos y se hacen p pruebas, en cada una se toman $p - 1$ subconjuntos para entrenar y se deja uno como validación y para optimizar los parámetros [8, 13]. Todo esto se realiza usando la librería (gratuita para fines académicos) “libsvm”

8. Resultados

A continuación se muestran los resultados obtenidos en esta investigación en el siguiente orden: datos adquiridos, transformación de los datos y clasificación.

8.1. Datos adquiridos

Se hicieron mediciones de la corriente de armadura al motor con tres niveles de carga: vacío, con carga nominal y con una carga intermedia. En el caso de carga nominal la corriente de armadura es de 7 A y con la carga intermedia es de 5 A. Se hicieron pruebas con el motor sin fallas y luego se procedieron a hacer pruebas con las distintas fallas en cojinetes

Para cada estado del motor (sin falla, falla en bola, en pista interna y en pista externa) y por razones de logística se realizaron 90 mediciones de la corriente de armadura las cuales se dividen en:

Tabla 1: Rasgos extraídos en cada condición de operación.

Características	Vacío	Sano		Falla en Bola(FB)		
		5 A	7 A	Vacío	5 A	7 A
Media	0,0321	0,0306	0,0164	0,0282	0,0246	0,0192
FC	1,4318	1,4214	1,4149	1,4393	1,4164	1,4098
Curtosis	1,5245	1,5033	1,4999	1,5181	1,503	1,4992
Mediana	0,0367	0,0275	0,0917	0,0642	0,0184	0
RMS	3,8573	4,9966	7,0261	3,9741	5,0485	7,0549
Asimetría	-0,0054	-0,0002	0,0032	-0,0128	0,0019	0,0011
Desv Est	3,8581	4,9978	7,0278	3,975	5,0497	7,0566
Varianza	14,8851	24,9779	49,3902	15,8007	25,4993	49,7955
Max Val	5,6150	7,193	10,0739	5,7434	7,2114	10,0556
Rango	11,2024	14,3219	20,0653	11,5327	14,3953	20,0469
Val Pico	5,5229	7,102	9,9412	5,72	7,1508	9,9461

Tabla 2: Datos normalizados.

Características	Vacío	Sano		Falla en Bola(FB)		
		5 A	7 A	Vacío	5 A	7 A
Media	0,1786	0,5000	0,2321	-2,3036	-0,1964	-0,8393
FC	0,3333	1,1222	-0,0333	-0,7556	1,9556	-0,5889
Curtosis	0,8214	2,0833	-0,4405	-0,8452	1,3214	-0,4762
Mediana	-0,1711	0,5247	0,1749	2,6160	1,5703	-0,1711
RMS	-1,1291	-1,1318	-0,2556	1,3053	-1,0420	-0,2157
Asimetría	-0,2241	-1,0000	-0,1034	0,4828	-2,2759	0,2586
Desv Est	-1,1290	-1,1319	-0,2555	1,3054	-1,0420	-0,2156
Varianza	-1,0493	-1,0513	-0,3537	1,3336	-0,9880	-0,3177
Max Val	-1,1327	-1,1327	-0,2619	1,3280	-1,0618	-0,2517
Rango	-1,1336	-1,1235	-0,2627	1,3223	-1,0323	-0,2424
Val Pico	-1,1423	-1,1300	-0,2569	1,3128	-1,0210	-0,2299

Tabla 3: Componentes principales y sus coeficientes.

	a_1	a_2	a_3	a_4	a_5	a_6	a_7	a_8
PC_1	0,0095	-0,322	-0,314	0,0029	0,3653	-0,010	0,3653	0,3623
PC_2	0,4597	0,0047	-0,004	0,6586	-0,005	-0,595	-0,005	-0,006
PC_3	0,8475	-0,01	-0,029	-0,127	-0,007	0,5136	-0,007	-0,012

30 mediciones en vacío, 30 con la carga intermedia y 30 con carga nominal. En total se realizaron 360 mediciones de la corriente de armadura.

La medición de la corriente de armadura consiste en la adquisición de su magnitud en el dominio del tiempo, específicamente en 1 segundo y para una frecuencia de 2000 muestras/s se obtuvieron 2000 puntos. Para cada medición se extraen 11 rasgos: la mediana, valor medio, valor rms, varianza, desviación estándar, valor pico, curtosis, asimetría, factor de cresta, máximo valor y rango. En la Tabla 1 se muestran los rasgos extraídas en seis mediciones de corriente.

De las 360 mediciones de corriente se tomaron 135 para entrenar a las máquinas de vectores soporte y 135 distintas para probarla.

8.2. Transformación de los datos

Se utilizó un preprocesamiento de los datos, específicamente la normalización con desviación estándar; para ello se creó una matriz 11x360 en donde cada fila representa una característica y cada columna una medición. El primer paso entonces es determinar la media y la desviación estándar de cada característica. Una vez obtenidos los valores anteriores se procede a normalizar los datos según

Tabla 4: Varianza y porcentaje de varianza de cada componente.

Componente	Varianza	Porcentaje de Varianza	Porcentaje acumulado
PC_1	7,3834	67,1218	67,1218
PC_2	1,8746	17,0421	84,1639
PC_3	0,8090	7,3542	91,5181
PC_4	0,5477	4,9791	96,4972
PC_5	0,3140	2,8544	99,3516
PC_6	0,0691	0,6279	99,9795
PC_7	0,0022	0,0197	99,9992
PC_8	0,0001	0,0007	99,9999
PC_9	0,0000	0,0001	100
PC_{10}	0,0000	0,0000	100
PC_{11}	0,0000	0,0000	100

ecuación (3).

$$v'_i = \frac{v_i - \text{media}(v)}{sd(v)} \quad (3)$$

En la Tabla 2 se muestran los valores normalizados

A estos valores se les realizó el PCA obteniéndose una matriz de 11x11 en donde las filas son las componentes principales ($PC_1, PC_2, \dots, PC_{11}$) y las columnas son los coeficientes respectivos (a_1, a_2, \dots, a_{11}), en la Tabla 3 se muestran las tres primeras componentes y ocho coeficientes de cada una.

El propósito de las componentes principales es proyectar los datos en otro espacio que, en principio, tiene las mismas dimensiones (componentes) de los datos originales. Como hay componentes que presentan mayor información que otra, se pueden descartar algunas y reducir la dimensión del nuevo espacio. En la Tabla 4 se observa, en la columna Porcentaje de Varianza, que la primera componente tiene un 67,12 % de la información y la segunda un 17,04 %, entre las dos se tiene un 84,16 % de la información. Si se toman las primeras cuatro componentes el porcentaje acumulado es de 96,5 %, esto indica que se pueden retener las dos primeras componentes y descartar el resto sin perder prácticamente información ya que el intervalo de confianza es mayor al 95 %.

Para proyectar los datos normalizados en las componentes principales se debe multiplicar cada rasgo por su coeficiente respectivo, véase

ecuación (2), por ejemplo la Tabla 5 tiene los rasgos extraídas de un motor sano en vacío (primera columna Tabla 2), los coeficientes de la componente PC_1 (primera fila Tabla 3) y la multiplicación del valor de cada característica por el coeficiente asociado. Luego, al sumar cada uno de estos productos se obtiene que el valor de la componente PC_1 es -2,8103.

Tabla 5: Tabla de peso de la primera componente.

Rasgos	Datos	Coefficientes	Datos*Coeficientes
Media	0,1786	0,0095	0,0017
FC	0,3333	-0,322	-0,1074
Curtosis	0,8214	-0,314	-0,2583
Mediana	-0,1711	0,0029	-0,0005
RMS	-1,1291	0,3653	-0,4124
Asimetría	-0,2241	-0,010	0,0023
Desv Est	-1,1290	0,3653	-0,4124
Varianza	-1,0493	0,3623	-0,3802
Max Val	-1,1327	0,3646	-0,4130
Rango	-1,1336	0,3647	-0,4134
Val Pico	-1,1423	0,3648	-0,4167

Si se observa en la Tabla 5 la media, mediana y asimetría no tienen un peso importante en comparación con el del resto de los rasgos. Valores altos de la primera componente corresponderán, entonces, a datos con valores RMS, desviación estándar, varianza, Máximo Valor, Rango y Valor Pico que sean altos y, Factor de Cresta y Curtosis bajos.

8.3. Clasificación

Para la clasificación de los datos se usaron máquinas de vectores soporte con kernel RBF. Los valores de C y γ se obtuvieron utilizando la técnica de validación cruzada. Primero se clasificó con los rasgos extraídos normalizados, seguidamente con los mismos normalizados pero excluyendo la información obtenida con el motor operando en vacío, y finalmente, con las dos primeras componentes principales.

8.3.1. Clasificación con las rasgos extraídos normalizados

Se tomaron 270 mediciones de corrientes, 135 se utilizaron para entrenar a las SVM y 135 para probarlas. Se extrajeron 11 rasgos de la corriente, la Tabla 6 resume el resultado de la clasificación de

esta información. Por medio de validación cruzada se obtuvieron $C = 32$ y $\gamma = 0,5$.

Tabla 6: Resultado de la clasificación.

Condición	Carga	Cantidad Datos	Cantidad Aciertos	Porcentaje Aciertos
Sano	Vacío	15	6	40,0 %
	5 A	15	14	93,3 %
	7 A	15	13	86,7 %
Falla en Bola	Vacío	10	10	100,0 %
	5 A	10	10	100,0 %
	7 A	10	10	100,0 %
Falla en Pista Externa	Vacío	10	9	90,0 %
	5 A	10	10	100,0 %
	7 A	10	9	90,0 %
Falla en Pista Interna	Vacío	10	10	100,0 %
	5 A	10	10	100,0 %
	7 A	10	10	100,0 %
Total		135	121	89,6 %

Se observa que los niveles más bajos de aciertos se obtuvieron cuando el motor no tiene fallas y sobre todo cuando el motor opera en vacío.

Tabla 7: Clasificación sin considerar la operación en vacío.

Condición	Carga	Cantidad Datos	Cantidad Aciertos	Porcentaje Aciertos
Sano	5 A	15	15	100,0 %
	7 A	15	13	86,7 %
Falla en Bola	5 A	10	10	100,0 %
	7 A	10	10	100,0 %
Falla en Pista Externa	5 A	10	10	100,0 %
	7 A	10	9	90,0 %
Falla en Pista Interna	5 A	10	10	100,0 %
	7 A	10	10	100,0 %
Total		135	121	89,6 %

8.3.2. Clasificación con los rasgos extraídas normalizadas y el motor operando con carga

Se tomaron 180 mediciones de corrientes, 90 se utilizaron para entrenar a las SVM y 90 para probarlas. La Tabla 7 resume el resultado de la clasificación de estos datos. Por medio de validación cruzada se obtuvieron valores de $C = 8$ y $\gamma = 0,5$. Estos resultados ratifican la conclusión anterior, que los porcentajes de aciertos mejoran si no se toma en cuenta la operación del motor con carga.

8.3.3. Clasificación usando las componentes principales

Se tomaron 180 mediciones de corrientes, 90 se utilizaron para entrenar a las SVM y 90 para probarlas. Los datos se cambiaron de espacio por medio de la técnica de PCA. Se clasificó tomando las dos primeras componentes principales, luego las tres primeras componentes y por último cuatro. La Tabla 8 resume el resultado de la clasificación de esta información. Por medio de validación cruzada se obtuvieron los valores de $C = 2$ y $\gamma = 8$.

Tabla 8: Clasificación con las componentes principales.

Condición	Carga	Cantidad Datos	Componentes por aciertos		
			2	3	4
Sano	5 A	15	4 (26,7 %)	0 (0,0 %)	13 (86,7 %)
	7 A	15	9 (60,0 %)	8 (53,3 %)	7 (46,7 %)
Falla en Bola	5 A	10	9 (90,0 %)	10 (100,0 %)	9 (90,0 %)
	7 A	10	10 (100,0 %)	10 (100,0 %)	7 (70,0 %)
Falla Pista Externa	5 A	10	5 (50,0 %)	10 (100,0 %)	8 (80,0 %)
	7 A	10	7 (70,0 %)	8 (80,0 %)	10 (100,0 %)
Falla Pista Interna	5 A	10	5 (50,0 %)	10 (100,0 %)	10 (100,0 %)
	7 A	10v	10 (100,0 %)	10 (100,0 %)	10 (100,0 %)

En la Tabla 8 se observa que al aumentar el número de componentes mejora el porcentaje de aciertos pero, con solo 4 componentes se obtiene un resultado de clasificación alto. Adicionalmente los peores resultados se obtienen al clasificar los datos obtenidos cuando el motor opera en vacío.

9. Conclusiones

El análisis de la corriente de armadura es una técnica efectiva para detectar fallas en cojinetes en estado incipiente. La ventaja de esta técnica es que es de alta sensibilidad a bajo costo. En este trabajo se realizaron pruebas al motor de inducción en tres condiciones de carga. En cada condición se hicieron mediciones con cuatro estados de cojinetes: sano, falla en bola, falla en

pista externa y falla en pista interna. Se realizó una limpieza y transformación de los datos, en donde se normalizó y luego se utilizó análisis de componentes principales.

Los datos se utilizaron para entrenar las máquinas de vectores soportes. La función Kernel escogida fue RBF los valores de C y γ se obtuvieron utilizando la técnica de validación cruzada. Al tomar métricas estadística de la señal de corriente en dominio del tiempo se pueden utilizar como indicadores del estado en cojinetes del motor obteniéndose porcentajes de clasificación cercanos al 90 %.

Referencias

- [1] Li Ruoyo, Sopon Ponrit, and He David. Fault features extraction for bearing prognostics. *Journal of Intelligent Manufacturing*, 23(2):213–221, 2012.
- [2] Mehla Neelam and Dahiya Ratna. An approach of condition monitoring of induction motor using MCSA. *International Journal of Systems Applications, Engineering & Development*, 1(1):13–17, 2007.
- [3] Won-Pyo Hong, Chung-Sup Yoon, and Dong-Hwa Kim. Stator current processing-based technique for bearing damage detection in induction motor. In *ICCAS 2005: International Conference on Control, Automation, and Systems*, 2005.
- [4] M. Sin, W. Soong, and N. Ertugrul. Induction machine on-line condition monitoring and fault diagnosis—a survey. In *Australasian Universities Power Engineering Conference*, pages 1–6, Christchurch, New Zealand, 2003.
- [5] M El Hachemi Benbouzid. A review of induction motors signature analysis as a medium for faults detection. *IEEE transactions on industrial electronics*, 47(5):984–993, 2000.
- [6] Xin Wen. *A hybrid intelligent technique for induction motor condition monitoring*. Doctoral Thesis, University of Portsmouth, 2011.
- [7] C. Jiménez y J. Jiménez. Clasificación de señales de voz utilizando transformada de wavelet y máquinas de vectores de soporte. Trabajo de Ascenso, Facultad de Ingeniería, Universidad de Carabobo, 2010.
- [8] M. M. A. Bin Hasan. *Current based condition monitoring of electromechanical systems. Model-free drive system current monitoring: faults detection and diagnosis through statistical features extraction and support vector machines classification*. Doctoral Thesis, Universidad de Bradford, 2012.
- [9] César Pérez y Daniel Santín. *Minería de datos: técnicas y herramientas*. Ediciones Paraninfo, S.A., 2007.
- [10] Achmad Widodo and Bo-Suk Yang. Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical Systems and Signal Processing*, 21(6):2560–2574, 2007.
- [11] Asa Ben-Hur and Jason Weston. A user’s guide to support vector machines. *Data Mining Techniques for the Life Sciences*, pages 223–239, 2010.
- [12] Steve R Gunn et al. Support vector machines for classification and regression. Technical report, Science and Mathematics School of Electronics and Computer Science, Faculty of Engineering, University of Southampton, 1998.
- [13] Alex J Smola and Bernhard Schölkopf. Learning with kernels: support vector machines regularization optimization and beyond. In *Adaptive computation and machine learning*. The MIT Press, 2002.