

**DETECCIÓN DE FALLAS EN MOTORES DE INDUCCIÓN USANDO MCSA
(MOTOR CURRENT SIGNATURE ANALYSIS) Y
MÁQUINAS DE SOPORTE VECTORIAL**

Ing. SILVIA JULIANA OVIEDO CASTILLO



**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
GRUPO DE INVESTIGACIÓN DICBOT
BUCARAMANGA
2011**

**DETECCIÓN DE FALLAS EN MOTORES DE INDUCCIÓN USANDO MCSA
(MOTOR CURRENT SIGNATURE ANALYSIS) Y
MÁQUINAS DE SOPORTE VECTORIAL**

Ing. SILVIA JULIANA OVIEDO CASTILLO

**Trabajo de Investigación presentado como requisito parcial para optar al
título de Magister en Ingeniería Mecánica**

**DIRECTOR:
JABID EDUARDO QUIROGA MÉNDEZ
MSc. INGENIERÍA MECÁNICA**

**CODIRECTOR:
CARLOS BORRÁS PINILLA
PhD. INGENIERÍA MECÁNICA**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
GRUPO DE INVESTIGACIÓN DICBOT
BUCARAMANGA
2011**

AGRADECIMIENTOS

La autora expresa sus agradecimientos a:

El profesor Jabid Quiroga M, por su dirección, sugerencias y aportes, que fueron muy útiles para resolver las dificultades de este proyecto.

El profesor Carlos Borrás P, codirector de este proyecto, por su respaldo y colaboración desde el comienzo del proyecto e hicieron posible la culminación del mismo.

El profesor Gabriel Ordóñez P, por la orientación acerca de diferentes aspectos de la técnica MCSA, que permitió hacer correcciones relevantes para el resultado final.

Tabla de Contenido

INTRODUCCIÓN	13
1. DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN.....	14
2. PLANTEAMIENTO DEL PROBLEMA	15
3. JUSTIFICACIÓN	16
4. OBJETIVOS DEL TRABAJO DE INVESTIGACIÓN	18
4.1. OBJETIVO GENERAL	18
4.2. OBJETIVOS ESPECÍFICOS.....	18
5. MARCO TEÓRICO	19
5.1. ¿POR QUÉ EMPLEAR LA SEÑAL DE CORRIENTE DEL ESTATOR?.....	19
5.2. ANÁLISIS DE LA CORRIENTE.....	20
5.2.1. Barras Rotas	21
5.2.2. Corto Circuito en el estator	21
5.2.2.1. Componente Secuencial Negativo	22
5.3. MÁQUINAS DE SOPORTE VECTORIAL.....	23
5.4. SELECCIÓN DE PARÁMETROS EN PROBLEMAS DE CLASIFICACIÓN.....	30
5.5. GENERACIÓN DE PARÁMETROS	34
5.6. PARÁMETROS USADOS PARA LA DETECCIÓN DE FALLAS EN MOTORES DE INDUCCIÓN.....	34
6. METODOLOGÍA.....	38
6.1. REVISIÓN BIBLIOGRÁFICA E IDENTIFICACIÓN DE REQUERIMIENTOS	39
6.2. ADQUISICIÓN Y ALMACENAMIENTO DE DATOS EN DIFERENTES CONDICIONES DE FALLA Y CARGA. 39	
6.3. ADAPTACIÓN DEL ALGORITMO DE DETECCIÓN USANDO MÁQUINAS DE SOPORTE VECTORIAL.	42
6.4. INFORME FINAL Y DIVULGACIÓN DE RESULTADOS.....	42
7. RESULTADOS Y ANÁLISIS	44
7.1. RESULTADOS OBTENIDOS CUANDO SE PRESENTA UN CORTO CIRCUITO EN EL ESTATOR	45
7.1.1. Análisis del espectro de corriente	45
7.1.2. Componente Secuencial Negativa I_{a2}	47
7.2. RESULTADOS OBTENIDOS CUANDO SE PRESENTAN BARRAS ROTAS	49
7.3. PARÁMETROS DE CLASIFICACIÓN DE FALLAS EN UN MOTOR DE INDUCCIÓN.	53
7.4. SELECCIÓN DE PARÁMETROS DE CLASIFICACIÓN.....	60
7.4.1. Prueba de separabilidad entre clases.....	61
7.4.2. Prueba de separabilidad entre severidad de falla para corto circuito	63
7.4.3. Prueba de separabilidad entre severidad de falla para barras rotas	65
7.5. CLASIFICADOR DE FALLAS EN UN MOTOR DE INDUCCIÓN BASADO EN SVM.	68

8.	ADAPTACIÓN DE UN ALGORITMO DE CLASIFICACIÓN DE FALLAS.	69
8.1.	ARQUITECTURA DE DIAGNÓSTICO Y CUANTIFICACIÓN DE LA SEVERIDAD.	73
8.1.1.	CLASIFICADOR DEL TIPO DE FALLA	73
8.1.2.	CLASIFICADOR DE SEVERIDAD PARA FALLAS DE CORTO CIRCUITO.....	79
8.1.2.1.	Clasificador Motor con falla de corto de 2%- Motor con falla de corto de 5%	79
8.1.3.	Clasificador de severidad para fallas de barras rotas.....	83
9.	CONCLUSIONES	89
10.	APORTES	90
11.	RECOMENDACIONES Y TRABAJOS FUTUROS.....	92
12.	BIBLIOGRAFÍA.....	93
	ANEXO A. CÓDIGO DE ENTRENAMIENTO Y VALIDACIÓN DE MÁQUINAS BICLASE.....	97

LISTA DE FIGURAS

Figura 1. Margen geométrico para un problema de clasificación binario y lineal.....	25
Figura 2. Parámetros del histograma a) Histograma original b) histograma con distribución normal c) histograma con skewness negativo d) histograma con skewness positivo e) histograma con kurtosis alta f) histograma con kurtosis baja.....	35
Figura 3. a) Banco de pruebas implementado b) Esquema de las componentes del banco de pruebas	40
Figura 4. Terminales de los devanados de una fase para la variación de severidad del corto.....	41
Figura 5. Rotor usado en la experimentación con tres barras rotas.....	42
Figura 6. Densidad espectral de potencia alrededor de 540 Hz para detección de corto..	45
Figura 7. Componente secuencial negativa para el motor sin carga acoplada.	47
Figura 8. Rotor usado en la experimentación con tres barras rotas.....	49
Figura 9. Densidad espectral de potencia del caso 1	50
Figura 10. Bandas laterales asociadas a barras rotas con 75% de carga acoplada. a) Banda lateral izquierda b) banda lateral derecha.....	51
Figura 11. Bandas laterales asociadas con barras rotas con 85% de carga acoplada. A) Banda lateral izquierda. B) Banda lateral derecha.....	52
Figura 12. Histograma de 1 segundo de la señal de corriente del motor sin falla y con tres barras rotas.....	54
Figura 13. Gráfica del set de valores para el parámetro PSC/NSC para tres clases	56
Figura 14. Gráfica del set de valores para el parámetro media para tres clases	57
Figura 15. Gráfica del set de valores para el parámetro media para tres clases	57
Figura 16. Gráfica del set de valores para el parámetro Entropía para tres clases	58
Figura 17. Gráfica del set de valores para el parámetro Factor de Cresta para tres clases	59
Figura 18. Gráfica de la probabilidad normal para el parámetro “Relación PSC/NSC”	60
Figura 19. Relación entre los parámetros seleccionados para un clasificador de severidad de falla de corto circuito	65
Figura 20. Relación entre los parámetros seleccionados para un clasificador de severidad de falla de corto circuito	66
Figura 21. Diagrama de flujo general para el entrenamiento y validación de las máquinas asociadas a un clasificador de fallas en motores.....	72
Figura 22. Esquema de la arquitectura de diagnóstico dimensionado para la aplicación de detección de las fallas.....	74
Figura 23. Respuesta de entrenamiento para Clasificador Motor sin falla – Motor con barras rotas.....	76
Figura 24. Respuesta de entrenamiento de Clasificador Motor sin falla – Motor con corto circuito	77
Figura 25. Respuesta Clasificador Motor con corto circuito – Motor con barras rotas	78

Figura 26. Respuesta de entrenamiento Clasificador Motor con falla de corto de 2%- Motor con falla de corto de 5%	80
Figura 27. Respuesta de entrenamiento clasificador Motor con falla de corto de 5%- Motor con falla de corto de 10%	81
Figura 28. Respuesta clasificador Motor con falla de corto de 2%- Motor con falla de corto de 10%	82
Figura 29. Respuesta de entrenamiento clasificador Motor con una barra rota- Motor con dos barras rotas.....	84
Figura 30. Respuesta de entrenamiento de clasificador Motor con dos barras rotas- Motor con tres barras rotas	85
Figura 31. Respuesta de entrenamiento de Motor con una barra rota- Motor con tres barras rotas.....	86

LISTA DE TABLAS

Tabla 1. Posibles escenarios de toma de datos de corriente del estator.....	39
Tabla 2. Valor medio de I_{a2} para los casos del experimento.	48
Tabla 3. Resultados de t-test para clases de tipo de falla.....	62
Tabla 4. Parámetros para los clasificadores biclase planteados.	63
Tabla 5. Resultados de t-test para clases de severidad de falla para corto circuito	64
Tabla 6. Resultados de t-test para clases de severidad de falla para barras rotas	65
Tabla 7. Parámetros para los clasificadores biclase planteados.	67
Tabla 8. Resumen de parámetros preseleccionados para clasificadores.....	67
Tabla 9. Respuesta Clasificador Motor sin falla – Motor con barras rotas.....	75
Tabla 10. Respuesta Clasificador Motor sin falla – Motor con corto circuito	77
Tabla 11. Respuesta Clasificador Motor con corto circuito – Motor con barras rotas.....	78
Tabla 12. Respuesta Clasificador Motor con falla de corto de 2%- Motor con falla de corto de 5%	80
Tabla 13. Respuesta clasificador Motor con falla de corto de 2%- Motor con falla de corto de 10%	81
Tabla 14. Respuesta clasificador Motor con falla de corto de 2%- Motor con falla de corto de 10%	82
Tabla 15. Respuesta clasificador Motor con una barra rota- Motor con dos barras rotas...	83
Tabla 16. Respuesta clasificador Motor con dos barras rotas- Motor con tres barras rotas	85
Tabla 17. Respuesta Motor con una barra rota- Motor con tres barras rotas.....	86

TITULO: DETECCIÓN DE FALLAS EN MOTORES DE INDUCCIÓN USANDO MCSA (MOTOR CURRENT SIGNATURE ANALYSIS) Y MÁQUINAS DE SOPORTE VECTORIAL*

Autora: Silvia Juliana Oviedo Castillo **

Palabras Claves: Motor de inducción, Máquinas de Soporte Vectorial, clasificador, detección de fallas, MCSA.

RESUMEN

El trabajo descrito en este documento consistió en la validación experimental de la técnica MCSA (Motor Current Signature Analysis) usando como banco de pruebas motores de inducción de 2 HP, 4 polos en los cuales se indujeron las fallas correspondientes a corto circuito en el devanado del estator y barras rotas. La experimentación arrojó resultados favorables en condiciones de carga específicas, para cada tipo de falla, así, para la falla de corto circuito, la adición de carga desfavorece notoriamente la capacidad de detección de los indicadores de falla señalados en la literatura. Por su parte, el indicador de la falla de barras rotas mostró mejoría en la detección con niveles de carga elevados. Adicionalmente, se empleó máquinas de soporte vectorial para realizar una arquitectura de detección y diagnóstico de fallas en motores. Los parámetros usados para la clasificación fueron seleccionados empleando pruebas con los diferentes clasificadores biclase y métodos estadísticos. Estos parámetros fueron los parámetros usuales, propuestos por la técnica MCSA, que tuvieron poca efectividad y algunos parámetros estadísticos del dominio del tiempo, que mostraron una efectividad satisfactoria en la clasificación. Dicha efectividad fue medida en términos del error de entrenamiento y validación, así como el número de vectores de soporte. La validación de la arquitectura de detección y diagnóstico de fallas fue propuesta usando validación cruzada con el 50% de los datos por ensayo.

* Proyecto de Grado

** Facultad de Ingenierías Físico-mecánicas. Escuela de Ingeniería Mecánica. Director: Jaid Quiroga Méndez. Codirector: Carlos Borrás Pinilla.

TITLE: FAULT DETECTION IN AN INDUCTION MOTOR USING MCSA (MOTOR CURRENT SIGNATURE ANALYSIS) AND SUPPORT VECTOR MACHINES.*

Author: Silvia Juliana Oviedo Castillo **

Keywords: Induction Motor, Support Vector Machines, classifier, Fault detection, MCSA.

ABSTRACT

The work described in this paper is the experimental validation of the MCSA technique (Motor Current Signature Analysis) using as a test rig 2HP, 4 poles induction motors, in which faults corresponding to stator winding short and broken bars were induced. The experiment yielded positive results under specific load conditions for each type of failure. In this manner, for the short circuit fault, the addition of load noticeably disfavors the detection capability of fault indicators identified in the literature, unlike the indicator of the broken bar fault detection, which showed improved detection capability under higher load levels. Additionally, support vector machines were used for the proposal of a fault detection and diagnosis architecture in motors. The parameters used for classification were selected using tests on different bi-class classifiers and statistical methods. These parameters were the usual parameters proposed by MCSA, which showed poor performance and some statistical parameters in time domain, which showed a satisfactory performance in the classifying task. The mentioned performance was measured in terms of training error and validation error, as well as the number of support vectors. The validation of the architecture of fault detection and diagnosis was proposed using cross validation with 50% of test data.

* Work degree

** Faculty of Physical-mechanical Engineering. School of Mechanical Engineering. Advisor: Jaid Quiroga Méndez. Co advisor: Carlos Borrás Pinilla

INTRODUCCIÓN

Los motores de inducción son las máquinas eléctricas más populares en la industria, por lo que del buen desempeño de los mismos depende el éxito de las operaciones dentro de un proceso industrial. Es por ello que es importante implementar un sistema de monitoreo que permita identificar condiciones anormales de manera prematura, para prevenir daños mayores en el sistema o proceso y riesgos a los operarios involucrados.

El análisis de las características de la corriente de un motor de inducción o MCSA, por sus siglas en inglés (Motor Current Signature Analysis) es una técnica de monitoreo de máquinas eléctricas. Dicha técnica forma parte de las prácticas del mantenimiento basado en la condición, en el cual no se requiere la detención de las máquinas eléctricas de una planta para su posterior evaluación de condición, sino que por el contrario, se aprovechan las características de las señales (ya sea en estado transitorio o estacionario) propias de la operación del equipo, como la corriente (en el caso de MCSA) o las vibraciones para la detección de fallas en los diferentes elementos del mismo.

El creciente interés de la comunidad científica internacional alrededor de la técnica MCSA es la motivación principal del grupo de investigación DICBOT para explorar dicha técnica bajo diferentes condiciones de experimentación y así, poder acercarla a los posibles interesados de la industria regional. Asimismo, se pretende el fortalecimiento de la técnica a través del uso de la inteligencia artificial, particularmente la técnica de Máquinas de Soporte Vectorial (SVM), por sus siglas en inglés, de manera que se pueda obtener un diagnóstico muy confiable a través de un algoritmo robusto que tenga la capacidad de distinguir entre diferentes fallas, bajo diferentes condiciones de carga del motor. Cabe resaltar que la investigación que se va a realizar tiene como meta poder contribuir no solo al mantenimiento a nivel regional, sino contribuir a la discusión acerca de MCSA que las investigaciones alrededor del mundo suscitan.

1. DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN

1.1. TÍTULO

“DETECCIÓN DE FALLAS EN MOTORES DE INDUCCIÓN USANDO MCSA (MOTOR CURRENT SIGNATURE ANALYSIS) Y MÁQUINAS DE SOPORTE VECTORIAL “

1.2. DIRECTOR DEL PROYECTO

JABID EDUARDO QUIROGA MÉNDEZ

Ingeniero Mecánico, MSc. Ingeniería Mecánica

Universidad Industrial de Santander (Colombia)

Escuela de Ingeniería Mecánica.

1.3. CODIRECTOR DEL PROYECTO

CARLOS BORRÁS PINILLA

Ingeniero Mecánico, PhD. Ingeniería Mecánica

Universidad Industrial de Santander (Colombia)

Escuela de Ingeniería Mecánica.

1.4. AUTOR DEL PROYECTO

SILVIA JULIANA OVIEDO CASTILLO

Ingeniera Electrónica, Candidata a Magíster en ingeniería Mecánica

Universidad Industrial de Santander (Colombia)

1.5. ENTIDADES INTERESADAS EN EL PROYECTO

- UNIVERSIDAD INDUSTRIAL DE SANTANDER – UIS (Colombia)
- Grupo de Investigación en Dinámica, Control y Robótica DICBOT
- Empresas locales con cantidades importantes de motores eléctricos de inducción.

2. PLANTEAMIENTO DEL PROBLEMA

La mayoría de los esquemas de mantenimiento usados en la región consisten en la detención periódica de las plantas de producción por secciones y el reemplazo de los componentes que, cumplido cierto tiempo de operación, se asumen defectuosos, como rodamientos y el reemplazo de los motores, cuando la inspección (generalmente visual) así lo sugiere. La detención de las plantas (muchas veces injustificada) genera pérdidas de dinero importantes e inconvenientes para las empresas.

Cabe señalar que la detención periódica no es el único problema que afronta el mantenimiento en la actualidad. Si bien existen técnicas no intrusivas que permiten la detección de diferentes tipos de fallas, como el análisis de vibraciones y el análisis de la corriente del estator, la decisión acerca de la presencia de la falla, a partir de la evaluación de indicadores de falla está en manos del encargado del mantenimiento, lo cual hace subjetiva la detección y probablemente errónea, si el individuo no tiene el conocimiento suficiente acerca de las técnicas mencionadas.

El desarrollo de este proyecto pretende dar solución a los inconvenientes anteriores por medio del desarrollo de un algoritmo inteligente que realice la detección de fallas en motores de inducción de forma autónoma y empleando la señal de corriente del estator (MCSA), de manera tal que se pueda proponer un esquema de detección de fallas no intrusivo, confiable y objetivo de fácil implementación en las industrias interesadas.

El uso de MCSA se sustenta en el creciente interés mundial en la detección de fallas con el análisis de información presente en la señal de corriente del estator, que hacen que MCSA constituya uno de los métodos más poderosos para la detección de fallas en tiempo real en motores (1). Estudios revelan que las fallas detectables a través de MCSA son: fallas en rodamientos (2), cortos circuitos en el

estator (3), barras rotas (4) (5) y excentricidad del entrehierro (1). Casos de estudio en ambientes industriales (6), (7), (8) revelan la efectividad de la técnica en la práctica.

3. JUSTIFICACIÓN

La detección de fallas en motores de inducción es un problema que se ha abordado de diversas formas en la investigación en el campo de mantenimiento basado en la condición, por cuanto la justificación de la solución que se plantea al problema de la detección de fallas debe responder a las siguientes preguntas:

- ¿Por qué emplear la técnica de análisis de la corriente para el monitoreo de los motores de inducción?
- Si se conoce acerca de la efectividad de varias técnicas de inteligencia artificial en la detección de fallas en máquinas eléctricas (9), (10) ¿Qué hace que máquinas de soporte vectorial sea la técnica de inteligencia artificial escogida en esta investigación?

Para la mayoría de las investigaciones que han sido registradas en la literatura acerca de MCSA, el análisis de la señal por medio de la observación de sus componentes en frecuencia a través de la FFT ha arrojado resultados satisfactorios porque se conocen de antemano las frecuencias estimadas de aparición de las fallas, en caso de presentarse, y , a través de un análisis comparativo de las magnitudes de las componentes espectrales, tomando como referencia el espectro de la condición normal, se determina la presencia o ausencia de fallas de diversos tipos. Estudios realizados acerca de detección de fallas usando MCSA (11), (12) sugieren el uso de ésta técnica para la detección de fallas como corto circuito en el estator (monitoreando el valor de la componente secuencial negativa) y barras rotas en el rotor (bajo condiciones de carga). En (12) se demostró que MCSA permite la detección de barras rotas de forma más clara, con respecto al análisis de vibraciones.

Respecto al segundo interrogante, vale la pena destacar que son muchas las técnicas de inteligencia artificial que se han empleado para resolver problemas de clasificación. En este caso, se requiere separar aquellos rasgos de los cuales depende la detección a partir de un conjunto cuantioso de datos y evaluar los indicadores obtenidos, para así poder determinar la condición de la máquina.

Las técnicas de inteligencia artificial como Redes Neuronales (10), algoritmos genéticos (9), Lógica Difusa, y combinaciones de éstas (13) han sido exploradas a lo largo de los últimos años, y por la factibilidad de las combinaciones entre ellas, existen muchas posibilidades para realizar detección de fallas. No obstante, a las técnicas de inteligencia artificial se ha agregado recientemente la técnica de Máquinas de Soporte Vectorial (MSV) para lograr detección de fallas en máquinas eléctricas y, después de las redes neuronales artificiales (ANN), es la técnica que concentra los esfuerzos de investigación a nivel mundial en la actualidad. A pesar de las fortalezas que algunas técnicas de inteligencia artificial han demostrado, en este proyecto se empleará la técnica de MSV porque se desea plantear una solución al problema de detección autónoma de fallas desde una perspectiva novedosa, aprovechando el creciente interés de la comunidad científica internacional en esta técnica.

4. OBJETIVOS DEL TRABAJO DE INVESTIGACIÓN

4.1. OBJETIVO GENERAL

- Continuar con la misión de la Universidad de generar conocimiento, de atender y dar solución a diferentes problemáticas en los procesos industriales, en particular en ofrecer un clasificador basado en SVM (Support Vector Machines) para el monitoreo de motores de inducción usando MCSA (Motor Current Signature Analysis). Adicionalmente, este proyecto pretende impulsar la línea de investigación relacionada con el monitoreo de equipos e inteligencia artificial del grupo DicBot de la Escuela de Ingeniería Mecánica.

4.2. OBJETIVOS ESPECÍFICOS

- Desarrollar e implementar un algoritmo para clasificación y detección de fallas en un motor de inducción basado en máquinas de soporte vectorial usando la información transportada por la señal de corriente del estator.
- Realizar la detección y análisis de las fallas offline en un motor de inducción 3 ϕ y 2 hp correspondientes a: Corto circuito en el devanado del estator y barras rotas en el rotor usando los términos lingüísticos para caracterizar la severidad de la falla (incipiente, moderada y severa).
- Validar experimentalmente el algoritmo propuesto, usando un banco de pruebas dedicado para este tipo de ensayos en distintos escenarios de carga (sin carga, 75% y 85% de la corriente nominal) y severidad de falla (2%, 5% y 10% de espiras cortocircuitadas en una fase para la falla de cortocircuito y 1, 2 y 3 barras rotas).

5. MARCO TEÓRICO

Las actividades principales en la investigación acerca de fallas en motores eléctricos consisten en la detección de las fallas y la identificación de las fallas. El análisis de la señal de corriente, como lo sugiere la técnica de MCSA (Motor Current Signature Analysis) es un método de creciente popularidad. Dicho análisis se puede realizar mediante diversas formas, porque existen varias transformadas que permiten observar la señal en diferentes dominios, como el dominio del tiempo, el dominio de la frecuencia, o, ambos. La observación de determinadas características de la señal permite establecer indicadores de falla, cuya evaluación permite determinar si una cierta falla existe, o no. El desarrollo del marco teórico pretende dar una idea general de las bases que fundamentan la propuesta de investigación y justifican la elección de las técnicas a emplear.

5.1. ¿Por qué emplear la señal de corriente del estator?

Un buen número de señales pueden ser colectadas desde un motor de inducción con el fin de detectar fallas en el mismo, ya que los avances científicos proveen en la actualidad variedad de sensores muy precisos de tensiones y corrientes del estator, densidades de flujo magnético, posición y velocidad del rotor, torque de salida, temperaturas interna y externa y vibraciones, entre otras. Sin embargo, hay una creciente tendencia a nivel mundial en cuanto a la detección de fallas mediante el uso de la corriente del estator, a pesar de que por décadas se viene empleando el análisis de vibraciones y temperaturas para la detección de las fallas. En búsqueda de una solución novedosa para los esquemas de mantenimiento regionales, algunos de los cuales incluyen el análisis de vibraciones, se sabe que la técnica de MCSA puede detectar de forma exitosa y menos dispendiosa las fallas. Lo anterior porque en muchas ocasiones, la señal de vibración obtenida de un motor contiene armónicos adicionales a los de interés, producidos por la construcción misma de la máquina, variaciones del torque de la

misma y perturbaciones inducidas por el individuo que realiza la toma de datos. Dichos armónicos son información redundante, que probablemente dificulta la detección. Por otra parte, la recolección de muestras de corriente emplea sensores de variada conformación (14), precisión y precio, lo cual, añadido al hecho de que con estas muestras se puede detectar fallas en forma más confiable, hace que MCSA sea una técnica atractiva para hacer parte de un sistema de detección de fallas en máquinas eléctricas.

5.2. Análisis de la Corriente

El porcentaje de fallas de los motores de inducción, de acuerdo al tipo de falla es, según estudios (15):

- Fallas relacionadas con el estator: 38%
- Fallas relacionadas con el rotor: 10%
- Fallas relacionadas con rodamientos: 40%
- Otros tipos de fallas: 12%

La metodología de detección de las fallas más comunes en motores de inducción empleando MCSA consiste en que, conocidas las ecuaciones de frecuencia de fallo para cada una de dichas fallas se toman las muestras de la señal de corriente del estator y a través de la manipulación de dichas muestras con alguna transformación se indica si la frecuencia excitada por la falla en la señal de corriente existe o no.

La descripción de las fallas y las frecuencias de falla se encuentran descritas en la literatura (16), (17), (18), (19), (20) a través de las ecuaciones a continuación, en las que se debe tener en cuenta que:

$$S = \frac{n_s - n_m}{n_s} \quad (1)$$

Donde s es una cantidad llamada deslizamiento, que es una cantidad adimensional que relaciona la velocidad síncrona del motor n_s , con la velocidad mecánica del motor, n_m y f_0 es la frecuencia de alimentación del motor (60 Hz).

5.2.1. Barras Rotas

Thompson (21) describe el mecanismo de falla de barras rotas como una consecuencia de las altas corrientes de arranque de motores, produciendo elevadas fatigas mecánicas y térmicas en los mismos. Los ciclos de trabajo pesado y largos tiempos de arranque incrementan la incidencia de rupturas en la región de la unión de las barras con el anillo. Este tipo de falla crece progresivamente en severidad como consecuencia de la elevación de temperatura alrededor del rompimiento y el hecho de que las demás barras llevarán un excedente de corriente proveniente de la barra que ya no conduce, incrementando aún más la fatiga térmica durante el arranque del motor.

La expresión que indica las componentes de falla está dada por la Ecuación (2), y sugiere la aparición de componentes laterales alrededor de la frecuencia fundamental, en presencia de la falla:

$$f_b = (1 \pm 2ks)f_0 \quad (2)$$

Con $k = 1, 2, 3, \dots$

f_0 es la frecuencia de suministro de la red.

5.2.2. Corto Circuito en el estator

La falla de corto circuito en motores eléctricos comienza usualmente como una falla no detectada de aislamiento entre dos vueltas de un devanado y luego evoluciona en un corto circuito aislando un determinado número de vueltas (22). Este tipo de falla es acumulativa, y las altas corrientes, producto del arranque del motor pueden llevar a la pérdida de los devanados de fase, cortos entre fases o cortos entre una fase y tierra. Las fallas incipientes de corto circuito pueden tener un efecto

relativamente pequeño en el desempeño del motor, pero en general pueden afectar la longevidad, la disponibilidad y la confiabilidad del motor a mediano plazo.

La Ecuación (3) corresponde a las frecuencias asociadas a la falla de corto circuito entre vueltas de un devanado (14):

$$f_{st} = f_1 \left\{ \frac{n}{p} (1 - s) \pm k \right\} \quad (3)$$

Donde f_{st} es la frecuencia de las componentes de frecuencia asociadas a la falla de corto circuito, f_1 es la frecuencia de la red de suministro del sistema eléctrico, p es el número de pares de polos, $n = 1, 2, 3 \dots$, $k = 1, 3, 5 \dots$ y s es el deslizamiento del motor.

5.2.2.1. Componente Secuencial Negativo

El método de las componentes simétricas es una técnica matemática para describir sistemas desbalanceados de potencia. Para un sistema trifásico, las componentes secuenciales están descritas por la ecuación (4):

$$\begin{aligned} I_{a0} &= \frac{1}{3} (I_a + I_b + I_c) \\ I_{a1} &= \frac{1}{3} (I_a + \alpha I_b + \alpha^2 I_c) \\ I_{a2} &= \frac{1}{3} (I_a + \alpha^2 I_b + \alpha I_c) \end{aligned} \quad (4)$$

Donde I_{a0} , I_{a1} , e I_{a2} son las componentes cero, positiva, y negativa, respectivamente, y α es un operador de rotación de fase equivalente a rotación $e^{j2\pi/3}$ o 120° . Un sistema trifásico de corrientes balanceado solo contendrá componente secuencia positiva, la secuencia negativa es una indicación de la

cantidad de desbalance (o asimetría) en el sistema. Finalmente, la componente cero es una medida de la cantidad de corriente que no está retornando por los conductores de fase (11).

Las asimetrías en las corrientes de una máquina eléctrica trifásica pueden ser ocasionadas por una variedad de razones: 1) Corto circuito en el estator del motor, 2) Asimetrías inherentes a la máquina o a la instrumentación. 3) Fluctuaciones de la carga, 4) Fuentes de tensión de alimentación desbalanceadas. Dichas asimetrías se reflejarán en la componente secuencial negativa. Por esta razón, dicha componente se puede emplear como indicador de falla, en el caso de corto circuito en el devanado del estator, ya que ha sido demostrado en (12) el incremento de la componente secuencial negativa en presencia de este tipo de falla.

5.3. Máquinas De Soporte Vectorial(23)(24)(25)

Para facilitar la comprensión de las SVM (support vector machine), se considerará un problema de clasificación lineal y binario con características x y valores de clasificación y . Se usará $y \in \{-1,1\}$ para denotar los valores de clase. Además, en lugar de parametrizar el clasificador lineal con el vector θ , se usarán los parámetros ω, b y escribir el clasificador como

$$h_{\omega,b}(x) = g(\omega^T x + b) \quad (5)$$

Donde $g(z) = 1$ si $z \geq 0$ y $g(z) = -1$ en otro caso. Esta notación permite tratar el término de intercepto, b de forma separada de los otros parámetros. El vector ω es entonces un vector de la forma $[\theta_1 \dots \theta_n]^T$.

Por la definición dada a g , este tipo de clasificador predecirá directamente 1 o -1 sin necesidad de estimar primero la probabilidad de que y sea 1 (como se lleva a cabo en la regresión logística, con fines de clasificación binaria).

Márgenes Funcional y Geométrico

Dado un ejemplo de entrenamiento $(x^{(i)}, y^{(i)})$, se define el margen funcional de (ω, b) con respecto al ejemplo de entrenamiento como:

$$\hat{y}^{(i)} = y^{(i)}(\omega^T x + b) \quad (6)$$

Si $y^{(i)} = 1$, entonces para que la predicción sea lo suficientemente confiable y correcta (el margen funcional debe ser lo suficientemente grande), es decir, se requiere que $\omega^T x + b$ sea un número positivo grande. De la misma forma, si $y^{(i)} = -1$, se requiere que $\omega^T x + b$ sea un número negativo grande. Así, si $y^{(i)}(\omega^T x + b) > 0$, entonces la predicción en este ejemplo será correcta. Se concluye entonces que un margen funcional grande representa una predicción correcta y muy confiable.


En general, el valor de g y por supuesto de $h_{\omega, b}(x)$ depende solo del signo, mas no depende de la magnitud de $\omega^T x + b$. Reemplazando (ω, b) por $(2\omega, 2b)$ es lo mismo que multiplicar el margen funcional por un factor de 2, por lo que se podría hacer el margen funcional lo suficientemente grande (arbitrariamente) sin cambiar el valor de g . Si se impone entonces una normalización como $\|\omega\|_2 = 1$ se podría reemplazar (ω, b) por $(\frac{\omega}{\|\omega\|_2}, \frac{b}{\|\omega\|_2})$ y considerar el margen funcional de esto último.

Dado un set de entrenamiento $S = \{(x^{(i)}, y^{(i)}); i = 1, \dots, m\}$ se define el margen de función de (ω, b) con respecto a S como el menor de los márgenes funcionales de cada uno de los ejemplos de entrenamiento. Denotado por $\hat{y}$, puede ser escrito como:

$$\hat{y} = \min_{i=1, \dots, m} \hat{y}^{(i)} \quad (7)$$

Para hablar del margen geométrico, se considera la figura 1, a continuación:

Figura 1. Margen geométrico para un problema de clasificación binario y lineal



Fuente: CS229 Lecture notes. Part IV. Andrew Ng. Stanford University.

En la figura se puede observar la frontera de decisión correspondiente a (ω, b) . Nótese que el vector ω es ortogonal al hiperplano que separa las dos clases, luego, $\omega/\|\omega\|$ es un vector unitario en la misma dirección de ω . Considérese el punto A, que representa la entrada de algún ejemplo de entrenamiento, $x^{(i)}$ que corresponde a $y^{(i)}=1$. La distancia del punto A a la barrera de decisión, $\gamma^{(i)}$, está dada por el segmento de línea AB. Como A representa a $x^{(i)}$, es claro que B está dado por la diferencia $x^{(i)} - \gamma^{(i)} \cdot \omega/\|\omega\|$. El punto B yace en la barrera de decisión, es decir que, al igual que todos los puntos en la barrera de decisión, satisface $\omega^T x + b = 0$. Por lo tanto, reemplazando la expresión para el punto B, en la expresión de la barrera se obtiene:

$$\omega^T (x^{(i)} - \gamma^{(i)} \cdot \frac{\omega}{\|\omega\|}) + b = 0 \quad (8)$$

Resolviendo la ecuación (8) para $\gamma^{(i)}$ se tiene:

$$\gamma^{(i)} = \frac{\omega^T x^{(i)} + b}{\|\omega\|} = \left(\frac{\omega}{\|\omega\|} \right)^T x^{(i)} + \frac{b}{\|\omega\|} \quad (9)$$

De forma general, se define el margen geométrico de (ω, b) con respecto a un ejemplo de entrenamiento $(x^{(i)}, y^{(i)})$ como :

$$\gamma^{(i)} = \left(\left(\frac{\omega}{\|\omega\|} \right)^T x^{(i)} + \frac{b}{\|\omega\|} \right) \quad (10)$$

Debe notarse que si $\|\omega\| = 1$, entonces el margen funcional será igual al margen geométrico. También, el margen geométrico es invariante ante escalamientos de los parámetros. Esto quiere decir que se podrá imponer una condición arbitraria para adecuar $\omega y b$ a los datos de entrenamiento (como por ejemplo, $\|\omega\| = 1$).

También se puede definir el margen geométrico de (ω, b) con respecto al set de entrenamiento $S = \{(x^{(i)}, y^{(i)}); i = 1, \dots, m\}$ para que sea el menor de los márgenes geométricos de cada uno de los ejemplos de entrenamiento:

$$\gamma = \min_{i=1, \dots, m} \gamma^{(i)} \quad (11)$$

Clasificador de Margen Óptimo

Como resultado de la anterior discusión se llega a que es una decisión natural el querer encontrar los parámetros de una barrera de decisión que maximice el margen geométrico, porque ello implicaría, como se mencionó antes, una predicción muy confiable y correcta. De forma más específica, se obtendría un clasificador que separa los ejemplos positivos y negativos del entrenamiento mediante una brecha (que es el margen geométrico).

Si se asume por ahora que el set de entrenamiento es linealmente separable, se puede plantear el siguiente problema de optimización:

$$\max_{\gamma, \omega, b} \gamma$$

Con las condiciones siguientes:

$$\begin{aligned} y^{(i)}(\omega^T x + b) &\geq \gamma, \quad i = 1, \dots, m \\ \|\omega\| &= 1 \end{aligned} \tag{12}$$

De manera alterna (25), para encontrar el hiperplano que separa las dos clases de manera óptima es necesario realizar una maximización del margen resolviendo el siguiente problema de optimización, teniendo en cuenta que el margen es inversamente proporcional a $\|\omega\|$:

$$\min_{\omega, b} \frac{1}{2}(\omega \cdot \omega)$$

Sujeto a la restricción:

$$y_i(\omega \cdot x_i + b) \geq 1 \quad i = 1, \dots, m \tag{13}$$

Cuando se usan los multiplicadores de lagrange con $\alpha_i \geq 0$ para resolver problemas de máximos y mínimos con condiciones, dichos problemas se transforman en la representación dual de la ecuación (14), luego el objeto es la minimización del lagrangiano L :

$$L(\omega, b, \alpha) = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^n \alpha_i [y_i(\omega \cdot x_i + b)] \tag{14}$$

Los puntos con α_i diferente de cero serán los vectores de soporte, que serán la base de la separación de las clases.

Caso no linealmente separable(25)

Cuando los elementos de las clases están mezclados en el espacio (un problema común), se emplea una estrategia conocida como “softmargin”. Para permitir que haya una “relajación” de las condiciones de optimización se usan variables de holgura (ξ_i) y las nuevas condiciones serán:

$$y_i(\omega \cdot x_i + b) \geq 1 - \xi_i \quad i = 1, \dots, m \quad (15)$$

$$\text{Con } \xi_i \geq 0 \quad i = 1, \dots, m$$

El hiperplano óptimo puede ser obtenido usando el criterio de “softmargin” propuesto en la ecuación (16):

$$\min_{\omega, b} \frac{1}{2}(\omega \cdot \omega) + C \sum_{i=1}^m \xi_i \quad (16)$$

Sujeto a

$$y_i(\omega \cdot x_i + b) \geq 1 - \xi_i \quad i = 1, \dots, m$$

Donde el parámetro C es llamado constante de penalización de errores, que es definida según el criterio de diseño del algoritmo empleado. Cuando de nuevo, se emplean los multiplicadores de Lagrange, este problema se transforma en la ecuación (17):

$$\max_{\alpha} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (17)$$

Sujeto a

$$0 \leq \alpha_i \leq C, \text{ para } i = 1, \dots, m \quad \text{y} \quad \sum_{i=1}^m \alpha_i y_i = 0$$

Máquinas de Soporte Vectorial basadas en Kernel(25)

En caso de tener ejemplos de datos que no son linealmente separables, es posible transformar el set de datos a un nuevo espacio dimensional, donde los datos son separables linealmente. La función de transformación o mapeo, $\phi(\cdot)$ es definida en términos de los productos escalares de los datos en el espacio original de clasificación. En lugar de especificar la función de transformación, se especifican sus funciones Kernel, $K(u \cdot v)$ porque éstos realizan la transformación y el producto escalar en un solo paso.

El uso apropiado de una función Kernel, las máquinas de soporte vectorial pueden clasificar los datos en un nuevo espacio, por lo que los algoritmos de clasificación lineal pueden extenderse a casos no lineales, usando una función de Kernel apropiada.

En (26) se propone un esquema de detección y diagnóstico de fallas en motores de inducción que consiste en cuatro etapas principales:

- ✓ Adquisición de datos, que consiste en la consecución de diferentes ejemplos de entrenamiento y de validación para la máquina de soporte vectorial. Estos ejemplos incluyen los datos experimentales de la corriente de las tres fases del motor bajo diferentes escenarios de carga y de severidad de la falla.
- ✓ Extracción de parámetros, que generalmente son parámetros estadísticos. Son valores que representan a un vector de muestras de determinado periodo de tiempo, correspondientes a cada ejemplo de entrenamiento.
- ✓ Selección de parámetros, que consiste en escoger aquellos parámetros de un set que contengan mayor información acerca de las señales de corriente en el dominio del tiempo y también en el dominio de la frecuencia, de manera que se reduzca el número de dimensiones en el problema de clasificación y con ello, la complejidad del mismo. Para ello se emplean diversos métodos estadísticos o las pruebas de clasificación.

- ✓ Clasificación de las fallas. Clasificadores basados en redes neuronales, redes bayesianas y máquinas de soporte vectorial, cuyos parámetros se varían para obtener el mínimo de errores de clasificación y la generalización del clasificador implementado. En general, la generalización de un clasificador aumenta a medida que aumentan los ejemplos de entrenamiento.

Este esquema es compartido por la mayoría de la literatura

5.4. Selección de Parámetros en Problemas de Clasificación

Antes de proceder con el diseño de un clasificador, se deben establecer los rasgos que van a representar a los eventos o señales medidas. En esta sección se describirá la teoría y el proceso para establecer los rasgos útiles para la clasificación de fallas.

En muchas aplicaciones el número de rasgos que pueden representar a un problema de clasificación puede ser elevado, incluso este número puede alcanzar docenas, e incluso cientos, haciendo que la dimensionalidad de los vectores de parámetros sea muy elevada.

Por qué reducir en Número de Dimensiones?

Existen varias razones por las cuales reducir el número de rasgos a un mínimo suficiente es ventajoso. La primera de ellas es que la complejidad computacional se reduce al tener pocos rasgos. La segunda razón es que los rasgos que están correlacionados redundan, incrementando el número de dimensiones y por lo tanto la complejidad, por lo que se recomienda encontrar un compromiso entre el número de dimensiones y lo representativo que sea un solo rasgo que reemplace a dos rasgos mutuamente relacionados. Finalmente, la capacidad de generalización de un clasificador está relacionada con el número de rasgos seleccionados. Entre mayor sea la relación entre el número de rasgos de

entrenamiento y el numero de parámetros de clasificación independientes, mayor será la capacidad de generalización, y por tanto menor será la incidencia de errores de clasificación.

La tarea de optimizar el numero de rasgos (Selección de Rasgos) consiste entonces en, dado un numero de rasgos, seleccionar aquellos que sean más representativos, reduciendo el número de dimensiones del problema de clasificación y reteniendo la mayor cantidad de información posible. De la cantidad de información que contengan los rasgos seleccionados depende el desempeño del clasificador y la simplicidad del mismo. Esto se ve reflejado en la magnitud del margen máximo para los datos de entrenamiento y la varianza de los mismos.

El pre procesamiento de los datos son las operaciones que se realizan sobre los mismos antes de su utilización. Las tres acciones de pre procesamiento más importantes son:

Remoción de puntos aislados:

Un punto aislado es un punto que reside muy lejos de la media de la variable aleatoria correspondiente, ya sea por medidas ruidosas u otros factores, lo que lleva a errores muy grandes durante el entrenamiento. Usualmente, esa distancia se toma como un número determinado de veces la desviación estándar (2 ó 3 veces la desviación estándar).

Normalización de Datos

Se realiza en aquellas situaciones en las cuales los diferentes parámetros se encuentran en rangos dinámicos diferentes con el fin de igualar la influencia de todos los parámetros en la función de costo. Una forma de normalización directa es usando los estimados de la media y la varianza para cada parámetro (27). Para N datos en el k -ésimo parámetro se tiene:

$$\overline{x_k} = \frac{1}{N} \sum_{i=1}^N x_{ik} \text{ con } k = 1, 2, \dots, l \quad (18)$$

$$\sigma_k^2 = \frac{1}{N-1} \sum_{i=1}^N (x_{ik} - \overline{x_k})^2 \quad (19)$$

Y la normalización se hará mediante la siguiente ecuación lineal:

$$\widehat{x_{ik}} = \frac{x_{ik} - \overline{x_k}}{\sigma_k} \quad (20)$$

Por lo que ahora, todos los datos tendrán media cero y varianza unitaria.

Existen muchos otros métodos de normalización, entre estos, existen algunos no lineales, que se emplean cuando la distribución de los datos alrededor de la media no es uniforme. Uno de estos métodos es escalamiento softmax, que consiste en aplicar las ecuaciones (21) y (22):

$$y = \frac{x_{ik} - \overline{x_k}}{r \sigma_k} \quad (21)$$

$$\widehat{x_{ik}} = \frac{1}{1 + \exp(-y)} \quad (22)$$

El efecto es limitar los datos al rango [0,1], donde el factor de escalamiento r es definido por el usuario.

Datos faltantes

Se presenta cuando algunos parámetros no aparecen en algunos vectores de parámetros, debido a que los datos no fueron dados, o transmitidos, en el caso de los sensores remotos, por ejemplo. Este problema es comúnmente sorteado colocando ceros en los espacios vacíos o bien la media computada con la información disponible de determinado parámetro. También se puede calcular la

media condicional, si se tiene un estimado de la función de densidad de probabilidad de los valores faltantes, completar los valores que no están (imputación) y descartar aquellos vectores con valores faltantes (si hay suficientes vectores).

El primer paso en la selección de parámetros es la revisión individual del comportamiento de los mismos, respecto a la información que puedan aportar:

Revisión de parámetros Individuales

Pruebas estadísticas de hipótesis (t-test)

Teniendo un conjunto de muestras de determinado parámetro, con su respectiva calificación, se intenta probar si los valores del parámetro en las dos clases difieren de forma significativa, por lo que este método consiste en determinar cuál de las dos hipótesis se cumple para cada par de clases:

H_1 : Los valores de media del parámetro en las dos clases difieren (Hipótesis alternativa)

H_0 : Los valores de media del parámetro en las dos clases son iguales (Hipótesis nula)

Si la hipótesis nula resulta cierta, el parámetro que se está evaluando se descarta, si la hipótesis alternativa resulta cierta, el parámetro es seleccionado. Estas pruebas son ejecutadas teniendo en cuenta un valor o nivel de significancia, p , que corresponde a la probabilidad de cometer un error en la decisión, por tanto entre más pequeño se seleccione el valor de significancia, más difícil será la obtención de una hipótesis alternativa y más confiable será la decisión que se tome respecto a la selección de determinado parámetro.

Entre otros métodos de selección de parámetros se encuentran *Receiver Operating Characteristic (ROC)* que es una medida de la capacidad de discriminación entre clases de un parámetro determinado. Mide el traslape de las

funciones de densidad de probabilidad que describen la distribución de los datos de un mismo parámetro en dos clases y usualmente se cuantifica en términos del área común a las dos curvas. La *Relación discriminante de Fisher* es empleada para cuantificar el poder discriminatorio de un parámetro entre dos clases equiprobables, independientemente de la distribución de las mismas. Si m_1 y m_2 son los valores medios respectivos y σ_1^2 y σ_2^2 son las varianzas respectivas asociadas con los valores del parámetro en dos clases distintas, la relación discriminante de Fisher se define como:

$$FDR = \frac{(m_1 - m_2)^2}{(\sigma_1^2 + \sigma_2^2)} \quad (23)$$

5.5. Generación de Parámetros

Transformar los datos provenientes de medidas en algunos otros datos después de procesamientos diversos que descarten las redundancias presentes en los datos originales y que “compriman” la información con la suficiente representatividad para los fenómenos o eventos medidos es de vital importancia en todas las tareas asociadas a reconocimiento de patrones. En esta sección se describen algunas de estas transformaciones que dan como resultado un conjunto de valores que representan lo mejor posible la información original de las medidas, facilitando las labores computacionales. Una vez se tiene un set de diversos parámetros, se busca reducir la dimensión del espacio de parámetros para reducir la complejidad del problema de reconocimiento de patrones.

5.6. Parámetros usados para la detección de fallas en Motores de Inducción

Con el fin de clasificar fallas en los motores de inducción se deben proponer diferentes parámetros que representen lo suficientemente bien a la señal de corriente. En diversos problemas de clasificación es común el uso de parámetros

de dominio tiempo como la media, la desviación estándar y Skewness. Particularmente, en los problemas de clasificación referentes a fallas en motores de inducción se encuentra que los sets de entrenamiento están compuestos por parámetros tanto de dominio tiempo como del dominio de la frecuencia, gracias al aporte que ha logrado consolidar la técnica MCSA (Motor CurrentSignatureAnalysis) al identificar que componentes de frecuencias particulares incrementan su energía a lo largo del desarrollo de una falla determinada. Entre dichas fallas se han estudiado Corto circuito, barras rotas, excentricidad del entrehierro y defectos en rodamientos, con resultados sobresalientes en la detección de barras rotas (28), especialmente.

Los parámetros que emplean los trabajos estudiados se clasifican en:


- ✓ Parámetros en el dominio del tiempo
- ✓ Parámetros en el dominio de la frecuencia

Los parámetros en el dominio del tiempo son en su mayoría parámetros estadísticos que pueden ser interpretados en términos del histograma de datos (29). La varianza es una medida del ancho del histograma, es decir, cuanto difieren los datos de la media. En (30) se establece que para usar la media como parámetro es necesario remover los valores sospechosos u “outliers” antes de calcularse, mientras que la mediana es inmune a estos valores. El skewness es una medida del grado de simetría del histograma y kurtosis es una medida de lo aguda que sea la distribución del histograma. Por su parte, la entropía es una medida de la uniformidad del histograma. Entre más parecidos sean los valores del histograma entre sí, mayor será el valor de la entropía. La figura 2 muestra variaciones de un histograma original de una imagen (Figura 2.a). Las figuras 2.e y 2.f se espera que tengan valores de kurtosis alto y bajo, respectivamente.

Se puede observar también, que el histograma original debe tener un valor elevado de kurtosis. Así mismo, para las figuras 2.c y 2.d se pueden distinguir de

las figuras 2.b, 2.e y 2.f por tener valores de skewness diferentes de cero, por tener un sesgo (negativo y positivo, respectivamente).

Figura 2. Parámetros del histograma a) Histograma original b) histograma con distribución normal c) histograma con skewness negativo d) histograma con skewness positivo e) histograma con kurtosis alta f) histograma con kurtosis baja.



Fuente: Referencia (30)

Asimismo, se espera que el histograma de la figura 2.e tenga el valor más alto de entropía, ya que es el más uniforme. Otros parámetros en el dominio del tiempo usados para la detección de fallas en motores de inducción son la media, el valor rms y el factor de cresta.

El Factor de cresta es igual a la amplitud del pico de la forma de onda dividida por el valor RMS. El propósito del cálculo del factor cresta es dar una indicación de qué tanto la falla está impactando la forma de onda en forma de “spikes”. Dichos impactos están asociados a fallas en motores y otras máquinas rotativas.

Por otra parte, entre los parámetros en el dominio de la frecuencia se encuentran: el centro de frecuencia, hallado como el centro de masa del espectro respecto a la fundamental, desde una frecuencia f_1 hasta una frecuencia f_2 . Las variaciones del

centro de frecuencia son relacionadas con fallas. El centro de frecuencia se halla como lo indica la ecuación siguiente (31).

$$FC = \frac{\sum_{f1}^{f2} f s(f) \Delta f}{\sum_{f1}^{f2} s(f) \Delta f} \quad (24)$$

Rootvariancefrequency también es otro factor que puede usarse para detectar componentes anómalas en el espectro, entre dos valores de frecuencia de interés.

$$RVF = \left[\frac{\sum_{f1}^{f2} (f - FC)^2 s(f) \Delta f}{\sum_{f1}^{f2} s(f) \Delta f} \right]^{\frac{1}{2}} \quad (25)$$

A continuación se describen los parámetros empleados en algunos trabajos relacionados con las fallas de inetrés: En (26) se extraen 13 parámetros estadísticos que incluyen el valor RMS de la señal con media cero (que es la desviación estándar), el coeficiente de Kurtosis y los valores máximo y mínimo del coeficiente del valor de skewness. En este trabajo emplean la técnica PCA (Principal componentAnalysis) para determinar cuáles son los parámetros más apropiados dentro del conjunto inicial. PCA es considerado como un método clásico de reducción de dimensionalidad a través de análisis estadístico. En (32) se proponen como parámetros principales, el área bajo la curva de los armónicos laterales a la fundamental, así como el ángulo de cresta de dichos armónicos y la amplitud de los mismos, extraídos de la densidad espectral de potencia de la corriente en estado estable usando la FFT. En este estudio se concluye que para la detección de barras de rotor rota, la combinación de dos primeros parámetros tiene resultados mejores que el uso de la amplitud como parámetro de clasificación. Por otra parte, la transformada de Park se usa usualmente para la detección de fallas de excentricidad y barras rotas en motores. Para ello, se

extraen parámetros a partir de la transformación DQ, como lo indica la ecuación (34):

$$\begin{cases} i_d = \sqrt{\frac{2}{3}} i_a - \frac{1}{\sqrt{6}} i_b - \frac{1}{\sqrt{6}} i_c \\ i_q = \frac{1}{\sqrt{2}} i_b - \frac{1}{\sqrt{2}} i_c \end{cases} \quad (26)$$

Esta transformación permite disminuir el número de variables (de tres a dos), conservandola información contenida en las tres señales. En (33) se establece que en la práctica, las fallas menores al 5% de las espiras cortocircuitadas no son fácilmente detectables. En este trabajo se usó la transformación de Park y la transformada wavelet continua para la extracción de parámetros (tres en total) como entradas de una herramienta de detección de corto circuito basada en SVM.

En (34) se implementa un sistema de detección basado en máquinas de soporte vectorial usando las señales de corriente y vibraciones en tres ejes. En este trabajo se emplean como parámetros en el dominio del tiempo la media, el valor RMS, shape factor, skewness, kurtosis, factor de cresta, entropía, entre otros. Los parámetros empleados en el dominio de la frecuencia son el valor RMS, la frecuencia central y rootvariancefrequency. En dicho trabajo la estrategia de clasificación multiclase empleada es tanto uno contra el resto como uno contra uno. En dicho estudio se uso la técnica de validación cruzada (10 foldcrossvalidation) para obtener los mejores valores de los parámetros de entrenamiento.

6. METODOLOGÍA

El desarrollo del presente proyecto consistió en cuatro etapas en las cuales se programaron actividades específicas concordantes con el nivel de avance del mismo. A continuación se presenta una breve descripción de cada una de las etapas:

6.1. Revisión Bibliográfica e identificación de requerimientos

Esta etapa consiste en la búsqueda de producción científica nacional e internacional acerca de los temas a tratar en el proyecto, así como el levantamiento de requisitos para la construcción de un banco de pruebas de motores de inducción.

6.2. Adquisición y almacenamiento de datos en diferentes condiciones de falla y carga.


Esta etapa incluye la generación de cada una de las condiciones de falla listadas a continuación, y la toma de datos del motor en operación bajo cada una de esas condiciones:

Tabla 1. Posibles escenarios de toma de datos de corriente del estator


Nivel de Carga	Sin Cargaacoplada			Cargaacoplada 75%			Cargaacoplada 85%		
Motor 1 (Corto Circuito entre espiras de una fase)	2%	5%	10%	2%	5%	10%	2%	5%	10%
Motor 3 (Barras Rotas)	1 barra rota	2 barras rotas	3 barras rotas	1 barra rota	2 barras rotas	3 barras rotas	1 barra rota	2 barras rotas	3 barras rotas

En las pruebas se emplean motores de 2 Hp, 440/220V, 4 polos, 22 barras de rotor, 1800 rpm, 60 Hz. La Figura 3 muestra una fotografía del banco de pruebas implementado, así como un diagrama esquemático de las componentes del banco de prueba que permite la aplicación de la metodología MSCA. Las condiciones de carga del 75% y 85% de la corriente nominal son obtenidas utilizando como carga del motor un generador shunt de corriente continua de 220 VDC al cual se le conectan cargas resistivas.

Figura 3. a) Banco de pruebas implementado b) Esquema de las componentes del banco de pruebas



a)



b)

Fuente: Autora

El sistema de adquisición de datos es implementado en Matlab/Simulink® con el software Windaq® como interfaz con el hardware. Los algoritmos utilizados en la implementación de la metodología MCSA fueron desarrollados en Matlab/Simulink®. El sistema de adquisición DataQ® DI-730-USB permite el registro y visualización de las tres corrientes de fase provenientes de tres pinzas AC/DC de efecto hall que permiten la adquisición de la corriente de los conductores de alimentación del motor a una frecuencia de muestreo de 5 KHz.

6.2.1. Emulación y toma de datos para corto circuito en el estator

El cortocircuito se emuló reconstruyendo el devanado de una fase del estator con varios terminales accesibles para variar el nivel de severidad de la falla inducida. Los niveles de severidad que se establecieron corresponden al 2%, 5% y 10% de espiras de una fase cortocircuitadas. La Figura 4 muestra la disposición de los terminales. Para emular diferentes condiciones de operación, una carga es aplicada al motor obteniéndose el 75% y 85% de la corriente nominal del mismo.

Figura 4. Terminales de los devanados de una fase para la variación de severidad del corto.



Fuente: Autora

Para las condiciones descritas y empleando una frecuencia de 5000 muestras por segundo se capturó 10 segundos de las tres señales de corriente del estator. Esto se hizo en varias ocasiones (diferentes días) y se tomó en cuenta la toma más favorable en cuanto a los resultados de la detección.

6.2.2. Emulación y toma de datos de barras rotas en el rotor.

Para emular las condiciones de falla, las barras del rotor fueron perforadas progresivamente de tal forma que el nivel de severidad del daño está determinado por el número de barras perforadas. Así, tres niveles de severidad fueron inducidos, correspondientes a 1, 2 y 3 barras rotas. La figura 5 muestra la

condición más severa inducida al rotor de motor de inducción correspondiente a tres barras rotas.

Figura 5. Rotor usado en la experimentación con tres barras rotas



Fuente: Autora

6.3. Adaptación del algoritmo de detección usando máquinas de soporte vectorial.

Se probaron las diferentes formas de obtención del espectro, como la FFT o el método de Welch, para comparar la detectabilidad de cada una de las fallas bajo ambos enfoques. Se escogió aquella que presentó los mejores resultados, teniendo en cuenta la conveniencia de su implementación en el algoritmo de SVM.

Se realizó una adecuación de la técnica de inteligencia artificial de máquinas de soporte vectorial (SVM) a los requerimientos de la detección y clasificación de las fallas implementadas. Tanto el set de entrenamiento como el de validación fue un conjunto de señales reales obtenidas de la simulación de las fallas y los experimentos descritos en la etapa 8.2, por lo que se puso a prueba la robustez del sistema de clasificación basado en la técnica SVM. El algoritmo de SVM corresponde al empleado por Theodoridis et al.[27].

6.4. Informe final y divulgación de resultados

La última etapa de desarrollo del proyecto está enfocada al acondicionamiento final de los algoritmos desarrollados, la documentación del desarrollo de los mismos, y la divulgación a la comunidad científica de los resultados obtenidos, conclusiones, y propuestas a futuro del proyecto. Finalmente se realizará el informe final del proyecto y se divulgará a través de presentaciones y publicaciones de carácter científico y tecnológico. Se resaltarán la adaptación del método al tipo de proceso estudiado, verificando los aportes hechos en el campo de la Inteligencia Artificial.

7. RESULTADOS Y ANÁLISIS

MCSA es una técnica de monitorización de máquinas eléctricas, ampliamente utilizada, que permite diagnosticar el estado eléctrico y mecánico de motores eléctricos usando la información obtenida en la señal de corriente. Dicha información se extrae utilizando algoritmos de procesamiento de señales y técnicas matemáticas como: Transformada Rápida de Fourier (FFT), Transformada wavelet, PowerSpectralDensity, y medidas estadísticas como la media o kurtosis.

El método de Welch es un método no paramétrico que se utiliza para mejorar la relación señal ruido de las señales cuya densidad espectral de potencia es estimada usando periodograma. El periodograma es un método para la obtención de densidad espectral de potencia, que está definido por la ecuación (35).

$$\hat{S}_k(e^{jw}) = \sum_{k=-N+1}^{N-1} \hat{r}_k(k) e^{-jkw} \quad (27)$$

Donde:

$\hat{S}_k(e^{jw})$: Periodograma

$\hat{r}_k(k)$: Secuencia de auto correlación.

N : Puntos de longitud de cada segmento.

La estimación del periodograma con el método de Welch consiste en dividir una señal en el dominio del tiempo en segmentos que se superponen o traslapan en un 50 %, para luego aplicar a cada segmento una ventana en el dominio del tiempo. Finalmente el periodograma es estimado computando la transformada discreta de Fourier y luego estimando la magnitud elevada al cuadrado de dicha transformada en cada segmento, para luego promediar los resultados de todos los segmentos y obtener la densidad espectral de potencia de la señal. La estimación de la densidad espectral de potencia usando el periodograma de Welch es

adecuada para la detección de las fallas en el dominio de la frecuencia debido a que permitió diferenciar con mayor claridad la presencia de la falla y especialmente los diferentes grados de severidad inducidos, con respecto a la FFT.

7.1. Resultados obtenidos cuando se presenta un corto circuito en el estator


7.1.1. Análisis del espectro de corriente

Caso 1. Corto circuito sin carga acoplada

La Figura 6 muestra las componentes del espectro de la corriente de una de las fases del motor sin carga acoplada para un ancho de banda entre 500 y 600 Hz. La densidad espectral de potencia entre 0 y 2500 Hz muestra solo la activación de una frecuencia alrededor de 540 Hz, entre las frecuencias reportadas en distintos artículos. Teniendo en cuenta este resultado, se espera la activación de esta componente para condiciones de carga superiores.

La severidad de la falla de corto circuito corresponde a 2%, 5% y 10% de las espiras de una fase en corto circuito.

Figura 6. Densidad espectral de potencia alrededor de 540 Hz para detección de corto.



Fuente: Autora

Caso 2. Corto circuito con 75% de carga acoplada

Otro experimento es llevado a cabo en condiciones similares a las del caso uno, con una carga acoplada al motor, representando el 75% de la corriente nominal del mismo. Los datos fueron tomados para las severidades de 2%, 5% y 10% de espiras cortocircuitadas. Como se esperaba, a partir del caso 1, la amplitud de la componente espectral en 540 Hz muestra un comportamiento consistente con el grado de severidad, mostrando una variación máxima de 8 dB entre la condición normal y el mayor grado de severidad (10% espiras cortocircuitadas). Sin embargo, una variación de esta misma magnitud, o similar puede ser observada en otras componentes que no están relacionadas con la falla de corto circuito, lo que hace que la sensibilidad del indicador seleccionado no sea satisfactoria para un diagnóstico confiable.

Caso 3. Corto circuito con 85% de carga acoplada

Un tercer experimento es llevado a cabo para evaluar el mismo indicador bajo una condición de carga de 85% de la corriente nominal, con los mismos porcentajes de espiras cortocircuitadas (2%, 5% y 10%). Las pruebas muestran que no existen componentes relevantes en el rango seleccionado entre 500 y 600 Hz, por lo que este rango, bajo una elevada condición de carga no es una elección apropiada para detectar las condiciones de falla inducidas en el banco de pruebas, ya que a esta condición de carga las componentes espectrales han desaparecido.

Con base en los resultados previos, puede concluirse que escoger una frecuencia de las decenas que sugiere la teoría como indicador de falla no es garantía de una detección confiable bajo todos los regímenes de carga del motor. Adicionalmente se concluye que incrementar la carga del motor atenúa las componentes f_{st} , haciendo más difícil el obtener resultados precisos en la detección del corto circuito usando la metodología MCSA.

7.1.2. Componente Secuencial Negativa I_{a2}

La búsqueda de un indicador que no deteriore su capacidad de detección de fallas a medida que se incrementa el nivel de carga del motor lleva al uso de la componente secuencial negativa. Un algoritmo de extracción de I_{a2} es implementado en Simulink de Matlab, empleando como entradas los mismos datos capturados para el análisis MCSA previo. La descripción de las condiciones experimentales para los tres casos siguientes corresponde con la de los casos en el análisis MCSA, por lo que a continuación se enseñan los resultados de forma inmediata.

Caso 1. Corto circuito sin carga acoplada

La figura 7 muestra las componentes I_{a2} para cada una de las severidades, explícitas en la figura.

Para una condición de operación sin carga, se obtiene un indicador muy claro de presencia de falla usando el valor de I_{a2} . Los valores de componente secuencial negativo que se aprecian en las figuras son relativamente elevados, dado que la corriente nominal del motor es 7 Amperios. Esto se debe al acumulado de los desbalances inherentes de la red de alimentación, del motor, y de los sensores de corriente empleados.


Caso 2. Corto circuito con 75% de carga acoplada

Los valores de I_{a2} , aunque distintos a los del caso 1, por la adición de carga al motor, ofrecen una distinción clara del nivel de severidad de la falla de corto circuito (Ver tabla 2).

Caso 3. Corto circuito con 85% de carga acoplada

Nuevamente, los valores de I_{a2} se incrementaron por la presencia de una mayor carga, pero aún así permiten distinguir tanto la presencia de falla, como el grado de severidad de la misma (Ver tabla 2).

Figura 7. Componente secuencial negativa para el motor sin carga acoplada.



Fuente: Autora

Tabla 2. Valor medio de I_{a2} para los casos del experimento.


Severidad de Falla	I_{a2} (A)		
	0% Carga	75% Carga	85% Carga
Condición Normal	0.35	0.37	0.72
2% Falla	0.39	0.40	0.79
5% Falla	0.43	0.45	0.82
10% Falla	0.82	0.84	0.85

Los resultados previos permiten concluir que existe un leve incremento en el valor de I_{a2} cuando la carga es incrementada. Esto significa que no habrá un solo valor de I_{a2} que caracterice a la condición normal del motor, sino que este valor dependerá del nivel de carga al que esté sometido el motor. La tabla 2 presenta los valores medios de I_{a2} para todos los niveles de severidad inducidos y los niveles de carga.

7.2 Resultados obtenidos cuando se presentan barras rotas

Para emular las condiciones de falla, las barras del rotor fueron perforadas progresivamente de tal forma que el nivel de severidad del daño está determinado por el número de barras perforadas. Así, tres niveles de severidad fueron inducidos, correspondientes a 1, 2 y 3 barras rotas. La figura 8 muestra la condición más severa inducida al rotor de motor de inducción correspondiente a tres barras rotas.

Figura 8. Rotor usado en la experimentación con tres barras rotas.




Fuente: Autora

Caso 1. Barras Rotas sin carga acoplada

Este experimento es desarrollado con el fin de realizar la detección de barras rotas usando MCSA cuando el motor opera sin carga. La literatura reporta que el espectro de corriente en presencia de barras rotas presenta frecuencias alrededor de la fundamental. Cuando el motor está operando sin carga y usando (3) se obtienen las frecuencias de 59.5 y 60.5 Hz. Como se nota en la figura 9 las anteriores frecuencias no presentan un cambio sustancial en magnitud con la severidad de la falla, que en este caso corresponde a 1, 2 y 3 barras rotas. Ésto permite concluir que cuando el motor opera sin carga no es posible discriminar los distintos niveles de severidad de barras rotas y más aún la detección de la falla.

Figura 9. Densidad espectral de potencia del caso 1




Fuente: Autora

Caso 2. Barras Rotas con 75% de carga acoplada

Esta prueba se realiza bajo las mismas condiciones de severidad de falla del caso 1, y con una carga acoplada al motor correspondiente al 75% de la corriente nominal. En la figura 10 puede observarse las bandas laterales producidas por la falla inducida. El incremento de la carga produce un incremento en la energía concentrada alrededor de la frecuencia de falla seleccionada. También se observa que los indicadores presentan un comportamiento consistente con la severidad de la falla inducida y que existe una variación máxima de 15 dB/Hz entre las amplitudes correspondientes a la condición normal y la máxima condición de falla, en este régimen de carga.

Figura 10. Bandas laterales asociadas a barras rotas con 75% de carga acoplada. a) Banda lateral izquierda b) banda lateral derecha



Fuente: Autora


Caso 3. Barras Rotas con 85% de carga acoplada

Un tercer experimento se ejecuta con una carga correspondiente al 85% de la corriente nominal del motor, y los mismos niveles de falla usados en el caso 1 y caso 2. Como se observa en las figura 11a y b las bandas laterales se diferencian

claramente y presentan un aumento máximo de aproximadamente 20dB/Hz entre la condición normal y el escenario de falla más grave.

Con base en los anteriores resultados, se concluye que es posible realizar un seguimiento confiable de la condición de las barras del rotor utilizando MCSA, siempre y cuando el motor esté funcionando bajo una condición de carga significativa. Además, tal como se encuentra en la experimentación, el aumento de la carga del motor conduce a la aparición de bandas laterales alrededor de ciertas frecuencias relacionadas tanto a la falla de barras rotas, como a excentricidad del entrehierro. Sin embargo, las bandas laterales en el rango de 56 a 66 Hz se consideran las más apropiadas para la detección de fallas barras rotas en las condiciones especificadas del experimento.

Figura 11. Bandas laterales asociadas con barras rotas con 85% de carga acoplada. A) Banda lateral izquierda. B) Banda lateral derecha.



Fuente: Autora

A partir de las pruebas realizadas para detectar la falla de corto circuito se concluye que las componentes de frecuencia conforman un indicador independiente de otros

tipos de falla, efectivo en condiciones de carga muy baja y con debilidades evidentes ante la adición de carga. Se estudió la técnica de la componente secuencial negativa y se comprobó la efectividad de ésta para la discriminación de la severidad de la falla de corto circuito en diferentes condiciones de carga, por lo que se establece que es un indicador efectivo para la detección del corto circuito, siempre y cuando se descarten de antemano desbalances de la red o inherentes del devanado del motor.

La experimentación con la falla de barras rotas arrojó resultados satisfactorios, especialmente en condiciones de carga reales (75%-85%), donde se logró una identificación plena de la falla, y de los grados de severidad inducidos, usando los indicadores propuestos por la técnica MCSA.

7.3 Parámetros de clasificación de fallas en un motor de inducción.

Los parámetros empleados en este trabajo corresponden a la mayoría de aquellos utilizados en la literatura, especialmente en fuentes como (33), ya que se pensó que tener parámetros en el dominio de la frecuencia serán muy útiles en la detección de las fallas, dada la experiencia previa en la aplicación de la metodología MCSA (35). Dicha experiencia también sugiere la aplicación de la componente de secuencia negativa de la señal de corriente como indicador de severidad de falla (36).

Los 10 parámetros extraídos a partir de la señal de corriente del estator son los que se listan a continuación:

Parámetros en el dominio del tiempo

- ✓ Media
- ✓ Factor de cresta
- ✓ Relación componente de secuencia positiva – componente de secuencia negativa

- ✓ Kurtosis
- ✓ Skewness
- ✓ Valor rms
- ✓ Entropía


Retomando lo mencionado en la sección 2.1, en la que se describió la relación entre los parámetros kurtosis, skewness, y entropía con el histograma de una señal. Para clarificar un poco más este hecho, vale la pena mencionar que el histograma en el caso de este trabajo corresponde a la distribución de amplitudes para una determinada clase. Como un ejemplo, se muestran en la figura 12 los histogramas de un segundo de la señal correspondiente a un motor sano (en rosado) y de un motor con 3 barras rotas (azul), producto de los experimentos realizados en laboratorio. En este caso el histograma sugiere que la entropía puede ayudar a diferenciar las dos condiciones, dado que el histograma correspondiente a la condición de falla tendrá una variación significativa en el valor de entropía, por cuanto el histograma asociado no es tan uniforme como aquel correspondiente a la condición normal. Lo que se establece con la simple inspección del histograma puede corroborarse con el uso de las técnicas descritas en la sección 7.4. Sin embargo esta inspección permitió establecer de forma sencilla los parámetros que entrarían en una inspección posterior.

Parámetros en el dominio de la frecuencia

- ✓ Frecuencia central
- ✓ Rootvariance
- ✓ rms del espectro

El cálculo de los parámetros en el dominio de la frecuencia se realiza teniendo como base la estimación de la densidad espectral de potencia obtenida usando el periodograma de Welch en Matlab, por las razones especificadas anteriormente.

Figura 12. Histograma de 1 segundo de la señal de corriente del motor sin falla y con tres barras rotas




A continuación se presentan algunas gráficas que se usaron para la misma función que los histogramas. Estas figuras permiten observar los sets de datos previamente a la clasificación usando cada uno de los 10 parámetros enunciados en la sección 9.3. En la figura 13 se graficó el valor del parámetro “relación PSC/NSC” (correspondiente al parámetro Relación componente de secuencia positiva sobre componente de secuencia negativa) en función del porcentaje de carga (0%, 75% y 85%) y las muestras, que corresponden en todos los casos a 90 valores extraídos de la señal de corriente de estator. En esta figura 13, al igual que en las siguientes, se observa que la carga tiene una fuerte incidencia en el valor de los parámetros de clasificación. Los colores representan la pertenencia a una determinada clase de tipo de falla. Como ejemplo se tomaron tres clases: motor sin falla, motor con falla de corto circuito y motor con falla de barras rotas. La severidad de las fallas cambia cada 10 unidades del eje “# muestra”, de tal forma que, por ejemplo, las muestras de 1 a 10 (para todas las clases de falla) pertenecen a la

severidad incipiente, las muestras de 11 a 20, una severidad moderada, 21 a 30, un daño severo, correspondientes a una condición sin carga. Por su parte, las muestras de 31 a 40 nuevamente corresponden a una severidad incipiente, aquellas de 41 a 50 a una severidad moderada y aquellas de 51 a 60 corresponden a un daño severo, para una carga del 75%. La misma secuencia se repite para los datos asociados a la carga de 85%.

En la figura 14 se puede establecer que bajo el parámetro de la media de la señal de tiempo se puede diferenciar con claridad la falla de corto circuito de la de barras rotas, y también se puede diferenciar claramente la falla de barras rotas de la condición normal, para todas las condiciones de carga del motor. Sin embargo es fácil observar que este parámetro no funciona por sí mismo para diferenciar entre las fallas de corto circuito y la condición normal.


Figura 13. Gráfica del set de valores para el parámetro PSC/NSC para tres clases



Fuente: Autora

A partir de la figura 15 se puede llegar a una conclusión muy similar a la anterior. Pero también puede establecerse de antemano que el indicador RMS en el dominio de la frecuencia es un indicador más débil para diferenciar la falla de barras rotas cuando ésta tiene el grado de severidad más alto, en cualquiera de las condiciones de carga del experimento, con respecto al parámetro analizado en la figura 14, correspondiente a la media. Esto sugiere que este indicador requiere complementarse con algunos otros para evitar problemas de falta de generalización a condiciones de severidad altas.


Figura 14. Gráfica del set de valores para el parámetro media para tres clases



Fuente: Autora

En el ejemplo de la Figura 16 no se puede determinar con facilidad el desempeño del parámetro Entropía en términos de clasificación entre las tres clases propuestas. Lo que sugiere la literatura en estos casos es usar las herramientas descritas en la sección 7.4 para determinar cuáles parámetros descartar o cómo ordenar los parámetros por importancia, de acuerdo a la separabilidad que estos representen para las clases estudiadas.


Figura 15. Gráfica del set de valores para el parámetro RMS frecuencia para tres clases



Fuente: Autora


Finalmente, para la figura 17 se puede establecer que el parámetro de factor de cresta muy difícilmente podrá diferenciar las tres clases propuestas. Sin embargo, si las clases propuestas fuesen la severidad de la falla de barras rotas con respecto a la condición normal: 1 barra rota vs sin falla, por ejemplo, este parámetro es muy útil y probablemente muy efectivo. Sin embargo al observar los datos pertenecientes a 2 barras rotas (desde 11 hasta 20 en el eje # de muestra) el mismo indicador no podría diferenciar esta condición de la condición normal, en forma sencilla. Ello parece ser común a todas las condiciones de carga.

Figura 16. Gráfica del set para el parámetro Entropía para tres clases



Fuente: Autora

Figura 17. Gráfica del set de valores para el parámetro Factor de Cresta para tres clases




Fuente: Autora

7.4 Selección de parámetros de clasificación

La selección de parámetros consiste en reducir las dimensiones del set de parámetros que son candidatos para la realización de la clasificación, con el fin de simplificar el problema y evitar el overfitting. Para ello es común hacer pruebas estadísticas para chequear individualmente la información que puede discriminar un determinado parámetro candidato. En este caso la prueba estadística empleada fue t-test. Para ello se verificó en primera estancia la distribución de frecuencias de los parámetros seleccionados. Aunque algunos se alejaron con cierto grado de la distribución normal, estos parámetros tuvieron un desempeño de acuerdo a lo establecido por las inspecciones de la sección 9.3 y el t-test. A continuación se presenta una gráfica de evaluación de la probabilidad que tienen los datos de tener una distribución normal, para el parámetro “Relación PSC/NSC”. Esta gráfica permite establecer el grado de pertenencia de cada parámetro a la distribución normal para establecer la viabilidad de aplicar pruebas estadísticas sobre el supuesto de distribución normal.

Figura 18. Gráfica de la probabilidad normal para el parámetro “Relación PSC/NSC”



Fuente: Autora

A continuación se presentan los resultados de evaluación de cada uno de los parámetros preseleccionados:

- ✓ Entropía
- ✓ Relación PSC/NSC
- ✓ Media_tiempo
- ✓ Kurtosis_tiempo
- ✓ Skewness
- ✓ Factor de Cresta
- ✓ Valor_RMS_tiempo
- ✓ Frecuencia Central
- ✓ RootVariance
- ✓ Valor_RMS_frecuencia

Lo siguiente, recordando lo establecido en la sección 7 acerca de los resultados del t-test:

1: Los valores de media del parámetro en las dos clases difieren (Hipótesis alternativa). 0: Los valores de media del parámetro en las dos clases son iguales (Hipótesis nula)

Finalmente cabe resaltar que se tomó un nivel de significancia de 0.05 para este tipo de prueba.

7.4.1 Prueba de separabilidad entre clases

Esta prueba se realiza con el fin de determinar la capacidad de discriminación de clases de cada parámetro en forma individual. Los resultados de esta prueba por lo tanto no representan el desempeño de combinaciones de parámetros (ello se hizo experimentalmente) en un clasificador, sino que da una idea del futuro desempeño de un determinado parámetro para diferenciar dos clases. A continuación se presentan los resultados del t-test para los parámetros en términos de la separabilidad de las siguientes tres clases, acomodadas por parejas en tres casos (Ver tabla 3):

- ✓ Motor sin falla
- ✓ Motor con falla de corto circuito

- ✓ Motor con falla de barras rotas

Tabla 3. Resultados de t-test para clases de tipo de falla

Parámetro	Caso de separabilidad		
	Sin falla vs. corto	Corto vs. barras rotas	Sin falla vs. Barras rotas
Entropía	1	0	1
Relación PSC/NSC	1	1	1
Media_tiempo	0	1	1
Skewness	0	0	0
Factor de Cresta	0	0	0
Valor_RMS_tiempo	0	0	0
Kurtosis_tiempo	0	0	0
Frecuencia Central	0	1	1
RootVariance	0	0	0
Valor_RMS_frecuencia	0	1	1

Como se puede observar en la tabla 3 se sombrearon los valores resultados del t-test para los parámetros que según la prueba, logran distinguir al menos dos de las tres clases propuestas. Ello indica que estos parámetros son los más opcionados dentro del set inicial de parámetros para formar parte de un clasificador exclusivo para distinguir el tipo de falla. Ellos son:

- Entropía
- Relación PSC/NSC
- Media_tiempo
- Frecuencia Central
- Valor_RMS_frecuencia

Por otro lado, si se usa un clasificador biclase para cada uno de los tres casos, cada clasificador tendría los parámetros para los cuales el t-test es 1, así:

Tabla 4. Parámetros para los clasificadores biclase planteados.

Clasificador	Parámetros
Sin falla vs. corto	Entropía
	Relación PSC/NSC
Corto vs. barras rotas	Relación PSC/NSC
	Media_tiempo
	Frecuencia Central
	Valor_RMS_frecuencia
Sin falla vs. Barras rotas	Entropía
	Relación PSC/NSC
	Media_tiempo
	Frecuencia Central
	Valor_RMS_frecuencia

El valor de frecuencia central, permite determinar el “centro” donde se acumula el área bajo la densidad espectral de potencia, entre dos límites de la misma. En el caso de barras rotas, este indicador se calculó entre las frecuencias 55.98 y 65.91 Hz. En el caso de corto circuito, este indicador se calculó entre 534.97 y 545.04 Hz. Ambos cálculos se hicieron empleando un paso de suma $\Delta f = 0.1526$ Hz.

7.4.2 Prueba de separabilidad entre severidad de falla para corto circuito

A continuación se presentan los resultados del t-test para los parámetros en términos de la separabilidad de las siguientes clases (Ver tabla 4):

- ✓ F2: Falla de 2% de las espiras cortocircuitadas
- ✓ F5: Falla de 5% de las espiras cortocircuitadas
- ✓ F10: Falla de 10% de las espiras cortocircuitadas

También se presentan los resultados del t-test para la diferenciación de dichas fallas con respecto a la condición normal (SF: Sin falla).

Tabla 5. Resultados de t-test para clases de severidad de falla para corto circuito


Parámetro	SF-F2	SF-F5	SF-F10	F2-F5	F2-F10	F5-F10
Entropía	1	1	1	0	0	0
Relación PSC/NSC	1	1	1	1	1	1
Media_ tiempo	0	0	1	0	0	0
Skewness	0	0	0	0	0	0
Factor de Cresta	0	0	0	0	0	0
Valor_RMS_ tiempo	1	0	0	0	0	0
Kurtosis_ tiempo	0	0	0	0	0	0
Frecuencia Central	0	0	0	0	0	0
RootVariance	0	0	0	0	0	0
Valor_RMS_frecuencia	1	0	0	1	1	1

En el caso de tener un clasificador exclusivo para severidad de falla, cuando se tiene una falla de corto circuito, se seleccionó el set de parámetros que obtuvo un resultado positivo en al menos cuatro de las seis clases propuestas. Dicho set está conformado por:

- Relación PSC/NSC
- Valor_RMS_frecuencia

La figura 19 muestra la relación de los parámetros escogidos, en términos de la severidad de falla de corto circuito. Es importante recordar que para el caso de este trabajo, se determinó que una falla correspondiente a 2% de las espiras cortocircuitadas es una falla incipiente o leve; una falla correspondiente al 5% de las espiras cortocircuitadas es una falla moderada y una falla del 10% de las espiras cortocircuitadas es una falla severa. Si se pretende usar un clasificador biclase éste usará los mismos parámetros definidos.

Figura 19. Relación entre los parámetros seleccionados para un clasificador de severidad de falla de corto circuito



Fuente: Autora

7.4.3 Prueba de separabilidad entre severidad de falla para barras rotas

A continuación se presentan los resultados del t-test para los parámetros en términos de la separabilidad de las siguientes clases (Ver tabla 6):

- ✓ 1b: Falla de 1 barra rota
- ✓ 2b: Falla de 2 barras rotas
- ✓ 3b: Falla de 3 barras rotas

Tabla 6. Resultados de t-test para clases de severidad de falla para barras rotas


Parámetro	SF-1b	SF-2b	SF-3b	1b-2b	2b-3b	1b-3b
Entropía	0	1	1	0	0	1
Relación PSC/NSC	0	1	1	0	0	1
Media_tiempo	1	1	1	1	1	1
Skewness	0	0	0	0	0	0
Factor de Cresta	1	0	1	1	1	1
Valor_RMS_tiempo	0	0	0	0	0	0
Kurtosis_tiempo	0	0	0	0	0	0
Frecuencia Central	0	0	0	0	0	0
RootVariance	0	0	0	0	0	0
Valor_RMS_frecuencia	0	0	0	0	0	0

En el caso de tener un clasificador exclusivo para severidad de falla, cuando se tiene una falla de barras rotas, se seleccionó el set de parámetros que obtuvo un resultado positivo en al menos cinco de las seis clases propuestas. Dicho set está conformado por:

- Media_tiempo
- Factor de cresta

La figura 20 muestra la relación de los parámetros escogidos, en términos de la severidad de falla de barras rotas. Es importante recordar que para el caso de este trabajo, se determinó que una falla correspondiente a 1 barra rota es una falla incipiente o leve; una falla correspondiente 2 barras rotas es una falla moderada y una falla 3 barras rotas es considerada una falla severa.

Figura 20. Relación entre los parámetros seleccionados para un clasificador de severidad de falla de corto circuito



Fuente: Autora

Si se usa una estrategia de clasificadores biclase, uno por cada caso enunciado, los parámetros de cada clasificador se resumen a continuación (ver tabla 7):

Tabla 7. Parámetros para los clasificadores biclase planteados.

Clasificador	Parámetros
1 barra rota vs. 2 barras rotas	Media_tiempo
	Factor de cresta
2 barras rotas vs. 3 barras rotas	Media_tiempo
	Factor de cresta
1 barra rota vs. 3 barras rotas	Entropía
	Relación PSC/NSC
	Media_tiempo
	Factor de cresta

En la tabla 8 se presenta un resumen de los parámetros relacionados con la diferenciación entre las clases enunciadas en la sección. Ésta incluye todos los parámetros, sin precisar si el clasificador es uno biclase o una generalización multiclase que incluya un solo set de parámetros para cada conjunto de clases.

Tabla 8. Resumen de parámetros preseleccionados para clasificadores

Clasificador	Parámetros
Tipo de falla	Entropía Relación PSC/NSC Media_tiempo Frecuencia Central Valor_RMS_frecuencia
Severidad de falla de corto circuito	Relación PSC/NSC Valor_RMS_frecuencia
Severidad de falla de barras rotas	Media_tiempo Factor de cresta Entropía Relación PSC/NSC

7.5 Clasificador de fallas en un motor de inducción basado en SVM.

7.5.1 Validación cruzada

Para aprovechar al máximo el set de datos original en el entrenamiento y validación se usó validación cruzada de 2 dobleces. Esta consiste en partir aleatoriamente el set de datos en 2 conjuntos de datos. Un solo conjunto se usa como datos de validación y el restante se emplea para entrenar el clasificador. El proceso de validación cruzada se repite 2 veces. Los 2 resultados de validación son luego promediados para producir una única respuesta. Se emplearon 2 dobleces para establecer un compromiso entre la habilidad de generalización de cada clasificador y la cantidad de datos disponibles, ya que el número de muestras por parámetro no fue muy elevado.

8 ADAPTACIÓN DE UN ALGORITMO DE CLASIFICACIÓN DE FALLAS.

En esta sección se presenta la metodología y los resultados de la aplicación de la función SMO (Sequential Minimal Optimization) de John Platt, adaptada por Michael Mavroforakis (27) con los parámetros propuestos en la sección anterior. La variación de las constantes de penalización C y parámetros del kernel se realizó de forma manual, empleando como indicador de desempeño el número de muestras por fuera de la clase correcta como errores (incluso aquellas muestras en la clase correcta, pero dentro del margen).

El error de entrenamiento consiste en la relación entre el conteo de muestras que quedaron en el lado equivocado del clasificador, durante el entrenamiento, así como aquellas muestras de parámetros que quedaron dentro del margen (no están mal clasificadas, pero están más cerca a la frontera de decisión) con respecto a las muestras totales del entrenamiento.

El error de validación consiste en la relación entre el conteo de muestras que quedaron en el lado equivocado del clasificador, cuando se evalúan los puntos de validación, así como aquellas muestras de parámetros que quedaron dentro del margen (no están mal clasificadas, pero están más cerca a la frontera de decisión) con respecto a las muestras totales de validación.

Las tablas siguientes enseñan los parámetros con los que se obtuvo los mejores resultados en términos del error de clasificación y el de entrenamiento, para cada caso. Los códigos relevantes, correspondientes al entrenamiento y validación de las máquinas biclase pueden ser consultados en el Anexo A.

Los parámetros de entrada que el algoritmo SMO requiere son:

- ✓ Una matriz X^T que contiene los puntos del set de entrenamiento. Cada fila es un punto.

- ✓ El vector de indicadores de clase y^T . Los indicadores para dos clases son 1 y -1. La longitud de este vector coincide con el número de ejemplos de entrenamiento.
- ✓ El tipo de kernel a emplear. En los clasificadores lineales, este parámetro se especifica como 'linear'.
- ✓ El número de pasos permisibles antes de detener la simulación.
- ✓ Tol: es un escalar que controla la precisión de la solución obtenida. Una vez se alcanza esa precisión el algoritmo se detiene, si no ha superado el límite de pasos.

Los parámetros de salida son:

- ✓ alpha: multiplicadores de la grange calculados.
- ✓ b: término de intercepto
- ✓ w: vector normal al plano separador (solo tiene sentido cuando se usa un separador lineal)
- ✓ evals: número de evaluaciones de la norma
- ✓ stp: número de pasos del algoritmo hasta alcanzar la convergencia.

En los clasificadores en los cuales se requiere el uso de alguna función de kernel, ésta debe especificarse, recordando que el papel de las funciones de kernel es mapear los vectores de parámetros en espacios de dimensión superior a la original. El kernel define el producto interno en el espacio de dimensión superior. Esto es importante, ya que todas las operaciones del algoritmo de SVM se pueden expresar en términos de productos punto. Por ello, para lograr resolver el problema de optimización en un espacio de dimensión superior, se evalúan los productos internos como el resultado de las funciones de kernel.

Ejemplos de funciones de kernel (las más populares)

A) Función de Base Radial

$$k(x, y) = \exp\left(-\frac{\|x - y\|^2}{\sigma^2}\right) \quad (28)$$

Donde σ es un parámetro que controla la tasa de decaimiento de la función de kernel hacia cero, a medida que y se aleja de x .

B) Función polinomial

$$k(x, y) = (x^T y + \beta)^n \quad (29)$$

En este kernel se debe especificar dos parámetros, que son el grado del polinomio y la constante de suma.

C) Función sigmoidea


$$k(x, y) = \tanh(x^T y + v) \quad (30)$$

Que se relaciona con las redes neuronales, pero no se ha establecido claramente para qué tipo de problemas de clasificación es adecuado.

En los casos de prueba con requerimiento del uso de funciones de kernel, los mejores resultados (e incluso la única situación en la que se obtuvo convergencia del algoritmo SMO2) se lograron empleando el kernel “Radial BasisFunction” o kernel gaussiano, por lo que éste es al que refiere la mayoría de las tablas de resumen siguientes. En los casos restantes se empleó el algoritmo con un separador lineal.

En la figura 21 se presenta una representación básica en diagrama de flujo de la herramienta empleada para la clasificación de las diferentes fallas.

Figura 21. Diagrama de flujo general para el entrenamiento y validación de las máquinas asociadas a un clasificador de fallas en motores.



Fuente: Autora

Cada uno de los casos descritos en esta sección corresponde a un clasificador biclase, para cada una de las posibilidades explícitas en las tablas de la sección 8.4. Se decidió emplear la metodología uno contra uno, porque un determinado conjunto de parámetros permite una clasificación correcta y dentro de márgenes de error aceptables para cada uno de los casos de clasificación. Por otro lado, no se logró generalizar un clasificador tipo uno contra el resto para el caso de la presente aplicación, ya que no se alcanzó la convergencia o márgenes de error aceptables con la selección de las constantes del clasificador.

Como fue descrito en 7.3, C es una constante de penalización que está relacionada con el margen. Entre mayor sea la constante C , menor será el margen de separación y por lo tanto el error de entrenamiento será menor. Si bien se escoge un valor menor de C , el valor del margen será un poco mayor, lo cual es deseable, porque ello incrementa la capacidad de generalización del clasificador.


8.1 Arquitectura de diagnóstico y cuantificación de la severidad.

Teniendo en cuenta que la cuantificación de la severidad de un tipo de falla, en el caso particular de este trabajo, depende directamente de la detección e identificación de la misma, se propone la arquitectura de máquinas de soporte vectorial que se muestra en la figura 22. Esta arquitectura es consecuente con el hecho de que los parámetros empleados para la clasificación de la severidad de las fallas de corto circuito son distintos a aquellos empleados para la clasificación de la severidad de las fallas de barras rotas.

8.1.1 Clasificador del tipo de falla

Cuenta con tres máquinas de aprendizaje encargadas de clasificar las fallas según las combinaciones de las siguientes clases:

Figura 22. Esquema de la arquitectura de diagnóstico dimensionado para la aplicación de detección de las fallas.



Fuente: Autora

Clase 1: Motor sin falla

Clase 2: Motor con falla de corto circuito

Clase 3: Motor con falla de barras rotas

La entrada de entrenamiento del algoritmo es una matriz de $N \times M$ donde N es el número de dimensiones de la máquina de aprendizaje. M corresponde a los datos de cada parámetro para las tres clases, cada clase entonces está definida por

90 valores de entrenamiento. A continuación se muestran los resultados obtenidos para las tres situaciones predefinidas.

8.1.1.1 Clasificador Motor sin falla – Motor con barras rotas

Este clasificador cuenta con los siguientes 4 parámetros de entrenamiento, como fue establecido previamente.

**(Relación PSC/NSC, Media_tiempo, Frecuencia Central,
Valor_RMS_frecuencia)**


A través de la experimentación se comprobó la pertinencia del uso de los cuatro parámetros para el entrenamiento de una máquina biclase con los parámetros de la tabla 9, con los cuales se obtuvo una respuesta satisfactoria, teniendo como parámetros de desempeño el error de entrenamiento y el error de prueba.

Tabla 9. Respuesta Clasificador Motor sin falla – Motor con barras rotas

C	σ	SV	Error de entrenamiento (%)	Error de prueba (%)
2000	0.08	22	0	0

La respuesta de la máquina se enseña en la figura 23, para las dimensiones que ocupan los parámetros Relación PSC/NSC (absisa) y Media_tiempo (ordenada). En general, para todas las figuras las líneas punteadas encierran los datos donde se acumulan puntos de una determinada clase y representan el margen que ha sido optimizado. También vale la pena establecer que para todas las gráficas los valores de los ejes se encuentran entre cero y uno.

Figura 23. Respuesta de entrenamiento para Clasificador Motor sin falla – Motor con barras rotas



Fuente: Autora

8.1.1.2 Clasificador Motor sin falla – Motor con corto circuito

Este clasificador cuenta con los siguientes 2 parámetros de entrenamiento, como fue establecido previamente.

(Entropía, Relación PSC/NSC)


A través de la experimentación se comprobó la pertinencia del uso de ambos parámetros para el entrenamiento de una máquina biclase con las constantes de la tabla 10, con los cuales se obtuvo una respuesta satisfactoria, teniendo como indicadores de desempeño el error de entrenamiento y el error de prueba.

Tabla 10. Respuesta Clasificador Motor sin falla – Motor con corto circuito

C	σ	SV	Error de entrenamiento (%)	Error de prueba (%)
1000	0.08	13	3.5	14

La respuesta de la máquina se enseña en la figura 24, para las dimensiones que ocupan los parámetros Entropía (absisa) y Relación PSC/NSC (ordenada).

Figura 24. Respuesta de entrenamiento de Clasificador Motor sin falla – Motor con corto circuito



Fuente: Autora

8.1.1.3 Clasificador Motor con corto circuito – Motor con barras rotas

Este clasificador cuenta con los siguientes 4 parámetros de entrenamiento, como fue establecido previamente.

**(Relación PSC/NSC, media_tiempo, frecuencia central,
valor_rms_frecuencia)**


A través de la experimentación se comprobó la pertinencia del uso de todos los parámetros para el entrenamiento de una máquina biclase con las constantes de la tabla 11, con los cuales se obtuvo una respuesta satisfactoria, teniendo como indicadores de desempeño el error de entrenamiento y el error de prueba.

Tabla 11. Respuesta Clasificador Motor con corto circuito – Motor con barras rotas

C	σ	SV	Error de entrenamiento (%)	Error de prueba (%)
2000	0.09	18	0	0

La respuesta de la máquina se enseña en la figura 25, para las dimensiones que ocupan los parámetros Relación PSC/NSC (absisa) y Media_tiempo (ordenada).

Figura 25. Respuesta Clasificador Motor con corto circuito – Motor con barras rotas



Fuente: Autora

Para aumentar la capacidad de generalización de los clasificadores, debe incrementarse el valor del parámetro Lamda, pero ello puede elevar el error de entrenamiento y de prueba, por lo que debe establecerse un compromiso entre un error permisible y clases con rangos más amplios para clasificación.

8.1.2 Clasificador de severidad para fallas de corto circuito.

Consiste en tres máquinas de aprendizaje encargadas de clasificar las fallas según las siguientes clases:

Clase 1: Motor con 2% de espiras cortocircuitadas en una fase

Clase 2: Motor con 5% de espiras cortocircuitadas en una fase

Clase 3: Motor con 10% de espiras cortocircuitadas en una fase

Este clasificador tiene dos parámetros, o dos dimensiones, para todos los clasificadores biclase:

(Relación PSC/NSC,valor_RMS_frecuencia)

La entrada de entrenamiento es una matriz de NXM donde N es el número de dimensiones, que en este caso es 2. M corresponde a los datos de cada parámetro para las tres clases, cada clase entonces está definida por 90 valores. Se tienen entonces 30 valores de entrenamiento para cada par de clases.

8.1.2.1 Clasificador Motor con falla de corto de 2%- Motor con falla de corto de 5%


En la tabla 12 se resume el valor de las constantes de entrenamiento con los que la máquina obtuvo un resultado satisfactorio en términos del error de entrenamiento y validación.

La respuesta de la máquina se enseña en la figura 26, para las dimensiones que ocupan los parámetros Relación PSC/NSC (absisa) y valor_RMS_frecuencia (ordenada).

Tabla 12. Respuesta Clasificador Motor con falla de corto de 2%- Motor con falla de corto de 5%

C	σ	SV	Error de entrenamiento (%)	Error de prueba (%)
5000	0.09	5	8	10

Figura 26. Respuesta de entrenamiento Clasificador Motor con falla de corto de 2%- Motor con falla de corto de 5%



Fuente: Autora

8.1.2.2. Clasificador Motor con falla de corto de 5%- Motor con falla de corto de 10%


En la tabla 13 se resume el valor de las constantes de entrenamiento con los que la máquina obtuvo un resultado satisfactorio en términos del error de entrenamiento y validación. Esta máquina es lineal, por lo que el producto punto no requiere una definición diferente a la usual.

Tabla 13. Respuesta clasificador Motor con falla de corto de 2%- Motor con falla de corto de 10%

C	SV	Error de entrenamiento (%)	Error de prueba (%)
2000	2	0	0

La respuesta de la máquina se enseña en la figura 27, para las dimensiones que ocupan los parámetros Relación PSC/NSC (absisa) y valor_RMS_frecuencia (ordenada).

Figura 27. Respuesta de entrenamiento clasificador Motor con falla de corto de 5%- Motor con falla de corto de 10%



8.1.2.2 Clasificador Motor con falla de corto de 2%- Motor con falla de corto de 10%

En la tabla 14 se resume el valor de las constantes de entrenamiento con los que la máquina obtuvo un resultado satisfactorio en términos del error de entrenamiento y


validación. Esta máquina es lineal, por lo que el producto punto no requiere una definición diferente a la usual.

Tabla 14. Respuesta clasificador Motor con falla de corto de 2%- Motor con falla de corto de 10%

C	SV	Error de entrenamiento (%)	Error de prueba (%)
2000	2	0	0

La respuesta de la máquina se enseña en la figura 28, para las dimensiones que ocupan los parámetros Relación PSC/NSC (absisa) y valor_RMS_frecuencia (ordenada).

Figura 28. Respuesta clasificador Motor con falla de corto de 2%- Motor con falla de corto de 10%



Fuente: Autora

8.1.3 Clasificador de severidad para fallas de barras rotas.

Es la máquina de aprendizaje encargada de clasificar las fallas según las siguientes clases:

Clase 1: Motor 1 barra rota

Clase 2: Motor con 2 barras rotas

Clase 3: Motor con 3 barras rotas

La entrada de entrenamiento es una matriz de $N \times M$ donde N es el número de dimensiones, que en cada máquina es distinto. M corresponde a los datos de cada parámetro para las tres clases, cada clase entonces está definida por 90 valores. Se tienen entonces 30 valores de entrenamiento.

8.1.3.1 Clasificador Motor con una barra rota- Motor con dos barras rotas

Este clasificador tiene dos parámetros, o dos dimensiones:

(Media_tiempo, Factor de Cresta)


En la tabla 15 se resume el valor de las constantes de entrenamiento con los que la máquina obtuvo un resultado satisfactorio en términos del error de entrenamiento y validación.

Tabla 15. Respuesta clasificador Motor con una barra rota- Motor con dos barras rotas

C	σ	SV	Error de entrenamiento (%)	Error de prueba (%)
5	0.01	10	19,7%	19.7%

La respuesta de la máquina se enseña en la figura 29, para las dimensiones que ocupan los parámetros Relación Media_tiempo (absisa) y factor de cresta (ordenada).

Figura 29. Respuesta de entrenamiento clasificador Motor con una barra rota- Motor con dos barras rotas



Fue

nte: Autora

8.1.3.2 Clasificador Motor con dos barras rotas- Motor con tres barras rotas

Este clasificador tiene dos parámetros, o dos dimensiones:

(Media_tiempo, Factor de Cresta)


En la tabla 16 se resume el valor de las constantes de entrenamiento con los que la máquina obtuvo un resultado satisfactorio en términos del error de entrenamiento y validación.

Tabla 16. Respuesta clasificador Motor con dos barras rotas- Motor con tres barras rotas

C	σ	SV	Error de entrenamiento (%)	Error de prueba (%)
5	0.01	7	0	0

La respuesta de la máquina se enseña en la figura 30, para las dimensiones que ocupan los parámetros media_tiempo (absisa) y factor de cresta (ordenada).

Figura 30. Respuesta de entrenamiento de clasificador Motor con dos barras rotas- Motor con tres barras rotas



Fuente:Autora

8.1.3.3 Clasificador Motor con una barra rota- Motor con tres barras rotas

Esta máquina tiene cuatro parámetros, o cuatro dimensiones:

(Entropía, Relación PSC/NSC, Media_tiempo, Factor de Cresta)


En la tabla 17 se resume el valor de las constantes de entrenamiento con los que la máquina obtuvo un resultado satisfactorio en términos del error de entrenamiento y validación.

Tabla 17. Respuesta Motor con una barra rota- Motor con tres barras rotas

C	σ	SV	Error de entrenamiento (%)	Error de prueba (%)
2000	0.1	5	0	0

La respuesta de la máquina se enseña en la figura 31, para las dimensiones que ocupan los parámetros Entropía (absisa) y Relación PSC/NSC (ordenada).

Figura 31. Respuesta de entrenamiento de Motor con una barra rota- Motor con tres barras rotas



Fuente: Autora

Con referencia a la arquitectura planteada en la sección 9.3, la tabla 18 resume las salidas de los diferentes clasificadores, para 7 entradas diferentes. Esta arquitectura implica que cada clasificador (clasificador tipo de falla, clasificador

severidad de falla de corto circuito, clasificador de severidad de falla de barras rotas), consta de tres máquinas para las cuales las entradas fueron comunes. Para las pruebas se alimentó de forma manual los parámetros y se obtuvo la respuesta de cada máquina en forma individual. Las siete entradas de prueba se tomaron con 50% de los datos disponibles de cada situación (randómicos).

Los rótulos de la tabla 18 corresponden a:

M1: máquina sin falla- falla corto circuito

M2: máquina sin falla- barras rotas

M3: máquina barras rotas-corto circuito

M4: máquina corto circuito 2%-corto circuito 5%

M5: máquina corto circuito 2%-corto circuito 10%

M6: máquina corto circuito 5%-corto circuito 10%

M7: máquina 1 barra rota – 2 barras rotas

M8: máquina 1 barra rota – 3 barras rotas

M9: máquina 2 barras rota – 3 barras rotas

NA: No Aplica

Tabla 18. Resultados prueba en cascada de la arquitectura de clasificación propuesta.

Clase predicha	SF	CC2%	CC5%	CC10%	BR1	BR2	BR3
M1	SF	NA	NA	NA	NA	NA	NA
M2	SF	NA	NA	NA	NA	NA	NA
M3	CC	NA	NA	NA	NA	NA	NA
M4	NA	CC2%	CC5%	CC2%	NA	NA	NA
M5	NA	CC2%	CC2%	CC10%	NA	NA	NA
M6	NA	CC10%	CC5%	CC10%	NA	NA	NA
M7	NA	NA	NA	NA	BR1	BR2	BR1
M8	NA	NA	NA	NA	BR1	BR1	BR3
M9	NA	NA	NA	NA	BR3	BR2	BR3

9 CONCLUSIONES

- Se adaptó un algoritmo de clasificación y detección de fallas en un motor de inducción basado en máquinas de soporte vectorial usando la información transportada por la señal de corriente del estator.
- Se realizó la detección y análisis de las fallas offline en un motor de inducción 3 ϕ y 2 hp correspondientes a: Corto circuito en el devanado del estator y barras rotas en el rotor para caracterizar la severidad de la falla (incipiente, moderada y severa).
- Se validó experimentalmente el algoritmo propuesto, usando un banco de pruebas dedicado para este tipo de ensayos en distintos escenarios de carga (sin carga, 75% y 85% de la corriente nominal) y severidad de falla (2%,5% y 10% de espiras cortocircuitadas en una fase para la falla de cortocircuito y 1,2 y 3 barras rotas).
- Se estudió un conjunto de parámetros relacionados con fallas en motores eléctricos y se estableció la conveniencia del uso de cada uno de ellos en términos de la separabilidad que ofrecen para cada clase.
- La adición de carga al motor desvanece las componentes de frecuencia relacionadas con la falla de corto circuito, por lo que no fue posible emplear los parámetros frecuencia central y root variance para clasificar estas fallas.
- Se probaron y evaluaron los parámetros usuales propuestos por la técnica MCSA para la detección de fallas en motores y se estableció la conveniencia de estos en los esquemas de mantenimiento basado en la condición.

10 APORTES

- Se investigó acerca de los parámetros empleados en la detección de fallas en motores de inducción, se probó su desempeño en una situación real y se propuso el uso del parámetro de relación PSC/NSC (componente de secuencia positiva/ componente de secuencia negativa), que tuvo el mejor desempeño entre los parámetros.
- Se adaptó un algoritmo de máquinas de soporte vectorial a una aplicación en mantenimiento basado en la condición para motores de inducción. Se encontraron resultados satisfactorios que permiten diferenciar las fallas en distintas condiciones de severidad y carga del motor.
- Se generaron tres artículos relacionados con la evaluación metodología MCSA:
 - ✓ Oviedo, S., Quiroga J., Borrás, C. *Experimental Evaluation of MCSA and Vibration Analysis for Rotor Broken Bars Detection in an Induction Motor*". Aceptado. III IEEE International Conference on Power Engineering, Energy and Electrical Drives, Powereng 2011.
 - ✓ Oviedo, S., Quiroga J., Borrás, C. *Motor Current Signature Analysis and Negative Sequence Current based short Fault Detection of an Induction Motor Stator Winding* " Aceptado. Revista DYNA.
 - ✓ Oviedo, S., Quiroga J., Ordóñez, G. *Validación Experimental de la Metodología Motor Current Signature. Analysis para un Motor de Inducción de 2 HP.*
- Se generaron los siguientes proyectos de pregrado, relacionados con la técnica MCSA y la detección de fallas en motores de inducción:
 - ✓ *Detección de Fallas en un Motor de Inducción Usando MCSA (Motor Current Signature Analysis).* Aldo Fernando Rico Maestre, Miguel Ángel Tristancho Caballero ; Director Gabriel Ordoñez Plata. Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones.

- ✓ *Detección de Fallas en un Motor de Inducción Usando Análisis De Vibraciones Mecánicas Bajo Distintos Escenarios De Carga. Helmer Omar Carvajal Suarez, Iván Fernando Estupiñán López. Director: Jabid Quiroga Méndez. Escuela de Ingeniería Mecánica.*

11 RECOMENDACIONES Y TRABAJOS FUTUROS

- Aumentar la capacidad de generalización de los clasificadores mediante el uso de más ejemplos de entrenamiento para cada caso.
- Explorar y proponer otros parámetros en el dominio de la frecuencia que representen la técnica MCSA, ya que en este estudio los parámetros en el dominio de la frecuencia resultaron ser muy débiles para lograr la distinción de las diferentes condiciones de falla.
- Ampliar el estudio presentado en este trabajo a otras fallas relevantes en los motores de inducción, como fallas en rodamientos y excentricidad del entrehierro.

12 BIBLIOGRAFÍA

- [1] JUNG, Jee-Hoon, LEE, Jong-Jae and KWON, Bong-Hwan. Online Diagnosis of Induction Motors Using MCSA, En: Industrial Electronics, IEEE Transactions on, Dec. 2006, vol.53, No. 6, p.1842-1852.
- [2] RODRIGUEZ, I. Bearing Damage Detection of the Induction Motors using Current Analysis. En: R. Transmission & Distribution Conference and Exposition: Latin America, Agosto, 2006, p. 1 - 5.
- [3] PEREIRA, L.A. and DA SILVA GAZZANA, D. Motor current signature analysis and fuzzy logic applied to the diagnosis of short-circuit faults in induction motors. En: Industrial Electronics Society, IECON 2005. 31st Annual Conference of IEEE. 6-10 Nov. 2005. p. 6
- [4] BRUZZESE, C., HONORATI, O. and SANTINI, E. Spectral analyses of directly measured stator and rotor currents for induction motor bar breakages characterization by M.C.S.A. En: Power Electronics, Electrical Drives, Automation and Motion, SPEEDAM 2006. International Symposium on, Issue 23.
- [5] NOUREDDINE ,O.L. and IBTIOUEN, R. Spectral analysis for the rotor defects diagnosis of an induction machine. En: Intelligent Signal Processing, 2005 IEEE International Workshop on. Sept, 2005. p.183 – 187.
- [6] THOMSON, W.T. and FENGER, M. Case histories of current signature analysis to detect faults in induction motor drives. En: Electric Machines and Drives Conference, 2003. IEMDC'03. IEEE International. June, 2003. Vol. 3 p. 1459 – 1465.
- [7] BELLINI, A., et al. On-field experience with online diagnosis of large induction motors cage failures using MCSA. En: Industry Applications, IEEE Transactions on, Jul/Aug 2002, vol 38, No 4, p. 1045 – 1053 .
- [8] BELLINI, A., et al. Mechanical failures detection by means of induction machine current analysis: a case history. En: Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED 2003. 4th IEEE International Symposium on. Aug., 2003 p. 322-326.
- [9] GAO, X.Z., OVASKA, S.J. and DOTE, Y. Motor fault detection using Elman neural network with genetic algorithm-aided training, Systems, Man, and Cybernetics, 2000 IEEE International Conference on , vol.4, p.2386-2392.

- [10] XUHONG, Wang and YIGANG, He. Diagonal recurrent neural network based on-line stator winding turn fault detection for induction motors. En: Electrical Machines and Systems, 2005. ICEMS 2005. Proceedings of the Eighth International Conference on , vol.3, pp. 2266- 2269..
- [11] H.BOLLEN, M. and GU, I. En: Signal Processing of Power Quality Disturbances, IEEE Press Series on Power Engineering, 2006. p.861.
- [12] WILLIAMSON, S. and MIRZOIAN, K. Analysis of cage induction motors with stator windings faults, IEEE Trans. En: Power App. Syst., July 1985, vol. 104, No. 7, p. 1832-1842.
- [13] HAN, Tian, YANG, Bo-Suk and LEE, Jong Moon. A new condition monitoring and fault diagnosis system of induction motors using artificial intelligence algorithms. En: Electric Machines and Drives, 2005 IEEE International Conference on ,15 May 2005, p.1967-1974.
- [14] PONCELAS, O., et al.Design and application of Rogowski coil current sensor without integrator for fault detection in induction motors. En: Industrial Electronics, 2008. ISIE 2008. IEEE International Symposium on. July, 2008. p.558 – 563.
- [15] THOMSON, W.T. and FENGER, M.Current signature analysis to detect induction motor faults, En: Industry Applications Magazine, vol.7, No.4, Jul/Aug 2001. p. 26-34.
- [16] AYHAN, B., et al. On the Use of a Lower Sampling Rate for Broken Rotor Bar Detection With DTFT and AR-Based Spectrum Methods. En: Industrial Electronics, IEEE Transactions on. March 2008 vol 55, No. 3, p. 1421 - 1434.
- [17] TEOTRAKOOL, K., DEVANEY, M.J. and Eren, L. Adjustable Speed Drive Bearing Fault Detection via Wavelet Packet Decomposition. En: Instrumentation and Measurement Technology Conference, 2006. IMTC 2006. Proceedings of the IEEE. 24-27 April 2006 p. 22 – 25.
- [18] EL HACHEMI BENBOUZID, M.A review of induction motors signature analysis as a medium for faults detection. En: Industrial Electronics, IEEE Transactions on, Oct, 2000. Volume 47, No 5, p. 984 – 993.
- [19] BELLINI, A., et al.Thorough Understanding and Experimental Validation of Current Sideband Components in Induction Machines Rotor Monitoring.IEEE Industrial Electronics, IECON 2006 - 32nd Annual Conference on. Oct, 2000. p.4957 – 4962

- [20] BOCCALETTI, C., et al. Rotor bars breakage in railway traction squirrel cage induction motors and diagnosis by MCSA technique Part II : Theoretical arrangements for fault-related current sidebands. En: Diagnostics for Electric Machines, Power Electronics and Drives. SDEMPED 2. Sept, 2005. p. 1-6.
- [21] THOMSON, W.T. On-line current monitoring to detect electrical and mechanical faults in three-phase induction motor drives. En: Life Management of Power Plants, 1994, International Conference on, Dec 1994, p. 66-73.
- [22] AWADALLAH, M.A. and MORCOS, M. ANFIS-based diagnosis and location of stator interturn faults in PM brushless DC motors, En: IEEE Trans. Energy Conversion, 2004. vol. 19, No. 4, p. 795–796.
- [23] NG, Andrew. CS229 Lecture notes. Part IV. Stanford University. Disponible en: <http://www.stanford.edu/class/cs229/materials.html>. Consultado el 30 de Noviembre de 2010.
- [24] SCHOLKOPF, B. and J., SMOLA A. Learning with Kernels. MIT Press. Cambridge, Massachusetts, 2002.
- [25] MORA, J., MORALES, G. and PÉREZ, S. Classification methodology and feature selection to assist fault location in power distribution systems. En: Revista. Fac. Ingenierías. Universidad de. Antioquia, Junio, 2008 N° 44. p. 83-96.
- [26] GHATE, Vilas N., DUDUL, Sanjay V. Fault Diagnosis of Three Phase Induction Motor Using Neural Network Techniques. En: Second International Conference on Emerging Trends in Engineering & Technology, 2009. p: 922 – 928.
- [27] THEODORIDIS, S., et al. Introduction to Pattern Recognition. A Matlab Approach. 4 ed. Elsevier, Academic Press, 2010. p. 107-122.
- [28] PENROSE, Howard. APPLICATIONS FOR MOTOR CURRENT. s.l. : ALL-TEST Pro White Paper, 2004.
- [29] THEODORIDIS, S. and Koutroumbas, K. Pattern Recognition. 4 Ed. Elsevier, 2009. p. 412-414.
- [30] GHATE, V.N. DUDUL, S.V. Cascade Neural-Network-Based Fault Classifier for Three-Phase Induction Motor. En: Industrial Electronics, IEEE Transactions on. May 2011. Vol 58. p 1555 - 1563 .
- [31] DERAEMAERKER, A. et al. Vibration based SHM: comparison of the performance of modal features vs features extracted from spatial filters under

changing environmental conditions. En: ISMA2006 International Conference on Noise and Vibration Engineering. September, 2006. p 849-864 .

[32] GORDI, M., ROSHANFERK, R.A New Approach for Fault Detection of Broken Rotor Bars in Induction Motor Based on Support Vector Machine. En: Electrical Engineering (ICEE) 18th Iranian Conference on. 11-13 May 2010 p. 732 - 738 .

[33] DAS, S. KOLEY, C. PURKAIT, P. CHAKRAVORTI, S.Wavelet aided SVM classifier for stator inter-turn fault monitoring in induction motors. En: Power and Energy Society General Meeting, July 2010. p 1-6.

[34] ACHMAD Widodo, BO-SUK Yang , TIAN Han.Combination of independent component analysis and support vector machines for intelligent faults diagnosis of induction motor. En: Expert Systems, Junio, 2008, vol 32, p 299-312.

[35] OVIEDO, S., QUIROGA J., BORRÁS, C. Experimental Evaluation of MCSA and Vibration Analysis for Rotor Broken Bars Detection in an Induction Motor”. En: III IEEE International Conference on Power Engineering, Energy and Electrical Drives, Powereng 2011.

[36] OVIEDO, S., QUIROGA J., BORRÁS, C.Motor Current Signature Analysis and Negative Sequence Current based short Fault Detection of an Induction Motor Stator Winding ” Aceptado. Revista DYNA.

Anexo A. Código de entrenamiento y Validación de Máquinas Biclase.

En este anexo se muestran los códigos empleados para el entrenamiento de las máquinas de soporte vectorial, así como el procedimiento general de entrenamiento y prueba de las máquinas en forma de código.

El algoritmo propuesto por Michael Mavroforakis es una versión disponible en forma gratuita, del algoritmo SMO, propuesto por Platt, inicialmente. A continuación se muestra el código de entrenamiento y prueba de una máquina de clasificación del tipo de falla, particularmente aquella que diferencia entre la condición de corto circuito y la condición sin falla. La función `svcplot_book` es provista en [27] y es la que representa en forma gráfica el clasificador.

```
clear
clc
load10paramodificado.mat
%% set de entrenamiento
dim1=matriz_relacion_n(1:90);      % subset perteneciente a la
clase 1)
dim11=matriz_relacion_n(91:180)'; % subset perteneciente a la
clase 2)
dimuno=[dim1',dim11]; % este vector tiene 180 posiciones con
los datos de las dos clases en serie
dimuno=dimuno';

dim2=valor_rms_f_n(1:90);      % subset perteneciente a la
clase 1
dim22=valor_rms_f_n(91:180); % subset perteneciente a la
clase 2)
dimdos=[dim2;dim22]; % este vector tiene 180 posiciones con
los datos de las dos clases en serie para la dimensión 2

X=[dimuno, dimdos]; %Matriz X de entrada, cada fila es una
dimensión. Cada columna es un punto.
X=X';
```

```

y=[ones(1,90) -ones(1,90)]; %vector que indica qué clase es
cada ejemplo. Los labels son 1 y -1

[TRAIN,TEST] = crossvalind('HoldOut',180); % distribuye 90
datos de forma aleatoria para entrenamiento
%y 90 para prueba (X2)

X1=X(:,TRAIN);
X2=X(:,TEST);
y1=y(TRAIN);
y2=y(TEST);

%% máquina de soporte vectorial

kernel='rbf'; % especificación de la función de kernel
kpar1=0.09; %lamnda
kpar2=0;

% especificación de parámetros
C=1000;
tol=0.0001;
steps=100000;
eps=10^(-10);
method=1;

%entrenamiento de la máquina con 50% de los datos asignados a
X1
[alpha, w0, w, evals, stp, glob] = SMO2(X1', y1', kernel,
kpar1, kpar2, C,tol, steps, eps, method);
sup_vec=sum(alpha>0);% solo los
%entrenamiento de la máquina con 50% de los datos asignados
en forma aleatoria a X2
[alpha2, w02, w2, evals2, stp2, glob2] = SMO2(X2', y2',
kernel, kpar1, kpar2, C,tol, steps, eps, method);
    marg2=2/sqrt(sum(w2.^2));
    sup_vec2=sum(alpha2>0);

sup_vec
sup_vec2
%% cálculo de errores de entrenamiento y validación
X_sup=X1(:,alpha'~=0);
alpha_sup=alpha(alpha'~=0)';%multiplicadores de L.
y_sup=y1(alpha'~=0);%clase asignada

```

```

for i=1:max(size(X1))
t=sum((alpha_sup.*y_sup).*CalcKernel(X_sup',X1(:,i)',kernel,k
par1,kpar2))-w0;
if(t>0)
out_train(i)=1;% outtarin es el vector que dice la clase en
la que quedó cada muestra.
else
out_train(i)=-1;
end
end
% cómputo del error
Pel=sum(out_train.*y1<0)/length(y1)% se compara la clase con
la que quedó cada muestra, con la real.

% error de clasificación
X_sup2=X2(:,alpha'~=0);
alpha_sup2=alpha(alpha~=0)';
y_sup2=y2(alpha~=0);

for i=1:max(size(X2))
t=sum((alpha_sup2.*y_sup2).*CalcKernel(X_sup2',X2(:,i)',kerne
l,kpar1,kpar2))-w0;
if(t>0)
out_train(i)=1;
else
out_train(i)=-1;
end
end
Error_clasif=sum(out_train.*y2<0)/length(y2)

% errores con X2 como datos de entrenamietno y X1 como de
validacion
X_supv=X1(:,alpha2'~=0);
alpha_supv=alpha2(alpha2~=0)';
y_supv=y2(alpha2~=0);

for i=1:max(size(X2))
t=sum((alpha_supv.*y_supv).*CalcKernel(X_supv',X2(:,i)',kerne
l,kpar1,kpar2))-w02;
if(t>0)
out_train(i)=1;
else
out_train(i)=-1;
end
end
end

```

```

Pelv=sum(out_train.*y2<0)/length(y2)

% error de clasificación
X_sup2v=X2(:,alpha2'~=0);
alpha_sup2v=alpha2(alpha2~=0)';
y_sup2v=y1(alpha2~=0);

for i=1:max(size(X1))
t=sum((alpha_sup2v.*y_sup2v).*CalcKernel(X_sup2v',X1(:,i)',kernel,kpar1,kpar2))-w02;
if(t>0)
out_train(i)=1;
else
out_train(i)=-1;
end
end
Error_clasifv=sum(out_train.*y1<0)/length(y1)
%% gráfica del clasificador
global figt4
figt4=2;
svcplot_book(X1',y1',kernel,kpar1,kpar2,alpha,-w0)

```

A continuación se muestra el código de entrenamiento y prueba de una máquina de clasificación de severidad de la falla, particularmente aquella que diferencia entre la condición de corto circuito y la condición sin falla, la cual no requirió el uso de una función de kernel.

```

clear
clc
load10paramodificado.mat
%% set de entrenamiento
dim1=matriz_relacion_n(91:120); % subset perteneciente a la clase 1)
dim11=matriz_relacion_n(151:180)'; % subset perteneciente a la clase 2)
dimuno=[dim1',dim11]; % este vector tiene 90 posiciones con los datos de las tres clases
dimuno=dimuno';

dim2=valor_rms_f_n(91:120); % subset perteneciente a la clase 1)

```

```

dim22=valor_rms_f_n(151:180); % subset perteneciente a la
clase 2)
dimdos=[dim2;dim22];

X=[dimuno, dimdos];
X=X';

y=[ones(1,30) -ones(1,30)];

[TRAIN,TEST] = crossvalind('HoldOut',60);

X1=X(:,TRAIN);
X2=X(:,TEST);
y1=y(TRAIN);
y2=y(TEST);

%% máquina de soporte vectorial
%
kernel='linear';
kpar1=0;
kpar2=0;

C=2000;
tol=0.001;
steps=100000;
eps=10^(-10);
method=1;

[alpha, w0, w, evals, stp, glob] = SMO2(X1', y1', kernel,
kpar1, kpar2, C,tol, steps, eps, method);
marg=2/sqrt(sum(w2.^2));
sup_vec=sum(alpha>0);

[alpha2, w02, w2, evals2, stp2, glob2] = SMO2(X2', y2',
kernel, kpar1, kpar2, C,tol, steps, eps, method);
marg2=2/sqrt(sum(w2.^2));
sup_vec2=sum(alpha2>0);

sup_vec
sup_vec2
%% cálculo de errores

% error de entrenamiento conX1
Pe_tr=sum((2*(w*X1-w0>0)-1).*y1<0)/length(y1)

```

```

% error de prueba
Pe_te=sum((2*(w*X2-w0>0)-1).*y2<0)/length(y2)

%con X2 como entrenador y X1 como validación
Pe_tr=sum((2*(w*X2-w0>0)-1).*y2<0)/length(y2)

Pe_te=sum((2*(w*X1-w0>0)-1).*y1<0)/length(y1)

%% gráfica del clasificador
global figt4
figt4=2;
svcplot_book(X1',y1',kernel,kpar1,kpar2,alpha,-w0)

```