

Detection of incipient faults of bearings in a Generator Synchronous using Support Vector Machines (SVMs)

Aniello Sparano , Jesús Ramírez , Ledy Guerra* , Rubén Terán 

Departamento de Potencia, Escuela de Ingeniería Eléctrica, Universidad de Carabobo, Valencia, Venezuela

La selección de este artículo fue realizada en el marco de la Jornada de Investigación de la Escuela de Ingeniería Eléctrica "Prof. César Rodolfo Ruiz" Octubre 2020, siendo la evaluación, arbitraje, aceptación y edición a cargo de Revista Ingeniería UC.

Abstract.- Since the synchronous machine in its operation as a generator constitutes a vital element in electrical power systems, programs development and predictive maintenance techniques, in order to identify and fix problems in the machine before irreversible damage is done, is priority. A methodology is established below to detect incipient failures in a tested synchronous generator bearings using Support Vector Machines (SVM). Phase currents analysis is presented, using various methods for data reduction and matching algorithms learning based on support vector machines as data classifier element, in order to obtain a model that is capable of discriminate the condition of a machine, as far as mechanical failures are concerned. The training of support vector machines to obtain the classification criteria was executed using MatLab's SVM commands. The functions provided by this software allowed: training, optimization and subsequent classifier validation. The results obtained showed that the method applied based on SVM has a good fault recognition ability presented in the different components of the bearing, for different operating conditions.

Keywords: synchronous generator; failures; bearings; armature current; support vector machines (SVM); predictive maintenance.

DetECCIÓN DE FALLAS INCIPIENTES EN RODAMIENTOS DE GENERADORES SINCRÓNICOS UTILIZANDO MÁQUINAS DE VECTORES DE SOPORTE

Resumen.- Dado que la máquina sincrónica en su funcionamiento como generador constituye un elemento vital en los sistemas eléctricos de potencia, el desarrollo de programas y técnicas de mantenimiento predictivo, a fin de identificar y solucionar problemas en la máquina antes de que se produzcan daños irreversibles en la misma es prioridad. A continuación se establece una metodología para detectar fallas incipientes en rodamientos de un generador sincrónico de prueba a través de máquinas de vectores de soporte (SVM por sus siglas en inglés). Se presenta el análisis de las corrientes de fase, utilizando métodos variados para la reducción de los datos y algoritmos de aprendizaje automático basados en las máquinas de vectores de soporte como elemento clasificador de datos; a fin de obtener un modelo que sea capaz de discriminar la condición de una máquina, en cuanto a fallas mecánicas se refiere. El entrenamiento de las máquinas de vectores de soporte para obtener los criterios de clasificación se ejecutó utilizando los comandos para SVM de MatLab, las funciones que brinda este software permitieron: el entrenamiento, la optimización y la posterior validación de los clasificadores. Los resultados obtenidos demostraron que el método aplicado basado en la SVM posee una buena capacidad de reconocimiento de fallas presentadas en los diferentes componentes del rodamiento, para distintas condiciones de operación.

Palabras clave: generador sincrónico; fallas; rodamientos; corriente de armadura; máquinas de vectores de soporte; mantenimiento predictivo.

Recibido: 22 de octubre, 2020.

Aceptado: 23 de enero, 2021.

1. Introducción

Los generadores sincrónicos son esenciales en el proceso de conversión de energía eléctrica, por lo que su uso hoy en día se ha vuelto indispensable para el desarrollo y funcionamiento de la sociedad tal como la conocemos. Este tipo de máquinas

* Autor para correspondencia:
Correo-e: llguerra@uc.edu.ve (L. Guerra)

está propensa a sufrir tanto fallas externas como internas, siendo que estas últimas pueden ocurrir tanto en el rotor como en el estator de la máquina. Las principales fallas que pueden presentarse en estas máquinas son: [1, 2, 3]

- Fallas en rodamientos. (40–50 %)
- Fallas en aislamiento del estator. (30–40 %)
- Fallas en el devanado de amortiguamiento. (5–10 %)
- Excentricidad y otras.

Los rodamientos son elementos sobre los que se apoyan los dos extremos del eje que sustenta a la parte móvil de toda máquina eléctrica rotativa. Por consiguiente cualquier desperfecto que pueda presentar la máquina se traduce en esfuerzos mecánicos sobre estos dispositivos, razón por la que son los componentes con el porcentaje de falla más elevado [1].

El resultado de estas fallas se traduce en un daño o deterioro de la máquina, el cual puede impedir su óptimo desempeño y acarrear como consecuencias reducción del rendimiento, degradación en la calidad de energía generada así como disminución de la producción, desbalances en el sistema eléctrico, originar fallas más severas, entre otras; razón por la cual resulta necesario determinar la existencia de las fallas en estado incipiente.

El desarrollo de técnicas para supervisión de las condiciones de operación de las máquinas eléctricas rotativas, permite monitorear las variables de estado de la máquina a fin de detectar problemas incipientes antes de que se presenten fallas catastróficas. Se han desarrollado estudios y técnicas enfocadas en la detección, predicción y diagnóstico de fallas a través de sistemas de monitoreo continuo mientras la máquina esta en operación, mediante la medición de distintas variables y parámetros que representen síntomas de mal funcionamiento, con la finalidad de evitar fallas peligrosas, paradas de emergencia, preservar la vida útil del equipo y reducir costos en la producción y el mantenimiento, [4, 5]. En este sentido, los resultados obtenidos en esta investigación muestran que con las SVM se puede discriminar el estado de los rodamientos de una máquina sincrónica en su estado incipiente, lo que

contribuye a establecer planes de mantenimiento predictivo asociados a dichas máquinas.

2. Campos magnéticos en máquinas sincrónicas

Las máquinas sincrónicas son máquinas eléctricas donde la velocidad mecánica de rotación η se encuentra entrelazada o sincronizada con la frecuencia de la red eléctrica f en la cual están operando. La relación entre la velocidad de rotación de los campos magnéticos de la máquina y la frecuencia eléctrica del estator se expresa mediante la ecuación (1).

$$\eta = \frac{120}{p} f, \quad (1)$$

donde:

η : Velocidad de rotación, rpm.

f : Frecuencia de la red, Hz.

p : número de polos de la máquina, adim.

El campo magnético en el entrehierro de una máquina eléctrica es el resultado de las Fuerzas Magnetomotriz (Fmm) combinadas de los devanados inductor (normalmente en el rotor de la máquina sincrónica) e inducido normalmente en el estator de la máquina sincrónica), que actúan en esa región. En principio, el devanado inductor es el que produce el campo magnético en el entrehierro (campo del rotor), induciendo Fuerzas Electromotrices (Fem) en el devanado del inducido, que dan lugar a corrientes cuando se cierra el circuito. Al circular estas corrientes se crea una Fmm de reacción de inducido o de armadura que produce un campo magnético de armadura (campo del estator) que al combinarse con la F.m.m. del inductor, produce una Fmm resultante que produce un campo magnético resultante en el entrehierro de la máquina. En las máquinas eléctricas de corriente alterna se puede aproximar a que la distribución espacial de los campos magnéticos a lo largo del entrehierro, es sinusoidal, tal como se muestra en la Figura 1.

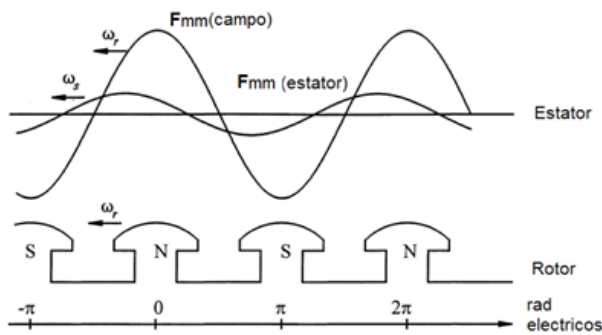


Figura 1: Distribución espacial de las Fuerzas Magnetomotrices en el entrehierro de la Máquina Síncrona [6]

3. Fallas en rodamientos


El rodamiento es una pieza que realiza una conexión móvil entre dos elementos de un mecanismo permitiendo la rotación de un elemento respecto al otro, con precisión y mínima fricción. En las máquinas eléctricas, los rodamientos deben soportar y mantener el eje del rotor, garantizando que el entrehierro de la máquina sea de un tamaño y distribución, adecuado y uniforme, de forma tal que se transfieran cargas mecánicas del eje a la carcasa de la máquina. Estos elementos deben operar a altas y bajas velocidades, minimizando la fricción y reduciendo las pérdidas de energía. En máquinas pequeñas y horizontales, los rodamientos que comúnmente se emplean son los rodamientos rígidos de bolas [7, 5].

Todos los rodamientos están compuestos básicamente por: pista exterior (PE), pista interior (PI), elementos rodantes (ER) y jaulas. En la Figura 2 se indican las partes de un rodamiento y se muestra que los elementos rodantes (bolas y rodillos), se encuentran alojados entre los aros. La jaula asegura la rodadura de los elementos.

- Pistas (Exterior e Interior): Los aros o pistas de los rodamientos soportan cargas que transmiten a los asientos de los ejes o estructuras de soporte tales como los alojamientos. Estos aros presentan un camino de rodadura endurecida donde se localizan y en el que rotan los elementos rodantes.
- Elementos Rodantes: Los elementos rodantes se clasifican en dos grupos: bolas y rodillos.

Los rodillos, a su vez, pueden ser: cilíndricos, de agujas, cónicos y esféricos.

- Jaula: Las jaulas se utilizan para contener a las bolas o rodillos y mantener la distancia entre los mismos en su dirección circunferencial. Estas se fabrican por prensado o forjado con aceros más blandos, poliamida, resina fenólica, latón o bronce.



Fuente: SKF (2004) Rolling Bearings in Electric Motors and Generators

Figura 2: Partes de un Rodamiento

Como toda pieza mecánica, los rodamientos tienen un tiempo de vida útil. Este tiempo está asociado a la velocidad de operación así como a la carga dinámica y estática que pueden soportar. Asimismo, el tiempo de vida depende de las condiciones de operación presentes, por lo que alteraciones en las mismas pueden producir fallas en los rodamientos, comprometiendo el desempeño del proceso de la máquina. Entre las principales causas de fallas en rodamientos se tiene [8, 7]:

- Carga excesiva.
- Desgaste por lubricación deficiente o excesiva.
 - Desgaste ocasionado por partículas abrasivas.
 - Desgaste ocasionado por lubricación inadecuada.
- Exposición a vibración mientras el rodamiento no se encuentra rodando.
- Contaminación externa.
- Instalación Incorrecta.
- Fatiga.
- Cambios bruscos de velocidad.

4. Máquinas de Vectores de Soporte (SVM por sus siglas en inglés)

Las máquinas de vectores de soporte (SVM, del inglés Support Vector Machines) fueron concebidas como un algoritmo para resolver problemas de clasificación binaria, hoy en día se han desarrollado como una técnica robusta para clasificación y regresión aplicadas a grandes conjuntos de datos complejos, apoyándose en criterios de generalización y optimización matemática. La SVM consiste en un modelo de clasificación que sirve como herramienta para distinguir objetos pertenecientes a distintas categorías o clases. Para obtener el modelo de clasificación es necesario cumplir dos fases: entrenamiento y prueba [9, 10, 11].

En la fase de entrenamiento, en base a las propiedades del conjunto inicial de datos, se seleccionan los parámetros que serán utilizados para definir la separación de clases. En esta fase, el algoritmo de aprendizaje define, en función a los ejemplos de entrenamiento, los elementos cuya clase es conocida, un hiperplano de separación, el cual establece el límite para distinguir entre los elementos pertenecientes a cada clase. Este plano se define a través de vectores construidos por los puntos más cercanos de cada clase al límite de separación, los cuales son llamados vectores de soporte. Posteriormente, en la fase de prueba, el modelo de separación entre clases, es aplicado a un conjunto de muestras (conjunto de pruebas) cuyas etiquetas de clase se desconocen, con el objetivo de determinar su clase. A continuación se describen los modelos de clasificación considerando que los datos son linealmente separables, que los datos son cuasi separables linealmente y que los datos no son separables linealmente [1, 12].

El modelo más simple de las SVM, conocido como clasificador de margen máximo, funciona sólo para datos linealmente separables en el espacio de características, es decir, se tiene un conjunto de datos en el que cada punto de entrenamiento $x_i \in R^n$ se corresponde con alguna de dos posibles clases, las cuales se designan con un valor $y_i \in \{-1, 1\}$ para $i = 1, \dots, l$.

Inicialmente, para un conjunto de entradas

separables linealmente, denotado como $S = (x_1; y_1); \dots; (x_n; y_n)$, se puede definir un hiperplano de separación como una función lineal de la forma indicada en la ecuación (2).

$$D(x) = \langle w \cdot x \rangle + b. \quad (2)$$

Donde w representa el vector normal del plano y b es llamado el intercepto del plano. El vector normal define la orientación del plano en el espacio, mientras que la relación entre la norma del vector w y b , define la distancia entre el hiperplano y el origen del espacio. Ambos parámetros son coeficientes reales, además el hiperplano de separación cumplirá con las restricciones indicadas en la ecuación (3) para todo x_i del conjunto de ejemplos:

$$\begin{aligned} \langle w, x_i \rangle + b &\geq 0 & \text{si } y_i = +1 \\ \langle w, x_i \rangle + b &\leq 0 & \text{si } y_i = -1, i = 1, \dots, n. \end{aligned} \quad (3)$$

En la Figura 3 se muestran los posibles hiperplanos que permiten la separación de los datos. Como se observa, el plano de separación no es único. Para ello se hace necesario fijar un criterio de optimización, entonces se define el margen (τ) de un hiperplano, el cual representa la distancia mínima entre el plano y los ejemplos de cada clase más cercanos al mismo; por consiguiente un hiperplano es óptimo si su margen es máximo, en otras palabras, el hiperplano de separación a seleccionar, será aquel que entre el conjunto de infinitos planos, guarde la máxima distancia entre él y los ejemplos más cercanos de ambas clases.

La distancia entre el plano y un punto de ejemplo x' viene dada por la ecuación (4).

$$\frac{D(x')}{\|w\|}. \quad (4)$$

Tomando en cuenta las restricciones de la ecuación (2), todos los ejemplos de entrenamiento cumplirán con la ecuación (5).

$$\frac{y_i D(x_i)}{\|w\|} \geq \tau, \quad \text{con } i = 1, \dots, n. \quad (5)$$

Por consiguiente, encontrar el hiperplano óptimo equivale a encontrar el valor de w que maximice




Figura 3: N posibles hiperplanos de separación en un espacio bidimensional [11]

el margen. Comprendiendo que existen infinitas soluciones que difieren solo en la escala de w , se reduce el número de posibles soluciones a una sola, fijando arbitrariamente el valor del producto de τ y la norma w , igual a la unidad, quedando como la ecuación (6).

$$\tau \|w\| = 1. \tag{6}$$

De esta manera, aumentar el margen equivale a disminuir el valor de la norma del vector w . La maximización del margen estará directamente relacionada con la capacidad de generalización del hiperplano de separación, de forma tal que a mayor margen, existirá mayor distancia de separación entre las clases. Por lo tanto, un hiperplano óptimo de separación, de acuerdo con su definición, es aquel que posee un margen máximo, en consecuencia, un mínimo valor de $\|w\|$, sujeto la restricción indicada en la ecuación (7).

$$y_i(\langle w, x_i \rangle + b) \geq 1, i = 1, \dots, n; y_i \in (-1, 1). \tag{7}$$

La restricción presentada reflejará una relación de igualdad para los ejemplos que están situados a ambos lados del hiperplano óptimo y que definen el margen; estos reciben el nombre de vectores soporte. Puesto que estos ejemplos son los más cercanos al hiperplano de separación, serán los más difíciles de clasificar y, por tanto, deberían ser los únicos ejemplos a considerar al momento de construir ese hiperplano. Estos puntos se observan en la Figura 4.

En este sentido, para encontrar el hiperplano equidistante a las dos clases linealmente separables




Figura 4: Margen máximo de separación e hiperplano óptimo de ejemplos linealmente separables [10]

en el espacio de entrada, es necesario encontrar solución al problema de optimización de la ecuación (8).

$$\begin{aligned} \text{Max} &\rightarrow \frac{1}{\|w\|} \\ \text{sujeto a } &y_i(\langle w, x_i \rangle + b) \geq 1, i = 1, \dots, n. \end{aligned} \tag{8}$$

Que se puede escribir como la ecuación (9).

$$\begin{aligned} \text{Min} &\rightarrow \frac{1}{2} \langle w, w \rangle \\ \text{sujeto a } &y_i(\langle w, x_i \rangle + b) \geq 1, i = 1, \dots, n. \end{aligned} \tag{9}$$

De acuerdo a la teoría de optimización, el problema primal tiene una forma dual si la función objetivo y las restricciones son funciones que no tienen máximos o mínimos locales. De esta manera, resolver el problema dual implica obtener la solución del problema primal.

Inicialmente se construye un problema de optimización sin restricciones, utilizando el Lagrangiano del problema primario, como la ecuación (10).

$$\begin{aligned} \mathcal{L}(w, b, \alpha) &= \frac{1}{2} \langle w, w \rangle \\ &- \sum_{(i=1)}^n \alpha_i (y_i(\langle w, x_i \rangle + b) - 1). \end{aligned} \tag{10}$$

Donde $\alpha_i \geq 0$ representa los multiplicadores de Lagrange, los cuales indican la dificultad intrínseca en el cumplimiento de cada una de las restricciones de la función objetivo, mientras mayor es el valor del multiplicador, más difícil es cumplir con la restricción asociada a $(y_i(\langle w, x_i \rangle + b) - 1)$.

El siguiente paso consiste en aplicar las condiciones de Karush – Kuhn – Tucker, indicadas en las ecuaciones (11), (12) y (13).

$$\frac{\partial \mathcal{L}(w^*, b^*, \alpha)}{\partial w} = w^* - \sum_{i=1}^n \alpha_i x_i y_i = 0, \quad (11)$$

$$\frac{\partial \mathcal{L}(w^*, b^*, \alpha)}{\partial b} = \sum_{i=1}^n \alpha_i y_i = 0, \quad (12)$$

$$\alpha_i (1 - y_i(\langle w^*, x_i \rangle + b^*)) = 0. \quad (13)$$

Obteniéndose las ecuaciones (14) y (15).

$$w^* = \sum_{i=1}^n \alpha_i x_i y_i, \quad (14)$$

$$\sum_{i=1}^n \alpha_i y_i = 0. \quad (15)$$

Sustituyendo en la ecuación (9) se obtiene la ecuación (16).

$$\mathcal{L} = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle x_i \cdot x_j \rangle. \quad (16)$$

Se ha transformado el problema primal en su correspondiente dual que consiste en maximizar la ecuación (16) sujeto a las restricciones de la ecuación (15) y a que $\alpha_i \geq 0, 1, \dots, n$.

De esta manera el vector de peso w^* queda en función de α^* como se muestra en la ecuación (17).

$$w^* = \sum_{i=1}^n \alpha_i y_i x_i. \quad (17)$$

El valor de b no aparece en el problema dual por lo que b^* se obtendrá a partir de la ecuación (13), en la que se cumple la condición de $\alpha_i > 0$, como se indica en la ecuación (18).

$$y_i(\langle w^*, x_i \rangle + b^*) = 1. \quad (18)$$

El ejemplo (x_i, y_i) satisface la condición del problema primal de la ecuación (9). Adicionalmente, los ejemplos del entrenamiento que satisfacen la condición de igualdad, es decir aquellos que tienen multiplicadores de Lagrange distintos de cero, serán un vector de soporte. Despejando b^* de la ecuación (18) se tiene la ecuación (19).

$$b^* = y_{v_s} - \langle w^*, x_{v_s} \rangle. \quad (19)$$

Donde (x_{v_s}, y_{v_s}) representa al vector soporte con su respectiva clase. Sin embargo en la práctica se obtiene el valor de b^* a partir del promedio de todos los vectores de soporte, tal como se indica en la ecuación (20).

$$b^* = \frac{1}{N_{v_s}} \sum_{i=1}^{N_{v_s}} (y_{v_s} - \langle w^*, x_{v_s} \rangle). \quad (20)$$

Conocidos w^* y b^* el hiperplano óptimo se puede expresar de acuerdo a la ecuación (21).

$$D(x) = \sum_{i=1}^n \alpha_i^* y_i \langle x, x_i \rangle + b^*. \quad (21)$$

En algunos casos los datos no son linealmente separables en el espacio de entrada, por lo que la estrategia a seguir es permitir la clasificación errónea de algunos ejemplos del conjunto de datos de entrenamiento. Se considera que un ejemplo es no separable si no cumple la condición en (7), lo que equivale a dos posibles opciones; la primera donde el ejemplo cae dentro del margen asociado a la clase correcta, de acuerdo con la frontera de decisión establecida por el hiperplano de separación seleccionado; y la segunda donde el ejemplo cae en el lado equivocado de la frontera de decisión.

Para abordar este problema, se añade a la condición del hiperplano de separación, un conjunto de variables reales y positivas, denominadas variables de holgura, $\varepsilon_i, = 1, \dots, n$; estas permitirán cuantificar el número de ejemplos no separables que se está dispuesto a admitir, quedando la restricción del hiperplano de acuerdo a la ecuación (22).

$$y(\langle w, x_i \rangle + b) \geq 1 - \varepsilon_i, \varepsilon_i \geq 0, \quad (22)$$

$$i = 1, \dots, n; y_i \in (-1, 1).$$

Para un ejemplo (x_i, y_i) , ε_i representa la desviación en caso de ser un ejemplo no separable, por lo que una variable de error de valor cero corresponde a un ejemplo separable, si es mayor que cero corresponde a un ejemplo no separable y mayor que uno corresponde a un ejemplo no separable y mal clasificado. La sumatoria de todas las variables de error permite tener una idea del precio asociado al número de ejemplos que son no separables; donde mientras mayor sea esta sumatoria, menor es la precisión de la clasificación. En la Figura 5 se muestra margen máximo de separación con la adición de la variable de error.

En la ecuación (23) y (24) se muestra la función a optimizar, la cual cuenta con C , un parámetro contante elegido por el usuario para controlar el grado de influencia del término de error de ejemplos no separables (ε_i) que permite regular la proporción entre el sobreajuste del clasificador final y el número de ejemplos no separables. En tal sentido, si C tiene un valor muy alto, permitirá tener valores de ε_i pequeños, donde si el límite de C se tender a infinito, todos los ε_i serán iguales a cero; por lo que se estaría considerando que el total del conjunto de datos es separable lo que acarrea un sobreajuste del clasificador. Si por el contrario el valor de C es muy pequeño, en el caso límite tendiendo a cero, se estaría permitiendo que los ejemplos tengan asociados valores de ε_i muy grandes, por lo que los ejemplos son mal clasificados. Se considera que $C \sum_{i=1}^n \varepsilon_i$ es un término del coste asociado a la clasificación de los elementos.

$$f(w, \varepsilon) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \varepsilon_i, \quad (23)$$

$$\text{Min} \rightarrow \frac{1}{2} \langle w, w \rangle + C \sum_{i=1}^n \varepsilon_i. \quad (24)$$

Con las restricciones indicadas en la ecuación (25).

$$\begin{aligned} y_i(\langle w, x_i \rangle + b + \varepsilon_i - 1) &\geq 0; \\ \varepsilon_i &\geq 0, i = 1, \dots, n. \end{aligned} \quad (25)$$

Al igual que para el problema de los casos linealmente separables se procede con la metodología




Figura 5: Margen máximo de separación de ejemplos cuasi-separables, con la adición de la variable de holgura [10]

de dualidad mostrada anteriormente obteniendo la ecuación (26).

$$\text{Max} \rightarrow \sum_{(i=1)}^n \alpha_i - \frac{1}{2} \sum_{(i,j=1)}^n \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle. \quad (26)$$

Con las restricciones de la ecuación (27).

$$\sum_{i=1}^n \alpha_i y_i = 0; 0 \leq \alpha_i \leq C; i = 1, \dots, n. \quad (27)$$

La solución a este problema permite expresar la frontera de decisión en términos de los coeficientes α_i^* como se muestra en la ecuación (28).

$$D(x) = \sum_{i=1}^n \alpha_i^* y_i \langle x, x_i \rangle + b^*, \quad (28)$$

donde b^* viene dado por la ecuación (29).

$$b^* = y_i \sum_{j=1}^n \alpha_j^* y_j \langle x_j, x_i \rangle; \quad (29)$$

$$\forall \alpha_i \text{ tal que } 0 < \alpha_i < C.$$

Adicionalmente existen conjuntos de datos que no son linealmente separables, por lo que resulta necesario hacer una transformación del espacio de entrada a un espacio de mayor dimensionalidad utilizando funciones de transformación llamadas Kernel para buscar el hiperplano óptimo en ese nuevo espacio [9, 10, 11].

Una función Kernel es una función $K : X \times X \rightarrow R$ que asigna a cada par de

elementos del espacio de entrada X , un valor real correspondiente al producto escalar interno de las imágenes de los elementos del espacio de entrada, en un nuevo espacio llamado espacio de características. La función Kernel se expresa como se indica en la ecuación (30).

$$\begin{aligned} \phi : X &\rightarrow F \\ K(x \cdot x') &= \langle \phi(x), \phi(x') \rangle = \langle \phi_1(x), \phi_1(x') \rangle \\ &+ \dots + \langle \phi_m(x), \phi_m(x') \rangle. \end{aligned} \quad (30)$$

En la Figura 6 se muestra la transformación del espacio de entrada al espacio de características, donde la función ϕ permite realizar dicha transformación de un espacio donde los datos no son linealmente separables a un espacio donde sí lo son.




Figura 6: Transformación de un espacio de entrada a un espacio de características [9]

En la Figura 7 se evidencia que los datos que no son linealmente separables en el espacio de entrada de dos dimensiones, pueden separarse linealmente en el espacio tridimensional de características.




Figura 7: Separación de clases mediante una función Kernel [9]

Como se explicó anteriormente el problema se reduce a la optimización de la ecuación (31).

$$\text{Max} \rightarrow \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j). \quad (31)$$

Con la restricción indicada en la ecuación (32).

$$\sum_{i=1}^n \alpha_i y_i = 0, 0 \leq \alpha_i \leq C, 1 = 1, \dots, n. \quad (32)$$

En la Tabla 1 se muestra las funciones Kernel más utilizadas.

Varios estudios realizados sobre la eficacia del entrenamiento de máquinas de vectores de soporte coinciden en que es recomendable empezar el entrenamiento a través del Kernel RBF, ya que esta función permite realizar mapeos no lineales de ejemplos a una mayor dimensión, a diferencia del Kernel lineal, el RBF puede manejar casos en los que la relación entre las etiquetas y los atributos (datos de entrenamiento) no es lineal. Adicionalmente el Kernel RBF permite facilidades en la selección de parámetros, ya que solo es necesario que el usuario escoja los parámetros C y γ , a diferencia de otras funciones las cuales requieren que se fijen parámetros adicionales.

Tabla 1: Funciones Kernel más comunes [10]

Kernel Lineal	$K(x, x') = \langle x, x' \rangle$
Kernel polinómico de grado p	$K_p(x, x') = (\gamma \langle x, x' \rangle + \tau)^p$
Kernel gaussiano o Función de Base Radial (RBF):	$K_p(x, x') = e^{-\gamma \ x - x'\ ^2}, \gamma > 0$
Kernel Sigmoid	$K(x, x') = \tanh(\gamma \langle x, x' \rangle + \tau)$

Sin embargo, existen algunas situaciones en las cuales el Kernel RBF no es confiable, en particular cuando el número de características es muy grande, se puede usar el Kernel lineal. Si el número de características es grande, tal vez no se necesita mapear la data a un espacio de mayor dimensión. Esto se debe a que el mapeo no lineal no mejora el desarrollo. Usar el kernel lineal es suficiente, y solo se necesita ajustar el parámetro C .

En principio se desconoce cuáles serán los mejores valores de C y γ para un problema determinado, en consecuencia, se debe llevar a cabo un procedimiento para la selección de los mismos. El objetivo de la selección de parámetros es identificar valores (C, γ) de manera que el clasificador realice eficientemente la predicción de datos de prueba.

La forma más común de llevar a cabo el procedimiento es separar los datos en tres partes, donde algunos autores recomiendan que se debe escoger el 50 % de ellos para entrenamiento, 25 % como conjunto de prueba y el 25 % restante como conjunto de validación. Asimismo, otros autores consideran una división que comprende 70 % para entrenamiento y el 30 % restante para verificación. Entonces la eficiencia de la predicción sobre el conjunto desconocido puede reflejar de forma precisa la eficacia del modelo para clasificar en conjunto de datos desconocidos [9, 10, 11, 1, 12].

Una versión desarrollada del proceso de selección es la validación cruzada donde se divide el conjunto de entrenamiento en z subconjuntos de igual tamaño. Seguidamente un subconjunto es probado usando el clasificador entrenado con los $z - 1$ subconjuntos restantes. Por lo tanto, cada instancia del conjunto de entrenamiento completo es predicha una vez, y con ello la eficacia de la validación cruzada representaría el porcentaje de data que ha sido clasificada correctamente.

Es recomendable realizar el ajuste de C y γ usando validación cruzada, donde son probados pares de valores de los parámetros y aquel par con la mayor eficiencia en validación cruzada se selecciona. En este sentido se tiene que probar con secuencias exponenciales crecientes de C y γ , es un método práctico para identificar buenos valores de estos parámetros.

5. Pruebas realizadas

En el Laboratorio de Máquinas Eléctricas de la Universidad de Carabobo se cuenta con un prototipo de máquina sincrónica para el estudio de fallas incipientes. En la Tabla 2 se muestra las características de dicha máquina, en la Figura 8 se muestra el diagrama del montaje y en la Tabla 3 se muestra las especificaciones de los equipos utilizados para las pruebas.

Adicionalmente se utilizaron tres (3) amperímetros DC, tres (3) amperímetros AC, un (1) voltímetro DC, un (1) voltímetro AC y un (1) tacómetro digital a fin de monitorear las condiciones de funcionamiento del circuito. Por otro lado, no fue necesario realizar el

Tabla 2: Características de la Máquina Sincrónica Utilizada [13]

Característica	Unidades
Ranuras	42
Número de polos	14
Devanado	Imbricado doble capa
Paso de bobina	2 ranuras
Paso polar	3 ranuras
Número de espiras	3
Número de bobinas por grupo	1
Número de bobinas por fase	14
Conductor de cobre esmaltado	N°17
Ángulos de ranuras	8.57 °mec, 60 °EE

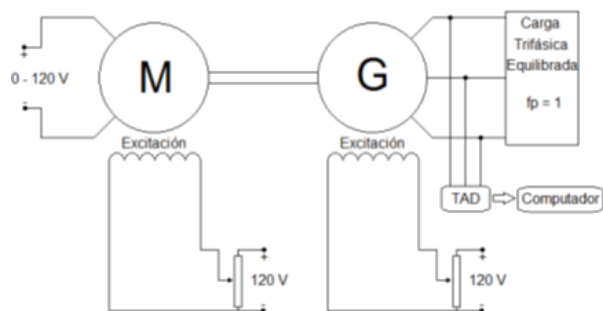


Figura 8: Diagrama del Montaje

condicionamiento de las señales debido a que se obtienen niveles de tensión que se pueden manejar directamente con la Tarjeta de adquisición de Datos (TAD).

Asimismo, para simular las fallas en rodamientos se emplearon 3 cojinetes, que inicialmente se encontraban en perfecto estado, con el fin de simular las fallas en Pista Interna, Pista Externa y Elemento Rodante. Para lograrlo, al primer cojinete se le realizó un agujero en la pista interna, al segundo se le hizo un agujero en la pista externa y para el tercero se realizó la extracción de una de las bolas internas del cojinete [13]. En la Figura 9 se pueden observar las fallas antes indicadas.



Figura 9: Fallas en los cojinetes [13]

Por otro lado, la máquina objeto de estudio se trabajó en dos tipos de conexión (Y y YY) con tres niveles de carga de tipo resistiva (Vacío, 50 %, 75 % y 100 %) y en cada condición de operación se adquirió las tres corrientes de línea [13]. Seguidamente los datos se organizaron como indica la Figura 10.




Figura 10: Organización de los datos

Seguidamente se realizó un estudio de los datos para establecer los parámetros característicos a utilizar en el entrenamiento de las SVM prevaleciendo cuatro (04) características a saber: media aritmética, desviación estándar, curtosis y asimetría.

En el entrenamiento de la SVM se proponen dos modelos de clasificación: el primero corresponde a una clasificación binaria (SVM binaria), la cual, al comparar la máquina en condición “sin falla” contra condiciones de falla, haga posible la detección de fallas en rodamientos. El segundo modelo corresponde a una clasificación multiclase (SVM multiclase), la cual apunta a descubrir una falla incipiente, así como identificar la naturaleza de la misma, es decir, detectar y clasificar fallas en los rodamientos del generador. Adicionalmente, para los dos modelos propuestos se utilizó el 70 % de los datos totales para el entrenamiento y el 30 % restante para validación y prueba. Por otro lado para la clasificación multiclase se utilizaron los siguientes algoritmos:

- 1 VS Resto: para este modelo se generan varias SVM binarias, donde para una de ellas, una de las clases es asignada como positiva y el resto son negativas. El algoritmo consiste en realizar todas las combinaciones posibles y aquella con la función de salida más alta asigna la clase. Aquí, el número de clasificadores es N, siendo N igual al número de clases.

Tabla 3: Especificaciones de los equipos [13]

Motor DC			
Fabricante	Electrónica Veneta	Modelo	M-12/EV
Tipo	EXC. SEP.	Potencia (W)	450
Voltaje (V)	220	Corriente (A)	2,1
Voltaje de excitación (V)	220	Corriente de excitación (A)	0,33
Velocidad (RPM)	3600	Torque (Nm)	1,5

Fuente de Alimentación Marca Terco		
Selector	Tensión (V)	Corriente (A)
DC fijo	220	3,5
DC variable	0 – 220	16
AC fijo	220	10
AC variable	0 – 220	10

Reóstatos para la Carga Trifásica	
Voltaje (V)	220
Corriente máxima (A)	16
Resistencia (Ω)	1,2

Reóstatos Shunt	
Marca	Terco
Voltaje (V)	220
Corriente Máxima (A)	2
Resistencia (Ω)	440

Tarjeta de Adquisición de Datos (TAD)	
Modelo	USB - 1208FS
Voltaje de alimentación (V)	120
Frecuencia de alimentación (Hz)	60
Nº de canales externos	8

- 1 VS 1: en este caso, se generan múltiples SVM donde, para cada una de ellas, una clase es positiva, otra negativa y el resto de las clases son ignoradas. La estrategia aquí consiste en acumular puntos de aciertos. Al introducir un nuevo ejemplo, cuya clase es desconocida, en cada combinación la SVM predice la clase del ejemplo, y cada vez que una clase es seleccionada, se le suma un punto. Al final, aquella con mayor cantidad de puntos se escoge como la clase ganadora. El número de clasificadores requeridos viene dado por la ecuación (33).

$$\text{Número de SVM} = \frac{N(N - 1)}{2} \quad (33)$$

Siendo N el número de clases. Para el diseño del programa de entrenamiento multiclase, se tiene que el número de clases es igual a 4 y haciendo uso de

Tabla 4: Matriz de decisión para el entrenamiento Multiclase

Clase	SVM					
	SVM 1	SVM 2	SVM 3	SVM 4	SVM 5	SVM 6
Sin falla	1	1	1	0	0	0
Falla Pista Interna	-1	0	0	1	1	0
Falla Pista Externa	0	-1	0	-1	0	1
Falla en Bola	0	0	-1	0	-1	-1

Tabla 5: Resultados del entrenamiento en conexión Y

SVM KERNEL	Precisión de la SVM (%)			Precisión SVM Multiclase (%)	
	Clasificación máquina sin falla VS:			Algoritmo de clasificación	
	Falla Pista Interna	Falla Pista Externa	Falla en Bola	1 Vs 1	1 Vs Resto
Linear	57,1	57,1	54,6	30,3	32,1
Quadratic	81	80	67,6	45,8	40,7
Cubic	86,7	87,3	81,3	63,4	60,9
Fine RBF	95,2	93,7	96,2	83,1	81,4
Medium RBF	85,1	89,2	80,5	62,7	61
Coarse RBF	65,1	67,3	57,6	34	41

Tabla 6: Resultados del entrenamiento en conexión YY

SVM KERNEL	Precisión de la SVM (%)			Precisión SVM Multiclase (%)	
	Clasificación máquina sin falla VS:			Algoritmo de clasificación	
	Falla Pista Interna	Falla Pista Externa	Falla en Bola	1 Vs 1	1 Vs Resto
Linear	67,9	68,8	63,2	45,1	34,4
Quadratic	73	87,9	77,8	59	49,7
Cubic	83,2	90,8	80	70,6	61,5
Fine RBF	95,2	96,2	94	89	89,7
Medium RBF	81,1	90,2	82,2	72	70,3
Coarse RBF	63,2	75,6	74,6	48,5	47,4

la ecuación (31), se obtuvo que para el algoritmo 1 VS 1 se requirieron 6 clasificadores individuales. En este sentido la matriz de decisión, en la cual las filas son las clases de estudio y las columnas los clasificadores por paso, queda como se indica en la Tabla 4.

Es posible mejorar el desempeño de clasificación de las SVM al modificar los parámetros de penalización del error (C) y la escala de la función Kernel (γ) utilizada. El parámetro C controla el equilibrio entre generar un margen amplio contra el error en la clasificación de los ejemplos cercanos al mismo, mientras que γ permite realizar ajustes sobre la curvatura de los datos. Se recomienda aplicar una secuencia exponencial geométrica de al menos 10 valores para el parámetro C , por ejemplo $C = 2^{-5}, 2^{-3}, \dots, 2^3, 2^5$. Por el contrario, para el ajuste de γ los software utilizan un procedimiento

heurístico para seleccionar el valor más apropiado para el modelo.

6. Resultados

En las Tablas 5 y 6 se muestran los resultados de precisión de la SVM, al comparar el generador sincrónico tanto para conexión en Y como para conexión YY , en condición sin falla contra las condiciones de falla en pista interna, falla en pista externa y falla en bola, tanto para clasificación simple como para clasificación multiclase, adicionalmente se refleja la variación de la función aplicada de la SVM.

Se observa indudablemente, que la función RBF es la más apta para optimizar el entrenamiento, donde para clasificación binaria se obtuvieron

Tabla 7: Clasificación Binaria para Conexión Y. Función Kernel = RBF

C	z = 5			z = 10		
	Falla Pista Interna	Falla Pista Externa	Falla Bola	Falla Pista Interna	Falla Pista Externa	Falla Bola
0,00193	57,1	57,1	57,1	57,1	57,1	57,1
0,00781	57,1	57,1	57,1	57,1	57,1	57,1
0,03125	57,1	57,3	57,1	57,2	57,3	57,2
0,125	90,7	92,4	89,4	90,6	92,2	90,7
0,5	94,8	93,8	94,4	95,9	93,6	94,4
2	96	95,9	97	96,6	95,5	96,2
8	96,5	96,4	98	97,1	96,7	96,9
32	96,2	95,9	98,2	97	97,0	96,7
128	96,5	95,3	98	96,5	96,1	96,8
512	95,9	94,7	97,9	96,1	95,8	96,6
1000	95,7	95	97,6	96,3	95,6	96,3

Tabla 8: Clasificación Multiclase para Conexión Y. Función Kernel = RBF

C	z = 5		z = 10	
	1 VS 1	1 VS RESTO	1 VS 1	1 VS RESTO
0,00193	30,8	78,3	30,8	79,8
0,00781	30,8	78,8	30,8	80
0,03125	30,8	79,8	30,8	79,7
0,125	73,6	78,9	75,4	80,3
0,5	83	82,8	83,2	82,9
2	86,4	85,6	85,9	85,8
8	87,4	85,3	87	85,8
32	87,2	85,1	87,3	85,7
128	86,5	84,9	86,4	85,1
512	85,5	84,8	86,3	84,9
1000	85,6	84,5	86,1	85

Tabla 9: Clasificación Binaria para Conexión YY. Función Kernel = RBF

C	z = 5			z = 10		
	Falla Pista Interna	Falla Pista Externa	Falla Bola	Falla Pista Interna	Falla Pista Externa	Falla Bola
0,00193	57,1	57,1	57,1	57,1	57,1	57,1
0,00781	57,1	57,1	57,1	57,1	57,1	57,1
0,03125	60,9	79,4	58,7	64,6	75,4	57,3
0,125	81,8	87,8	90,6	86,7	87,7	88,7
0,5	94,2	94,3	92,9	94,6	94,9	94,1
2	96,1	95,9	94,1	95,2	96,7	96,7
8	96	96,5	94,4	96,5	96,5	96,8
32	96	97	95,7	96,1	96,5	96,1
128	95,8	97	95	95,7	95,5	95,3
512	95,5	96,8	94,1	95,6	96,5	95,3
1000	95,5	97	93,1	95,6	96,2	95,3

porcentajes de acierto superiores a 93 % y para clasificación multiclase superior a 83 %.

Adicionalmente, para fijar los parámetros que optimicen el proceso de clasificación, se evalúan los parámetros que controlan la validación cruzada (z) y la minimización del error (C). Este

procedimiento se aplicó para la clasificación binaria y multiclase tanto en conexión Y como en YY, lo que se muestra en las Tablas 7, 8, 9 y 10.

En las Tablas 7 y 8 se observa que para valores de C muy bajos, la clasificación es baja, del orden del 57 % de aciertos para clasificación binaria y en

Tabla 10: Clasificación Multiclase para Conexión YY. Función Kernel = RBF

C	z = 5		z = 10	
	1 VS 1	1 VS RESTO	1 VS 1	1 VS RESTO
0,00193	30,8	83,6	30,8	84,3
0,00781	30,8	83,9	30,8	84,5
0,03125	41,1	83,9	43,6	84,4
0,125	78,3	85,1	80,7	85,9
0,5	89,5	88,8	90,3	89,8
2	91,8	91,8	92,8	92,4
8	92,7	92	93,2	93,1
32	92,5	91,3	92,7	92,6
128	91,8	90,6	92,5	91,5
512	91,5	90,3	92,3	91,6
1000	91,5	90,3	92,3	91,5

Tabla 11: Clasificación de fallas en función del nivel de carga. Función Kernel = RBF; C = 8; z = 10

Conexión	% Carga	% Precisión SVM al comparar máquina “sin Falla” vs:			% Precisión SVM Multiclase	
		Falla Pista Interna	Falla Pista Externa	Falla en Bola	1 vs 1	1 vs Resto
Y	50	99,7	100	100	96,3	96,2
	75	99,7	96	97,7	91	91,7
	100	100	100	97,3	91,5	88,8
YY	50	94,7	99	99	95,2	96,7
	75	99,3	97,7	99,7	97,8	96,8
	100	98,7	99,7	98,7	98,7	98,5

el orden de 31 % para 1 vs 1. Para valores mayores de C, el porcentaje de aciertos se incrementó notoriamente, siendo la media del 96,4 % para clasificación binaria y de 85,8 % para clasificación multiclase. La precisión fue aproximadamente igual para todas las fallas individuales, al igual que para todos los valores de z probados. Los mejores resultados se obtuvieron para valores de C en el rango $2 \leq C \leq 32$, sin embargo, para valores de $C > 1$, la variación no es significativa.

Al igual que para conexión Y, en conexión YY cuyos resultados se muestran en las Tablas 9 y 10, se observa que para valores de C muy bajos, la clasificación es baja, del orden del 57 % de aciertos para clasificación binaria y en el orden de 31 % para 1 vs 1. Para valores mayores de C, el porcentaje de aciertos se incrementó notoriamente, siendo la media del 95,8 % para clasificación binaria y de 91,9 % para clasificación multiclase.

La precisión fue aproximadamente igual para todas las fallas individuales, al igual que para todos los valores de z probados. Los mejores resultados se obtuvieron para valores de C en el rango $2 \leq C \leq 1000$ para clasificación binaria y $C = 8$ para

clasificación multiclase; sin embargo, para valores de $C > 1$, la variación no es significativa.

Por otro lado, se consideraron datos de entrenamiento para los niveles específicos de carga de 50 %, 75 % y 100 % obteniéndose los porcentajes de acierto que se muestran en la Tabla 11 observándose que, al entrenar las máquinas de vectores de soporte para un nivel de carga específico, los niveles de acierto se encuentran en el orden del 98 %. Adicionalmente, se observó que al ser comparados contra el entrenamiento sin atender al nivel de carga, los resultados de precisión se encuentran en el mismo rango de valores, lo que significa que la SVM es capaz de discriminar fallas de manera apropiada independientemente del nivel de carga.

7. Conclusiones

Los estudios asociados a fallas representan uno de los aspectos fundamentales a considerar actualmente para la adecuada operación en máquinas sincrónicas, así como para el desarrollo de nuevas tecnologías que permitan perfeccionar

su funcionamiento. Debido a la importancia que adquieren estas máquinas dentro de los sistemas eléctricos, el desarrollo de nuevas técnicas y modelos de mantenimiento predictivo, basadas en métodos de aprendizaje supervisado, tal como la clasificación con SVM, permite establecer mejoras en el proceso de operación y mantenimiento de la máquina, así como la calidad del servicio que con ellas se suministra. En relación a lo anterior, para el entrenamiento de la SVM, se comprobó que organizar adecuadamente la data permite establecer con mayor claridad el problema de clasificación principal y cómo abordarlo, a su vez que permite aprovechar una de las principales ventajas de las SVM, la cual radica en la facilidad para el entrenamiento.

Asimismo, se demostró que, una vez definido el problema de clasificación, así como estructurados apropiadamente los casos de estudio, es posible diseñar y realizar el entrenamiento de una máquina de vectores de soporte para la detección y clasificación de fallas en rodamientos en el generador sincrónico, a partir del análisis de la corriente de armadura como variable de estudio. Debido a las propiedades de este clasificador, se comprobó que es posible su aplicación para el estudio del comportamiento en cuanto condiciones de fallas mecánicas, en lo que a máquinas eléctricas rotativas se refiere, en este caso específicamente en la máquina sincrónica operando como generador.

Finalmente, basado en el análisis de los resultados de los entrenamientos realizados, se concluye que la máquina de vectores de soporte es capaz de reconocer efectivamente la presencia de una falla en los rodamientos de la máquina sincrónica, a través de la observación de la corriente estática, independientemente del nivel de carga y de la conexión del devanado de armadura que se utilice. Adicionalmente es capaz de discriminar si la falla del cojinete se encuentra en la pista interna, pista externa o en bola.

Asimismo, los tres tipos de fallas de cojinete estudiados se discriminan en igual proporción debido a que para los tres tipos de fallas (en la pista interna, en la pista externa y en bola) los porcentajes de acierto se mantuvieron, a lo largo del análisis, en el mismo rango de valores, esto

permite concluir que la SVM discrimina todas las fallas en cojinetes por igual. En líneas generales, los resultados obtenidos son superiores a 85 % para clasificación multiclase y superiores a 96 % para clasificación binaria, por lo que el modelo aplicado y el desempeño demostrado por el clasificador son ciertamente satisfactorios.

8. Referencias

- [1] M. Fernández-Cabamas, M. García-Melero, G. Alfonso-Orcajo, J. Cano-Rodríguez, and J. Solares-Sariego, *Técnicas para el mantenimiento y diagnóstico de máquinas eléctricas rotativas*. ABB Service S.A.-Marcombo Boixareu Editores, 2000.
- [2] I. Tabatabaei, J. Faiz, H. Lesani, and M. Nabavi-Razavi, "Modeling and Simulation of a salient-pole synchronous Generator with dynamic eccentricity using modified winding function theory," *IEEE Transactions on Magnetics*, vol. 40, no. 3, pp. 1550–1555, 2004.
- [3] N. Prabhakar, "Stator fault analysis of Synchronous Machines," Phd. Thesis, Victoria University, 2007.
- [4] P. Tavner, "Review of condition monitoring of rotating electrical machines," *IET Electric Power Applications*, vol. 2, no. 4, pp. 215–247, 2008.
- [5] H. Toliyat, S. Nandi, S. Choi, and H. Meshgim-Kelk, *ELECTRIC MACHINES. Modeling, Condition Monitoring, and Fault Diagnosis*. Taylor & Francis Group, LLC, 2013.
- [6] P. Delgado-Arredondo, D. Morínigo-Sotelo, R. Osornio-Rios, J. Avina-Cervantes, H. Rostro-Gonzalez, and R. Romero-Troncoso, "Methodology for fault detection in induction motors via sound and vibration signals," *Mechanical Systems and Signal Processing*, vol. 83, no. 15, pp. 568–589, 2017.
- [7] Z. Medrano, C. Perez, J. Gomez, and M. Vera, "Nueva metodología de diagnóstico de fallas en rodamientos en una máquina síncrona mediante el procesamiento de señales vibro-acústicas empleando análisis de densidad de potencia," *Ingeniería Investigación y Tecnología*, vol. 17, no. 1, pp. 73–85, 2016.
- [8] M. Castillo and F. Garzón, "Tipología de Fallas en Generadores Síncronos Hidráulicos de la Empresa de Energía del Pacífico," Tesis para optar al título de Ingeniero Electricista, Universidad del Valle, 2016.
- [9] G. Betancourt, "Las Máquinas de Soporte Vectorial (SVMs)," *Scientia Et Technica*, vol. 1, no. 27, pp. 67–72, 2005.
- [10] E. Carmona, *Tutorial sobre Máquinas de Vectores de Soporte (SVM)*. Universidad Nacional de Educación a Distancia (UNED), 2014.
- [11] N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press, 2000.

- [12] L. Cao and W. Chong, “Feature extraction in support vector machine: a comparison of PCA, XPCA and ICA,” in *Proceedings of the 9th International Conference on Neural Information Processing, 2002. ICONIP '02*, vol. 2, 2002, pp. 1001–1005.
- [13] J. Amaya and M. Rangel, “Estudio Preliminar de Fallas en Máquinas Síncronas para la Aplicación de Mantenimiento Predictivo a partir del Análisis del Espectro de Señales Eléctricas.” Trabajo Especial de Grado para optar al título de Ingeiero Electricista, Universidad de Carabobo, 2012.