



**UNIVERSIDAD DE CARABOBO
FACULTAD DE INGENIERIA
AREA DE ESTUDIOS DE POSTGRADO
MAESTRIA EN INGENIERIA ELECTRICA**



**DESARROLLO DE UN CLASIFICADOR BINARIO PARA
DETERMINAR EL ESTADO DE FUNCIONAMIENTO DE LOS
MOTORES DE INDUCCION UTILIZANDO TRANSFORMADA
DE WAVELET Y MAQUINAS DE VECTORES DE SOPORTE**

Ing. Elimar Hernández Vilar

Trabajo de Grado

Presentado ante la ilustre Universidad de Carabobo
Para optar al título de: Magíster en Ingeniería Eléctrica

Valencia, 01 de julio del 2014

UNIVERSIDAD DE CARABOBO
FACULTAD DE INGENIERIA
AREA DE ESTUDIOS DE POSTGRADO
MAESTRIA EN INGENIERIA ELECTRICA

Aplicación de la Transformada de Wavelet y Maquinas de Vectores de Soporte para identificar el estado de funcionamiento de los motores

Autor: Elimar Hernández

Tutor: Carlos Jiménez

Resumen. En el presente trabajo se presenta una herramienta para identificar el estado de funcionamiento de los motores, a partir del análisis de sus variables eléctricas utilizando la Transformada de Wavelet y las Maquinas de Vectores de Soportes. Se utilizó la Transformada de Wavelet para la obtención de rasgos o características que representaran indicadores del estado del motor. Luego estos rasgos se aplicaron a la máquina de vectores de soporte para clasificar y realizar la identificación del estado del motor.

Las variables eléctricas consideradas fueron la corriente estatorica y el flujo de la maquina las cuales fueron obtenidas a través de un sistema de adquisición de datos donde se tomaron muestras de ambas señales a razón de 1024 puntos en un periodo de la onda. Las mediciones se realizaron para dos condiciones de funcionamiento del motor: Motor operando a plena carga y motor operando a 5/7 de su plena carga. Inicialmente se realizó la medición de las señales para los motores en condiciones óptimas de los rodamientos y posteriormente se realizó la medición para las condiciones de fallas en los rodamientos.

Para definir el clasificador más óptimo se realizaron diferentes ensayos considerando variaciones en los parámetros de la Transformada de Wavelet y de la Máquina de Vectores de Soporte. En el caso de la MVS se modificó su función Kernel, considerando Función de base radial, polinomial y Gaussiana y sus parámetros de sintonía C y γ , por otro lado, para la TW se varió la Wavelet Madre empleando la Haar, Daubechies, Coiflets y Symlets y cada una se analizó para diferentes niveles de descomposición. Se calcularon los momentos de los coeficientes de detalle y aproximación obtenidos con la aplicación de la TW y de ellos se seleccionaron dos, los cuales constituirían la información de entrada a la MVS; con esto se logró disminuir el tamaño de la data y facilitar la identificación y separación de las clases.

Los parámetros del modelo que arrojaron mayor porcentaje de acierto fueron: Wavelet madre la db5, coeficientes de aproximación 1, momentos de orden 12 y 20, función kernel 'rbf' y como señal eléctrica la corriente estatorica. El modelo

desarrollado presento una capacidad de predicción mayor del 96% de acierto. Durante los ensayos se entrenó con los datos asociados a un motor y la predicción con los datos pertenecientes a otro motor, así mismo se entrenó y probó con los datos de un mismo motor pero que no intervinieron en la etapa de entrenamiento. Los resultados obtenidos en la presente investigación permiten asegurar que son un método efectivo y exitoso para predecir la condición de funcionamiento de los motores eléctricos y resulta una herramienta valiosa para fundamentar programas de mantenimiento de tipo preventivo y predictivo.

Palabras Claves: Motor, Wavelet, Máquinas de Vectores de Soporte, predicción.

Application of the Wavelet Transform and Support Vector Machine to identify the state of the motor's functioning

Engineering school, University of Carabobo, Valencia- Venezuela .

Abstract. This work points out a tool to identify the state of the working capability of motors, starting from the analysis of its electric variables using the Wavelet Transform (TW) and the Support Vector Machine. The Wavelet Transform (MVS) was used to get the features and characteristics that indicates the state of the motor, then these features were applied to the Support Vector Machine to classify and identify the condition of the motor. The electric variables used for this work were the stator's current and the machine's flow taken from an acquisition data system in which data from both signals were collected at the rate of 1024 points in a period of the wave. The measurements were used to test two conditions of the motor's functioning: Motor working to its entire charge and motor working to a 5/7 of its entire charge. The measurement of the signs for the motor's treads which were in great condition was done first and after this, the measurement of the signs for the treads that were failing was done. To define the most appropriate classifier, two tryouts were mad considering the variations of the parameters of the Wavelet Transform and the Support Vector Machine. In the case of the MVS its function, Kernel was modified considering the function base radial, polynomial and Gaussian and its parameters of tuning C and γ , on the other hand, for the TW, the wavelet mother was changed by using the Haar, Daubechies, Coiflets and Symlets and each one was studied for different decomposition levels. The moments of the quotient of detail and approximation taken from the use of the TW were calculated and two of them were selected. These two became the entering information to the MVS; with this, the data size was shortened and made easier the identification and separation of the classes. The parameters of the Wavelet mother the db5 claimed to be the most precise ones with quotient of approximation 1, moments of order 12 and 20, Kernel function "rbf" and as electrical signal the stator's current. The model developed showed a capacity to predict more than 96% of accuracy. During the tryouts data associated to a motor was used and the prediction was achieved with data corresponding to another motor likewise the model was tested and proved with data form the same motor differently from the ones used in the tryouts. The results of this study assures that this model is a successful and effective method to predict the condition of the electrical motor's functioning and it is a valuable tool to establish programs of predictive and preventive maintenance

Key Words: Machines, predictive, motor, electric, Wavelet

INDICE

INTRODUCCIÓN	1
CAPITULO I	3
EL Planteamiento del problema	3
1.1 Objetivos	6
1.2.1 Objetivo General	6
1.2.1 Objetivos específicos	6
1.3 Justificación	7
1.4 Alcance y delimitación	8
CAPITULO II	9
2.1 Antecedentes de la investigación	9
2.2 Marco Teórico	11
2.2.1 Motores de Inducción	11
2.2.2 Maquina de Vectores de Soporte	17
2.2.3 Transformada de Wavelet	26
CAPITULO III	39
MARCO METODOLÓGICO	39
3.1 Nivel y tipo de Investigación	39
3.2 Procedimiento Metodológico	40
3.3 Técnicas e Instrumentos de recolección de datos	42
3.4 Técnicas de procesamiento y análisis de datos	43
CAPITULO IV	44
DISEÑO DEL CLASIFICADOR BINARIO PARA DETECTAR EL ESTADODE FUNCIONAMIENTO DE LOS MOTORES DE INDUCCION	44
4.1 Selección de la data para realizar los ensayos	45
4.1.1. Esquema de montaje del banco de mediciones de las corrientes y voltajes de los motores de inducción	46

4.1.2 Fallas introducidas en los motores de inducción	47
4.1.3 Condiciones de operación de los motores de inducción	48
4.1.4 Obtención de las señales de los motores de inducción en condiciones de falla y en buen estado:	48
4.2. Aplicación de la transformada de Wavelet y la máquina de vectores de soporte a la data seleccionada.	49
4.2.1 Proceso de experimentación.	49
4.3. Parámetros de evaluación del clasificador	54
CAPITULO V	56
ANALISIS E INTERPRETACIÓN DE LOS RESULTADOS	56
-Ensayo I: Entrenamiento con los datos del motor a y prueba con los datos del motor b, condición de carga igual a 5A.	61
-Ensayo II: Entrenamiento con los datos del motor B y prueba con los datos del motor A, condición de carga igual a 5A.	61
-Ensayo III: Entrenamiento y prueba con los datos del motor A, con condición de carga igual a 5A.	62
-Ensayo IV: Entrenamiento y prueba con los datos del motor B, con condición de carga igual a 5A.	62
-Ensayo V: Entrenamiento con los datos del motor A y prueba con los datos del motor B, para corriente nominal.	63
-Ensayo VI: Entrenamiento con los datos del motor B y prueba con los datos del motor A, para corriente nominal.	63
-Ensayo VII: Entrenamiento y prueba con los datos del motor A, para corriente nominal.	64
-Ensayo VIII: Entrenamiento y prueba con los datos del motor B,	

para corriente nominal.	64
-Ensayo I (sin TW): entrenamiento con los datos del motor A y prueba con los datos del motor B, condición de carga igual a 5A.	65
-Ensayo II (sin TW): entrenamiento con los datos del motor B y prueba con los datos del motor A, condición de carga igual a 5A.	65
-Ensayo III (sin TW): entrenamiento y prueba con los datos del motor A, con condición de carga igual a 5A.	66
-Ensayo IV (sin TW): entrenamiento y prueba con los datos del motor B, con condición de carga igual a 5A.	67
-Ensayo V (sin TW): entrenamiento con los datos del motor A y prueba con los datos del motor B, para corriente nominal	67
-Ensayo VI (sin TW): entrenamiento con los datos del motor B y prueba con los datos del motor A, para corriente nominal	68
-Ensayo VII (sin TW): entrenamiento y prueba con los datos del motor A, para corriente nominal.	69
-Ensayo VIII (sin TW): entrenamiento y prueba con los datos del motor B, para corriente nominal.	69
CONCLUSIONES	70

INDICE DE FIGURAS

Fig. 2.1. Vista externa del motor de Inducción	12
Fig. 2.2. Estator de la maquina	12
Fig. 2.3 Estator de la maquina	13
Fig. 2.4. Rotor bobinado.14	
Fig. 2.5. Rotor de Jaula de ardilla	15
Fig. 2.6. Rotor de Jaula de ardilla	15
Fig. 2.7: Separación de las dos clases a través del hiperplano.	19
Fig. 2.8: Determinación de los vectores de soporte.	20
Fig. 2.9: Transformar del espacio.	25
Fig. 2.10. Esquema de la Transformada de Fourier por intervalos (STFT).	28
Fig. 2.11. Esquema de la Transformada Wavelet.	29
Fig. 2.12. Ejemplos de señal sinusoidal y señal Wavelet.	31
Fig. 2.13: Paso 1 para la obtención de la Transformada Wavelet.	32
Fig. 2.14. Paso 2 para la obtención de la Transformada Wavelet.	32
Fig. 2.15. Paso 3 para la obtención de la Transformada Wavelet.	34
Fig. 2.16. Diagrama de descomposición de señales.	35
Fig. 2.17. Diagrama de descomposición de señales.	36
Fig. 2.18. Árbol de descomposición Wavelet.	38
Fig. 4.1. Porcentaje de fallas de componentes de motores eléctricos.	47
Fig. 4.2. Esquema de montaje para la medición del voltaje y la corriente de los motores	48
Fig. 4.3. Árbol de descomposición Wavelet considerado	51
Fig. 4.4. Calculo de los coeficiente de aproximación y detalle en Matlab	52
Fig. 4.5. Calculo de los momentos a los coeficientes CD y CA en Matlab.	53
Fig. 4.6. Entrono grafico de la aplicación de MVS	54
Fig. 5.1 Fase de entrenamiento y prueba correspondiente al ensayo I	61
Fig. 5.2 Fase de entrenamiento y prueba correspondiente al ensayo II	61

Fig. 5.3 Fase de entrenamiento y prueba correspondiente al ensayo III	62
Fig. 5.4 Fase de entrenamiento y prueba correspondiente al ensayo IV	62
Fig. 5.5 Fase de entrenamiento y prueba correspondiente al ensayo V	63
Fig. 5.6 Fase de entrenamiento y prueba correspondiente al ensayo VI	63
Fig. 5.7 Fase de entrenamiento y prueba correspondiente al ensayo VII	64
Fig. 5.8 Fase de entrenamiento y prueba correspondiente al ensayo VIII	64
Fig. 5.9 Fase de entrenamiento y prueba correspondiente al ensayo I sin TW.	65
Fig. 5.10 Fase de entrenamiento y prueba correspondiente al ensayo II sin TW.	65
Fig. 5.11 Fase de entrenamiento y prueba correspondiente al ensayo III sin TW.	66
Fig. 5.12 Fase de entrenamiento y prueba correspondiente al ensayo IV sin TW.	66
Fig. 5.13 Fase de entrenamiento y prueba correspondiente al ensayo V sin TW.	67
Fig. 5.14 Fase de entrenamiento y prueba correspondiente al ensayo VI sin TW.	67
Fig. 5.15 Fase de entrenamiento y prueba correspondiente al ensayo VII sin TW.	68
Fig. 5.16 Fase de entrenamiento y prueba correspondiente al ensayo VIII sin TW.	68

INTRODUCCION

Los motores eléctricos de inducción son pieza fundamental en todo proceso industrial. Debido a los constantes esfuerzos de carga y a los procesos cada vez más complejos a los que son sometidos estos motores, hay un incremento en las fallas y aspectos como seguridad, confiabilidad, eficiencia y buen funcionamiento son algunas de las mayores preocupaciones. En este sentido las técnicas para diagnosticar a tiempo el estado de los motores juegan un papel importante para dar continuidad en la operación del sistema y evitar paradas de forma no planificada que pueden generar pérdidas económicas a la empresa.

De esta manera, la presente investigación tiene por objetivo desarrollar un clasificador binario que permita identificar el estado de funcionamiento del motor, a partir del análisis de las variables eléctricas utilizando como herramientas la transformada de wavelet (TW) y las máquinas de vectores de soportes (MVS). En este trabajo se utilizó la TW como una técnica para extraer características de las señales del motor que permitieron facilitar el proceso de clasificación y por otro lado se emplearon las MVS para clasificar, pues ambas (TW y MVS) han demostrado un excelente desempeño en este tipo de aplicaciones.

La realización de este trabajo contempló las siguientes etapas: En la primera se realizó una revisión de los antecedentes relacionados directa o indirectamente con la presente investigación y los fundamentos teóricos para la comprensión de las

técnicas empleadas en este proyecto, en la segunda etapa se diagnosticaron las variables eléctricas del motor con las que se iba a trabajar, como tercera etapa se realizó el procesamiento de las señales seleccionadas empleando la transformada de Wavelet y herramientas de estadísticas como los momentos, para extraer las características diferenciadoras que serán introducidas al clasificador, en la cuarta etapa se diseñó el clasificador basado en máquina de vectores de soporte y en la última se evaluó el rendimiento clasificador diseñado.

CAPITULO I

1.1 PLANTEAMIENTO DEL PROBLEMA

El motor de inducción es uno de los equipos eléctricos de mayor aplicación en el ámbito industrial; en virtud de su bajo costo, robustez, fácil mantenimiento y versatilidad se han hecho populares. Muchos de estos motores se utilizan en la industria minera, petrolera, acero, entre otras, en donde una falla repentina puede tener graves consecuencias, por lo que resulta necesario asegurar la continuidad operativa de estas máquinas mediante la detección oportuna de fallas incipientes originadas por los esfuerzos eléctricos, mecánicos y térmicos, a los que se someten durante su operación.

De este modo, identificar a tiempo el estado del motor permite planear su mantenimiento y reducir pérdidas en la producción. En los últimos años se han propuesto e implementado diversas alternativas para la detección y diagnóstico del estado de funcionamiento de las máquinas de inducción [1][2], las cuales destacan por su carácter no invasivo y por su capacidad para detectar fallas mientras la máquina funciona en condiciones normales.

Estas nuevas técnicas se basan en la utilización de herramientas computacionales y de procesamiento de señales. En este trabajo se eligieron dos de

ellas, las máquinas de vector de soporte empleada para clasificar y la Transformada de Wavelet utilizada para procesar la señal y extraer de ella características o rasgos que no son apreciables en su forma original.

Para clasificar existen varias técnicas convencionales tales como redes neuronales, árboles de decisión y máquinas de vectores de soporte, de ellas, las redes neuronales son una de las más empleadas [4], sin embargo, han de tomarse en cuenta diversos factores al construir una red neuronal para un problema dado: el algoritmo de aprendizaje, la arquitectura, el número de neuronas por capa, el número de capas, la representación de los datos, su sensibilidad al ruido, entre otros. [5]

Otra de las técnicas son los árboles de decisión, también han sido ampliamente utilizados en problemas de clasificación, mostrando usualmente ser más veloces que las redes neuronales en la fase de entrenamiento, pero con el inconveniente de que no ofrecen flexibilidad al modelar los parámetros [6]. De estas técnicas, las máquinas de vectores de soporte han mostrado ser superiores a otros métodos de aprendizaje supervisado [7] [8], debido a los buenos fundamentos teóricos y la capacidad de generalización [5], por esto constituye la herramienta de clasificación a utilizar en la presente investigación.

Por otro lado, hoy en día existen numerosas herramientas matemáticas para el procesamiento de señales tanto en el dominio tiempo como en el de las frecuencias,

una de ellas la Transformada de Fourier, la cual permite hacer un estudio de la señal en el dominio frecuencial. Sin embargo, esta técnica solo trabaja bien si la señal a procesar está compuesta de componentes estacionarias durante su periodo de análisis. Esto indica que efectos tales como cambios abruptos en el tiempo o eventos locales no puedan detectarse correctamente, perdiéndose información sobre la naturaleza o forma de estas variaciones [9].

De esta forma, existe entonces la necesidad de un análisis que describa mejor estas señales no estacionarias o transitorias. Esto se consigue con las transformadas "tiempo-frecuencia". Entre estas está la transformada corta de Fourier, la cual se basa en el mismo principio de la transformada de Fourier pero aplicada a pequeñas secciones de la señal; basada en una técnica conocida como ventaneado, sin embargo esta presenta el inconveniente de que el tamaño de la ventana es constante, por lo que si se fija una buena resolución (tamaño) para frecuencias baja, no la tendrá para frecuencias altas.

Otra de las técnicas "tiempo-frecuencia" es la Transformada de Wavelet, la cual resuelve esta dificultad haciendo uso de ventanas de tamaño variable, de modo que para bajas frecuencia la ventana es grande y para altas frecuencia es pequeña, permitiendo tener buena resolución en todo el espectro de la señal [10]. De esta manera la transformada de Wavelet constituye la técnica para el procesamiento de las señales seleccionadas en esta investigación.

Por lo antes mencionado, el presente trabajo tiene como objetivo desarrollar un clasificador binario que permita diagnosticar el estado de funcionamiento del motor de inducción por medio del procesamiento de sus variables eléctricas utilizando la Transformada de Wavelet y las Maquinas de Vectores de Soporte, de esta forma se pretende con esta investigación aporta una herramienta para estimar el estado de los motores de inducción y a la vez analizar los efectos que tiene la aplicación de la transformada de Wavelet como técnica de procesamiento de señales en el rendimiento de la clasificación.

1.2 OBJETIVOS

1.2.1 OBJETIVO GENERAL

Desarrollar un clasificador binario para estimar el estado de funcionamiento de los motores de inducción utilizando transformada de Wavelet y maquinas de vector de soporte.

1.2.2 OBJETIVOS ESPECIFICOS

- a) Diagnosticar las variables eléctricas que se utilizaran para identificar el estado de funcionamiento del motor de inducción.
- b) Aplicar la transformada de Wavelet a las variables seleccionadas para la extracción de rasgos o características que faciliten el proceso de clasificación del estado de funcionamiento del motor.

- c) Determinar los parámetros de la máquina de vector de soporte para definir el clasificador.
- d) Determinar la capacidad de estimación del estado de funcionamiento del motor de inducción a través del rendimiento del clasificador binario diseñado.

1.3 JUSTIFICACIÓN

En este trabajo se desarrolló un diagnosticador del estado de funcionamiento de los motores de inducción. Es evidente que conocer a tiempo el estado del motor permite planificar de forma anticipada y oportuna el mantenimiento y reducir pérdidas en la producción por paradas inesperadas, es así como, con la implantación de este sistema se estima aumentar la disponibilidad y la confiabilidad de las máquinas de inducción, disminuir las detenciones imprevistas o las paradas del proceso no programadas que pueden aumentar los costos de mantenimiento y generar pérdidas a la planta.

Por otro lado, diferentes trabajos [1] [11] relacionados con el diagnóstico y detección de fallas en motores que emplean como predictor o clasificador a las redes neuronales o a las máquinas de vector de soporte, no consideran el procesamiento previo de las señales. Este aspecto, se toma en cuenta en esta investigación lo cual trae como ventaja la eliminación del ruido, la extracción de características que faciliten el proceso de clasificación y la generación de señales con menor

dimensionalidad que permitieron reducir el tiempo de cálculo y la complejidad de la herramienta diseñada.

Producto de esta investigación se obtendrá información del potencial que ofrece la unión de la transformada de Wavelet con las máquinas de vectores de soporte, lo cual servirá de guía para futuras investigaciones en esta importante área.

1.4 ALCANCE Y DELIMITACION

El presente trabajo se limitó a desarrollar un clasificador binario capaz de estimar el estado de funcionamiento del motor, sin determinar cuál es la falla que presenta, en caso de que, no este en buenas condiciones. Por otra parte, la data correspondiente a las variables eléctricas seleccionadas, se obtuvo de la data ya existente de mediciones que se realizaron en motores de inducción de jaula de ardilla que están ubicados en el Laboratorio de Mantenimiento Preventivo de la Escuela de Ingeniería Eléctrica de la Facultad de Ingeniería de la Universidad de Carabobo. Estas mediciones se efectuaron sobre motores en buen estado y en motores que presentaban fallas.

Las fallas consideradas en esta investigación fueron solo en los rodamientos, específicamente tres casos: Falla en su pista interna, falla en su pista externa y falla en el elemento rodante.

Este trabajo se desarrolló en la Escuela de Ingeniería Eléctrica de la Facultad de Ingeniería de la Universidad de Carabobo.

CAPITULO II

2.1 ANTECEDENTES DE LA INVESTIGACION

El trabajo realizado por los profesores Rodríguez I. y Rubén T., de la Universidad de Carabobo y Alves R. de la Universidad Simón Bolívar(2009) titulado: “Diagnóstico de Fallas en Motores de Inducción, empleando la técnica de Vectores de Soporte”, fue una de los puntos de partida de la presente investigación ya que en este se presenta a las máquinas de vector de soporte como una herramienta útil para la detección de fallas en motores de inducción.

Igualmente, como en la presente investigación se emplearan las máquinas de vectores de soportes para clasificar, otro de los trabajos considerados fue “Predicción de hipertensión arterial usando máquinas de vectores de soporte”realizado en la Universidad de Carabobo por Seijas C., Caralli A. Villasana S y Arteaga F.(2006), en el cual se evidencia nuevamente la capacidad de esta herramienta para clasificar y se aborda uno de los problemas que se presentan al momento de diseñar la máquina de vectores de soportes a utilizar, que es la elección de la función “kernel”.

De igual manera, otra de las técnicas que se utilizó en este trabajo es la Transformada de Wavelet, con esta se identificaron características o rasgos de las variables eléctricasseleccionadas del motorpara facilitar el proceso de clasificación. A tal efecto, el trabajo de grado de maestría realizado por el Prof. Carlos Jiménez en la

Universidad de Carabobo (2004), titulado: “Análisis de señales de voz utilizando la Transformada de Wavelet”, brinda un marco teórico acerca del funcionamiento y aplicación de la Transformada de Wavelet y muestra el cálculo de los coeficientes que se generan con la aplicación de esta transformada sobre la señal, tomando en cuenta varias funciones Wavelet y diferentes niveles de descomposición.

Por otro lado, en esta investigación se procesaranciertas variables eléctricas del motor para determinar su estado de funcionamiento, trabajos como “Técnicas de Detección y Diagnóstico de Fallos enMáquinas Eléctricas de Inducción” de Verucchi C. y Acosta G. (2004), “Sistema de detección de fallas eléctricas en motoresdel área de Carbón de CVG-VENALUM” de Valenzuela A.(2006) y “Diagnostico en línea y fuera de línea de motores de inducción de baja, media y ata tensión” Carvajal F., RamirezJ. yArco L. (1999), describen como por medio del procesamiento de algunas variables eléctricas o mecánicas del motor, es posible extraer información que va a permitir no solo diagnosticar en que condición se encuentra el mismo, sino incluso reconocer que falla presenta.

Otras de las investigaciones que sirvieron de punto de partida fueron las siguientes: “Clasificación de señales sísmicas por medio de onditas y máquinas de vectores de soporte” de J.E. Hurtado, R. Henao, G. Castellanos (2003) y “Análisis de formas de onda de plasma con Wavelet y maquinas de vectores de soporte” de S.

Dormido, J.M. de la Cruz, J. Vega, M. Santos, J. Sánchez y Gonzalo Farias (2005), en estos trabajos se muestra la utilización de la transformada de Wavelet como técnica para el procesamiento y extracción de características previo a la aplicación de las máquinas de vector de soporte como clasificador.

2.2 MARCO TEORICO

2.2.1 MOTOR DE INDUCCIÓN.

El motor eléctrico por excelencia en corriente alterna es el motor de inducción o motor asíncrono trifásico, es el más utilizado para el accionamiento de máquinas en la industria, su amplia utilización se debe a su sencillez de mantenimiento, facilidad de instalación, bajo coste y robustez. Una de sus principales características es que su armadura o rotor no está conectada a fuente alguna de potencia, sino que la recibe por inducción del flujo creado por los arrollamientos dispuestos en el estator, el cual está alimentado por corrientes polifásicos.

Cuando se habla de máquina de inducción, generalmente se está refiriendo al motor de inducción, pues el generador de inducción no tiene mucha aplicación.

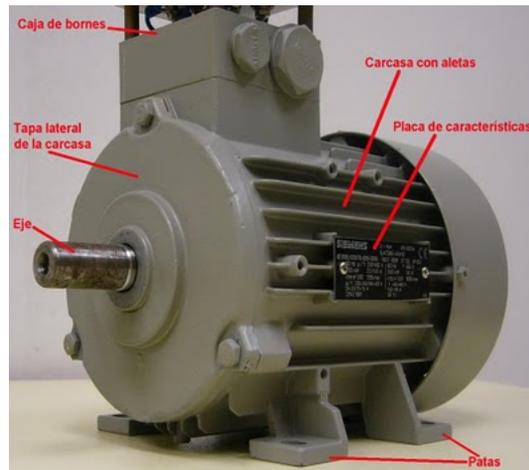


Figura 2.1. Vista externa del motor de Inducción
Fuente: (viatger, 2008)

El motor de inducción tiene dos partes principales: estator y rotor. El **estator** es la parte fija de la máquina en cuyo interior hay ranuras donde se coloca el devanado trifásico que se alimenta con corriente alterna trifásica, posee además las tapas laterales o también llamadas escudos que llevan dos cojinetes que permite el giro del rotor.

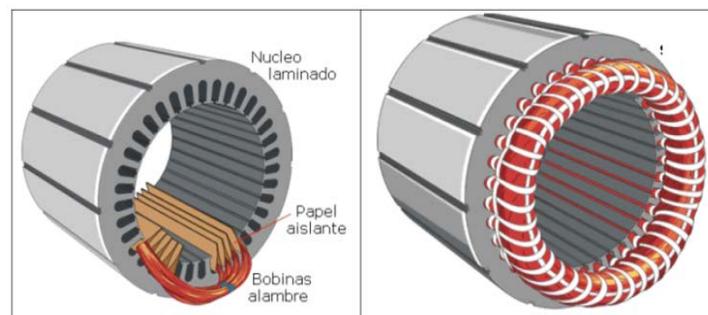


Figura 2.2. Estator de la máquina
Fuente: Control de Motores. Escuela Especializada en Ingeniería ITCA. 2006

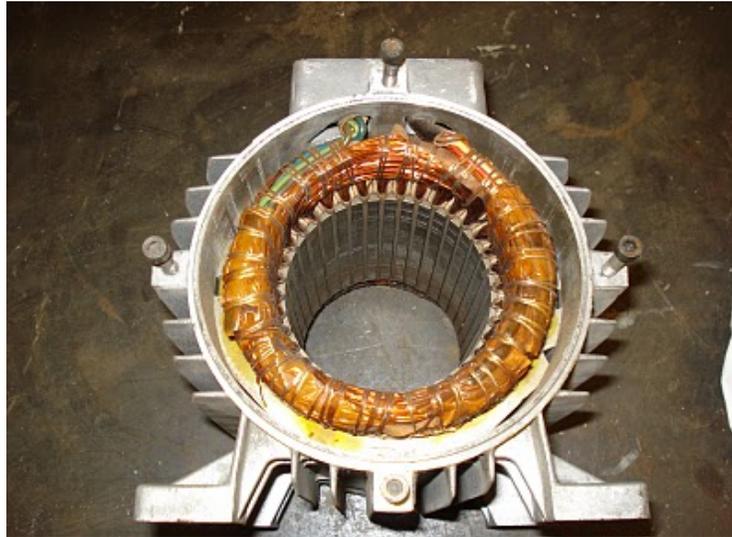


Figura 2.3 Estator de la maquina
Fuente: (viatger, 2008)

La parte giratoria de la máquina se llama **rotory** este puede ser de dos tipos uno es el rotor bobinado y el otro es el rotor jaula de ardilla:

a) Rotor Bobinado.

El rotor bobinado está compuesto de un devanado polifásico similar al del estator y con el mismo número de polos que él. Los terminales del devanado del rotor se conectan a anillos rasantes aislados, montados sobre el eje, en los que se apoyan escobillas de carbón, de manera que dichos terminales resultan accesibles desde el exterior, según se aprecia en la Figura 2.4.

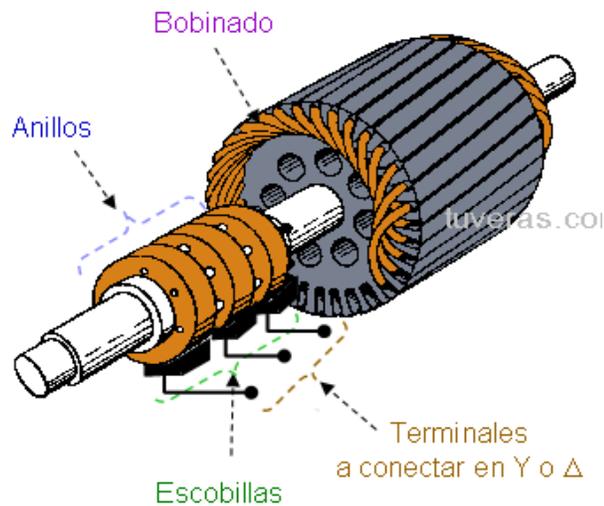


Figura 2.4. Rotor bobinado.

Fuente: www.tuveras.com/mquinaasincronica

b) Rotor Jaula de Ardilla.

El rotor jaula de ardilla está formado por varillas conductoras alojadas en ranuras que existen en el hierro del propio rotor y cortocircuitadas en ambos extremos mediante dos anillos planos conductores dispuestos en cada lado del rotor, según se puede apreciar en la Figura 2.5. De acuerdo a sus características par-velocidad, los motores de jaula de ardilla se diseñan en los tipos A, B, C y D. El diseño tipo B es el más común y cubre la mayoría de las aplicaciones de los motores.

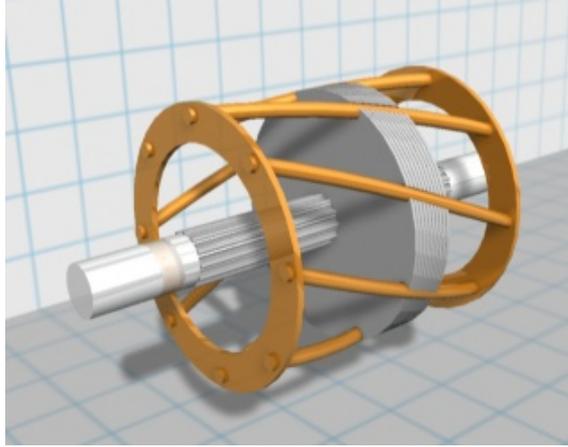


Figura 2.5. Rotor de Jaula de ardilla

Fuente (web:<http://ter.mforos.com/1398167/6720912-motor-asincrono/> 2008)



Figura 2.6. Rotor de Jaula de ardilla

Fuente: (viatger, 2008)

2.2.1.1 PRINCIPIOS BASICOS DE FUNCIONAMIENTO:

Cuando se excita al bobinado del estator de una máquina de inducción con un sistema trifásico de corrientes, todas de igual magnitud y desfasadas 120° , se producirá un campo magnético giratorio de magnitud constante, que girara con una velocidad sincrónica n_{sinc} , este campo va a actuar sobre el rotor y va a inducir sobre él

un voltaje que producirá unas corrientes, las cuales originaran otro campo, de este modo, existirán dos campos dentro de la máquina, el campo del estator B_s y el campo del rotor B_r , estos dos campos se atraerán causando una fuerza de atracción que hará girar al rotor.

$$n_{sinc} = \frac{120f}{p} \quad (Ec. 1)$$

Donde:

n_{sinc} : Velocidad síncrona (velocidad del campo giratoria del estator), f : Frecuencia de la red, p : Número de polos.

Ahora supongamos que,

n_r : rpm del rotor (Velocidad del campo magnético del rotor)

El campo del rotor se retrasa respecto al campo del estator en:

$$n = n_{sinc} - n_r \quad (Ec. 2)$$

El deslizamiento se expresa por:

$$s = \frac{n_{sinc} - n_r}{n_{sinc}} \quad (Ec. 3)$$

Esta variable nos indica como se está moviendo el rotor del motor, así tenemos que para $s=1$ el rotor está detenido y para s pequeño el rotor se mueve a una velocidad cercana a la velocidad sincrónica ($0 < s \leq 1$).

2.2.2 MAQUINAS DE VECTORES DE SOPORTE

2.2.2.1 GENERALIDADES DE LAS MAQUINAS DE VECTORES DE SOPORTE (MVS).

El método de los vectores de soporte (Support Vector o SV) es un método general para la resolución de problemas de clasificación, regresión y estimación. Las Máquinas de Vectores de Soporte (MVS) se basan en el trabajo de V. Vapnik en 1964 sobre la teoría de aprendizaje estadístico, utilizando el principio de inducción de minimización del riesgo estructural como proceso de inferencia. En los años 90 fue generalizado y en la actualidad es objeto de un gran interés.

La idea principal de las máquinas de vectores de soporte es construir un hiperplano como una superficie de decisión en la cual se maximice el margen de separación entre los ejemplos positivos y negativos.

2.2.2.2.- HIPERPLANO OPTIMO PARA PATRONES LINEALMENTE SEPARABLES.

Considere el siguiente par de entrenamiento $\{(x_i, y_i)\}_i^N$ donde x_i es el patrón de entrada para el i -ésimo ejemplo y y_i es la respuesta deseada que le corresponde. Para iniciar se supone que el patrón representado por el subconjunto $y_i = +1$ y el patrón representado por el conjunto $y_i = -1$ son “linealmente separables”. La ecuación de la superficie de decisión en forma de hiperplano es:

$$\langle w \cdot x \rangle + b = 0 \text{ (Ec. 4)}$$

$$\sum_{i=1}^n w_i \cdot x_i + b = 0$$

Dado el conjunto de muestras:

Donde x es el vector de entrada, w es el vector de pesos ajustable y b es el umbral. Entonces:

$$\langle w \cdot x_i \rangle + b \geq 0, \text{ para } y_i = +1 \text{ (Ec. 5)}$$

$$\langle w \cdot x_i \rangle + b < 0, \text{ para } y_i = -1 \text{ (Ec. 6)}$$

Para un vector de pesos w y un umbral b dados, la separación entre el hiperplano definido en las ecuaciones 5 y 6 y los datos más cercanos se denomina el margen de separación, y se denota por ρ . El objetivo de la máquina de vector de soporte es encontrar un hiperplano en particular tal que maximice el margen de separación. Con esta condición, la superficie de decisión se denota como hiperplano óptimo. En la figura 2.8 se ilustra la construcción geométrica de un hiperplano óptimo para un espacio de entrada bidimensional.

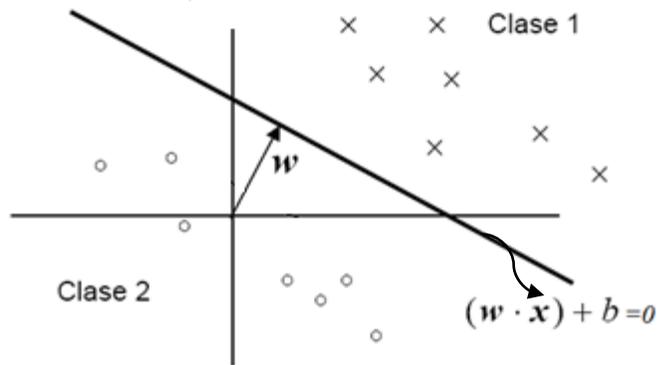


Figura 2.7: separación de las dos clases a través del hiperplano.

Fuente: (Fasanella M, 2004)

Como se ve en la figura superior, la interpretación geométrica es que el espacio de entrada x es dividido en dos partes por el hiperplano definido por $\langle w \cdot x \rangle + b = 0$, dentro de todos los hiperplanos posibles para la separación de los datos, existe un único hiperplano óptimo que es el que proporciona un mayor margen de separación entre las clases, significa entonces construir el hiperplano:

$$H: y = \langle w \cdot x \rangle - b = 0 \quad (\text{Ec. 7})$$

y dos hiperplanos paralelos:

$$H1: y = \langle w \cdot x \rangle - b = +1 \quad \text{y} \quad H2: y = \langle w \cdot x \rangle - b = -1 \quad (\text{Ec. 8})$$

Los puntos (x_i, y_i) para los cuales se cumplen las ecuaciones Ec. 8 se denominan vectores de soporte (Figura 2.5); de ahí el nombre de “máquinas de vectores de soporte”. En términos conceptuales, los vectores de soporte son aquellos

puntos que pertenecen a la cercanía de la superficie de decisión y tienen influencia directa en la localización óptima de la superficie separadora.

Considerando que 2ρ es el valor óptimo del margen de separación entre los dos planos o las dos clases que constituyen el conjunto de datos de entrenamiento, se tiene:

$$\rho = \frac{1}{\|w_o\|} \quad (\text{Ec. 9})$$

La ecuación anterior establece que maximizar el margen de separación entre clases es equivalente a maximizar la norma euclidiana del vector de pesos w .

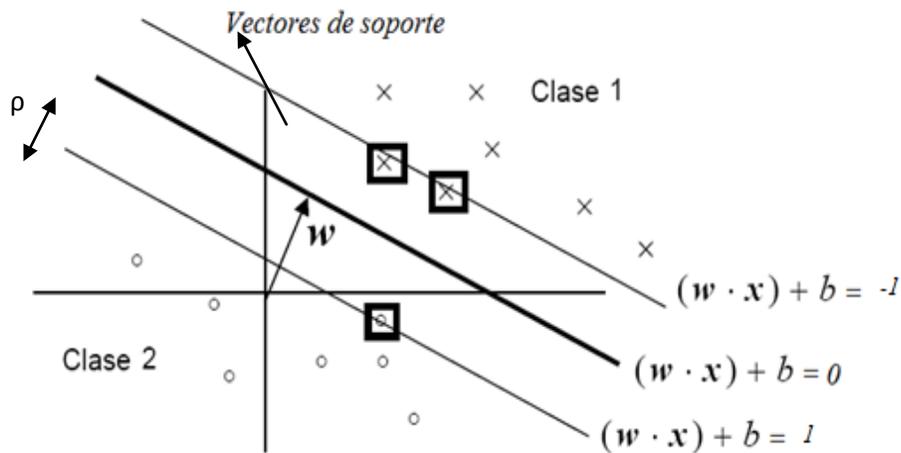


Figura 2.8: Determinación de los vectores de soporte.

Fuente: (Fasanella M, 2004)

2.2.2.3 OPTIMIZACIÓN CUADRÁTICA PARA ENCONTRAR EL HIPERPLANO ÓPTIMO.

El objetivo es desarrollar un procedimiento computacional efectivo para utilizar el par de entrenamiento $\{(x_i, y_i)\}_i^N$ a fin de encontrar el hiperplano óptimo. De este modo, dado un conjunto de entrenamiento $\{(x_i, y_i)\}_i^N$ encontrar los valores óptimos del vector de pesos \mathbf{w} y del umbral b tal que satisfaga las restricciones:

$$y_i\{\mathbf{w} \cdot \mathbf{x}_i\} + b \geq 1, i=1, \dots, N \text{ (Ec. 10)}$$

y el vector de pesos \mathbf{w} minimice la función:

$$g(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \text{ (Ec. 11)}$$

El factor de escalamiento $\frac{1}{2}$ se incluye por conveniencia de presentación. Este problema de optimización con restricciones se denomina el problema primario, y tiene las siguientes características:

- La función $g(\mathbf{w})$ es una función convexa de \mathbf{w} .
- Las restricciones son lineales en \mathbf{w} .

Por lo tanto, es posible resolver el problema de optimización con restricciones utilizando el método de multiplicadores de Lagrange (Bertsekas, 1995).

Primero se construye la función lagrangiana:

$$J(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i [d_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1] \text{ (Ec. 12)}$$

Donde las variables auxiliares no negativas, α_i , son llamadas multiplicadores de Lagrange. La solución al problema de optimización es determinada por el punto de silla de la función Lagrangiana $J(w, b, \alpha)$, la cual tiene que ser minimizada con respecto a w y a b ; y también que ser minimizada con respecto a α . Así que, diferenciando $J(w, b, \alpha)$ con respecto a w y a b e igualando los dos resultados a cero, se tienen las siguientes condiciones de optimalidad:

$$\text{Condición 1: } \frac{\partial J(w,b,\alpha)}{\partial w} = 0 \text{ (Ec. 13)}$$

$$\text{Condición 1: } \frac{\partial J(w,b,\alpha)}{\partial b} = 0 \text{ (Ec. 14)}$$

2.2.2.4 HIPERPLANO ÓPTIMO PARA PATRONES NO SEPARABLES

El análisis realizado hasta aquí se ha enfocado en patrones linealmente separables. Ahora se considera el caso más difícil de patrones no separables. Dado un conjunto de datos de entrenamiento de este tipo, no es posible construir un hiperplano separador sin encontrar errores de clasificación. De cualquier modo, se desea encontrar un hiperplano óptimo que minimice la probabilidad de errores de clasificación, promediado sobre el conjunto de entrenamiento.

El margen de separación entre las clases se dice suave si un punto (x_i, y_i) viola la siguiente condición:

$$y_i\{\mathbf{w} \cdot \mathbf{x}_i + b\} \geq 1, i=1, \dots, N \text{ (Ec. 15)}$$

Esta violación puede surgir en una de las dos formas siguientes:

- * Caso 1: El punto (x_i, y_i) cae dentro de la región de separación pero en el lado correcto de la superficie de decisión.
- * Caso 2: El punto (x_i, y_i) cae en el lado equivocado de la superficie de decisión.

Nótese que se tiene una clasificación correcta en el caso 1 pero incorrecta para el caso 2. Para realizar el tratamiento formal de patrones no separables se introducirá un nuevo conjunto de variables escalares no negativas $\{\xi_i\}_{i=1}^N$ tal que la definición del hiperplano de separación queda así:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, i=1, \dots, N \text{ (Ec. 16)}$$

Donde ξ_i miden la desviación del punto a partir de la condición ideal de la separabilidad de patrones. Ahora solo queda plantear formalmente el caso de patrones no separables:

Dado un conjunto de entrenamiento $\{(x_i, y_i)\}_i^N$ hallar los valores óptimos del vector de pesos \mathbf{w} y del umbral b tal que satisfaga las restricciones:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, i=1, \dots, N$$

$$\xi_i \geq 0 \quad \forall i$$

y tal que el vector de pesos w y las variables ξ_i minimicen la función:

$$g(w) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \text{ (Ec. 17)}$$

Donde C es un parámetro positivo especificado por el usuario.

Ahora usando el método de los operadores de Lagrange nos queda: Dado un conjunto de entrenamiento $\{(x_i, y_i)\}_i^N$ hallar los multiplicadores de Lagrange $\{\alpha_i\}_{i=1}^N$ tal que maximice la función objetivo:

$$W(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j (x_i x_j) \text{ (Ec. 18)}$$

Sujeto a las restricciones:

$$1) \sum_{i=1}^N \alpha_i y_i = 0 \text{ (Ec. 19)}$$

$$2) 0 \leq \alpha_i \leq C, \text{ (Ec. 20)}$$

Introduciendo los multiplicadores de Lagrange la solución a dicho problema toma siempre la forma:

$$w = \sum_{v_S} \alpha_i y_i x_i = \sum_i v_i x_i \text{ (Ec. 21)}$$

Los α_i son multiplicadores de Lagrange, muchos de los cuales son cero, siendo v_i , el producto de α_i por y_i . Al determinar el máximo margen, esto es los hiperplanos que maximizan el margen, sólo los puntos que se encuentren más cercanos a los hiperplanos tendrán valores de w_i positivos. Los vectores asociados a los multiplicadores no nulos se denominan “vectores soporte”, los demás son irrelevantes

porque quedan perfectamente clasificados, y de alguna de las condiciones (Karush-Kuhn-Tucker) se obtiene la constante b .

$$\alpha_i [y_i((\mathbf{w} \cdot \mathbf{x}_i) + b) - 1] = 0, i=1, \dots, N \text{ (Ec. 22)}$$

2.2.3.4. CLASIFICADOR NO LINEAL

La expansión del método de MVS a clasificadores no lineales, se realiza transformando el espacio de entrada $X \subseteq \mathcal{R}^n$ a otro espacio de mayor dimensión F , llamado espacio de características, dotado de producto interno y donde los datos son separables linealmente, ver figura 2.9.

$$\Phi: X \rightarrow F$$

$$(\Phi(\mathbf{x}_1) \cdot \Phi(\mathbf{x}_2)) = K(\mathbf{x}_1, \mathbf{x}_2) \text{ (Ec. 13)}$$

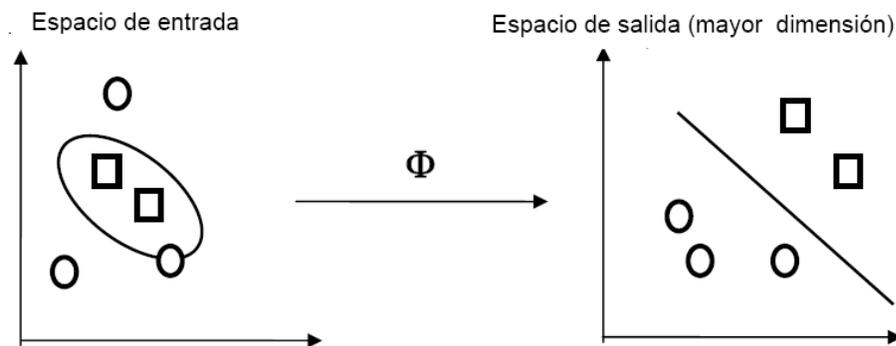


Figura 2.9: Transformar del espacio.

Fuente: (Fasanella M, 2004)

Esta proyección de los datos de un espacio a otro de más alta dimensionalidad se logra gracias a la habilidad del aprendizaje de las MVS que permite el uso de las funciones kernel de manera de extender las funciones de decisión al caso no lineal.

Bajo ciertas condiciones (condición de Mercer), el producto escalar en el espacio de salida se puede escribir a través de un cierto núcleo $K(x,y)$, función de Kernel, donde el cálculo se realiza con espacios de rasgos de dimensionalidad arbitraria sin usar $\Phi(x_i)$ explícitamente: Shölkopf observó que la función kernel define una medida de la distancia d sobre el espacio de entrada demostrando que la función kernel $k(x,y)$ puede interpretarse como una medida de la similitud entre el ejemplo x y el y .

2.3. TRANSFORMADA DE WAVELET

En el análisis de señales existe un gran número de herramientas que se han ido desarrollando con el paso de los años, entre las que destaca, sin lugar a dudas, la Transformada de Fourier, la cual permite entregar una representación del contenido de frecuencias que posee una determinada señal. Sin embargo, hace no más de 20 años, se han venido desarrollando nuevas herramientas, que permiten realizar un análisis de las señales desde otra perspectiva, surgidas principalmente ante la necesidad de poder analizar señales que no se comportan en forma estacionaria, o que presentan cambios bruscos en intervalos muy pequeños.

En muchos casos, el análisis mediante Transformada de Fourier resulta extremadamente útil, razón por la cual sería natural preguntarse por qué podría ser necesario el uso de otra herramienta para el análisis de señales; pues bien, al pasar una señal al dominio de la frecuencia se pierde la información referente al tiempo;

más precisamente, cuando se observa una señal producto de la Transformación de Fourier, resulta imposible determinar *cuándo* ocurre un determinado evento o *cuándo* está presente una determinada frecuencia. Si las propiedades de la señal que se está analizando no cambian demasiado en el tiempo, es decir, si se está trabajando con una *señal estacionaria*, esta desventaja no resulta muy relevante (como en el caso de señales periódicas, por ejemplo). Sin embargo, un importante número de señales de interés presentan características no estacionarias o transitorias, tales como una tendencia, cambios abruptos, comienzos o finales de eventos, etc.

A menudo, estas características no estacionarias resultan ser las secciones más interesantes de las señales, y la Transformada de Fourier no está preparada para detectarlas y/o analizarlas.

2.3.1 ANÁLISIS DE FOURIER POR INTERVALOS

En un esfuerzo por corregir la deficiencia presentada en el punto previo, en 1946 Denis Gabor adaptó la transformada de Fourier para poder analizar una pequeña sección de la señal en un determinado tiempo (mediante una especie de ventana). Esta adaptación es la que se conoce como STFT, la cual lleva una señal del plano del tiempo al plano bidimensional de tiempo y frecuencia [9], tal como se presenta esquemáticamente en la figura 2.7.

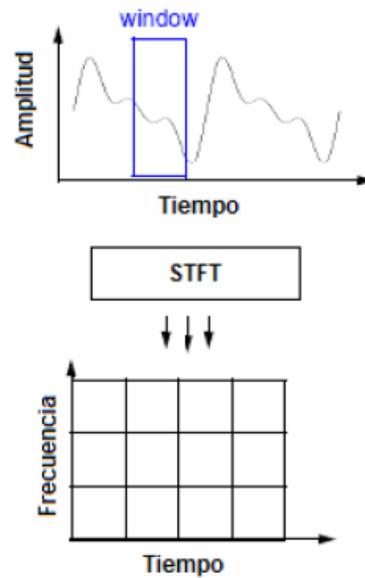


Fig. 2.10. Esquema de la Transformada de Fourier por intervalos (STFT).

Fuente: Kouro R y Musalem M. 2001.

Es importante mencionar que la STFT representa una especie de compromiso entre el dominio del tiempo y el de la frecuencia de una señal, ya que provee algo de información acerca de *cuándo* y a *qué* frecuencia de una señal ocurre un determinado evento. Sin embargo, solamente se puede obtener dicha información con una precisión limitada, la cual está acotada por el tamaño de la ventana. Mientras que el compromiso entre la información del tiempo y la frecuencia puede resultar útil, el inconveniente surge dado que una vez que se escoge un determinado tamaño para la ventana de tiempo, dicha ventana es la misma para todas las frecuencias. Muchas señales requieren un acercamiento más flexible, de modo tal que sea posible variar el tamaño de la ventana para determinar con mayor precisión el tiempo o la frecuencia.

2.3.2 GEBERALIDADES DE LA TRANSFORMADA DE WAVELET

El análisis Wavelet representa el paso siguiente a la STFT: una técnica mediante ventanas con regiones de tamaño variable. El análisis Wavelet permite el uso de intervalos grandes de tiempo en aquellos segmentos en los que se requiere mayor precisión en baja frecuencia, y regiones más pequeñas donde se requiere información en alta frecuencia. Esta idea es la que se muestra en forma esquemática en la figura 2.8



Fig. 2.11. Esquema de la Transformada Wavelet.

Fuente: Kouro R y Musalem M. 2001.

Una forma sencilla de comprender el modo de operación de esta transformada es pensar que la señal en base de tiempo es pasada por varios filtros pasabajos y pasaaltos, los cuales permiten separar las porciones de la señal de alta frecuencia de aquellas de baja frecuencia.

Para clarificar más la forma en que opera esta Transformada, se considera el siguiente ejemplo: Supóngase que se tiene una señal que posee frecuencias hasta 1000[Hz]. En la primera etapa se divide la señal en 2 partes, pasándola por un filtro

pasaaltos y uno pasabajos. De este modo, se obtienen 2 diferentes versiones de la señal original: parte de la señal que corresponde al rango 0-500[Hz] y la otra en el rango 500-1000[Hz]. [9]

Posteriormente, se toma una de estas partes (o ambas) y se repite el proceso. Suponiendo que se hace nuevamente este proceso con la parte de baja frecuencia de la señal, y que en dicho resultado el proceso se vuelve a repetir en la parte de baja frecuencia, se tienen 4 partes de la señal original: 0-125[Hz], 125-250[Hz], 250-500[Hz] y 500-1000[Hz]. Se puede continuar con este procedimiento hasta que se haya descompuesto la señal en un determinado número de *niveles*. De este modo, se tienen un grupo de señales que representan a la misma señal, pero todas ellas corresponden a diferentes bandas de frecuencias.[9]

2.2.4. ANÁLISIS MEDIANTE LA TRANSFORMADA DE WAVELET

Antes de explicar las características del análisis de señales mediante Transformada Wavelet, es necesario señalar que una *Wavelet* es una señal (o forma de onda) de duración limitada cuyo valor medio es cero. Comparando las Wavelets con las funciones sinusoidales (que son la base del análisis de Fourier), se puede resaltar que la principal diferencia radica en que las señales sinusoidales no tienen duración limitada, dado que se extienden desde $-\infty$ a $+\infty$. Además, mientras las

señales sinusoidales son suaves y predecibles, las Wavelets tienden a ser irregulares y asimétricas[9], tal como se puede apreciar en la figura 2.9

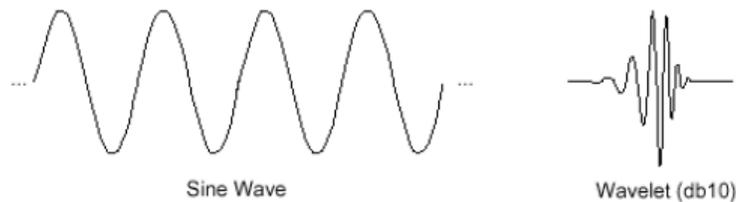


Fig. 2.12. Ejemplos de señal sinusoidal y señal Wavelet.

Fuente: Kouro R y Musalem M. 2001.

Tal como se menciona previamente, el análisis a través de Transformada de Fourier consiste en descomponer la señal original en funciones sinusoidales de diferentes frecuencias. En forma similar, el análisis de señales mediante Transformada Wavelet descompone la señal en versiones trasladadas (en tiempo) y escaladas de la Wavelet original, más conocida como *Wavelet madre*.

Observando las gráficas de la figura 2.12, resulta intuitivo pensar que las señales con cambios bruscos serán mejor analizadas mediante Wavelets irregulares que a través de suaves sinusoides. Como consecuencia de aquello, es que una de las principales ventajas que provee la Transformada Wavelet es su facultad para el análisis de áreas localizadas de señales grandes.

Hasta ahora, solamente se ha discutido acerca del tratamiento de señales de una dimensión, sin embargo, el análisis mediante Transformada Wavelet puede ser

aplicado a datos bidimensionales (imágenes), y en principio, a datos de mayor dimensión también.

2.2.5. CÁLCULO DE LA TRANSFORMADA WAVELET

En este punto se presenta en forma cualitativa un método sencillo para obtener la Transformada Wavelet de una determinada señal. Antes de describir los pasos a seguir, debe elegirse una función Wavelet, la que será la *Wavelet madre* y servirá como prototipo para todas las ventanas que se emplean en el proceso. Existe una importante cantidad de *familias* de funciones Wavelets que han probado ser especialmente útiles; entre ellas destacan la *Haar*, *Daubechies*, *Biortogonal*, *Coiflets*, *Symlets*, *Morlet*, *Sombrero mexicano* y *Meyer*, entre otras[9]. Los pasos a seguir para determinar la Transformada Wavelet de una señal son:

1. Comenzando con un determinado valor de s (escala), por ejemplo 1, para la señal Wavelet, se ubica ésta al comienzo de la señal a analizar (en $t = 0$). Luego, se multiplican entre sí ambas señales y el resultado se integra sobre todo el espacio de tiempo. El resultado de dicha integral se multiplica por el inverso de la raíz cuadrada de s , con el objeto de normalizar la energía y de este modo obtener una función Transformada con la misma energía a cualquier escala. Este resultado es el valor de la Transformación Wavelet en tiempo cero y $s = 1$.

Es importante mencionar que este resultado indica cuán correlacionada está la Wavelet con el segmento de la señal original. Lógicamente, el resultado dependerá de la elección de la función Wavelet. Este paso queda representado en la figura 2.10.

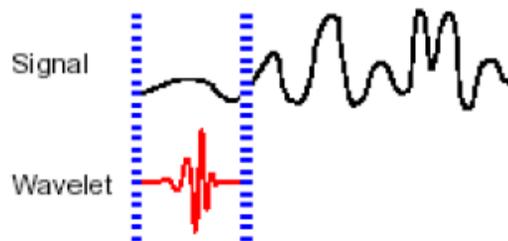


Figura 2.13: Paso 1 para la obtención de la Transformada Wavelet.

Fuente: Kouro R y Musalem M. 2001.

2. La función Wavelet (en la misma escala, por ejemplo $s=1$) se traslada en tiempo (hacia la derecha) en τ , y se vuelve a realizar el procedimiento descrito en el paso 1. Se debe repetir esto hasta llegar al final de la señal a analizar. Este paso queda ilustrado en la figura 2.14.

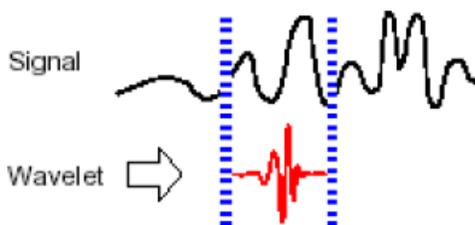


Fig. 2.14. Paso 2 para la obtención de la Transformada Wavelet.

Fuente: Kouro R y Musalem M. 2001.

3. Se varía el valor de s (escala) y se vuelven a realizar los pasos 1 y 2 hasta haber barrido todo el rango de frecuencias que se desea analizar. Note que dado que se trata

de una Transformación continua, tanto el corrimiento en tiempo como la variación de escala debiesen realizarse en forma continua. Sin embargo, si es necesario obtener la Transformada Wavelet por medios computacionales la condición anterior se reduce a considerar un paso suficientemente pequeño. Cada cálculo para un determinado valor de s llena la correspondiente fila de datos del plano tiempo-escala. Este paso se ilustra en la figura 2.12.

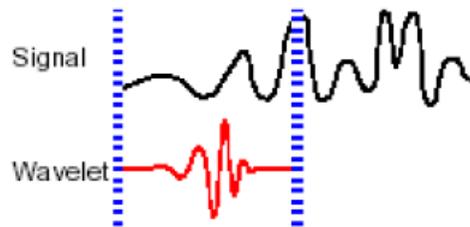


Fig. 2.15. Paso 3 para la obtención de la Transformada Wavelet.
Fuente: Kouro R y Musalem M. 2001.

Cuando se haya completado el cálculo para todos los valores de s , se habrá obtenido la Transformada Wavelet continua de la señal.

2.2.5. TRANSFORMADA WAVELET DISCRETA

Para aplicar la transformada Wavelet a una serie de datos numéricos, se hace necesario implementar una transformada discreta. La idea fue desarrollada por Mallat en 1988 [9], quien diseñó un algoritmo basado en un banco de filtros que permite

obtener una transformada Wavelet en forma instantánea a partir de los datos de interés.

2.2.5.1 FILTROS DE UN NIVEL.

En la mayoría de las señales son las componentes de baja frecuencia las que le otorgan a la señal la mayor parte de su información, o bien, le dan una especie de identidad a la señal. Mientras que las componentes de alta frecuencia se encargan de incorporar características más particulares. Es por ello que se subdividen las componentes de una señal en dos categorías:

- Aproximaciones (baja frecuencia)
- Detalles (alta frecuencia)

Luego surge la idea de separar estas dos componentes a través de filtros. Lo anterior queda ejemplificado en el diagrama de la figura 2.16,

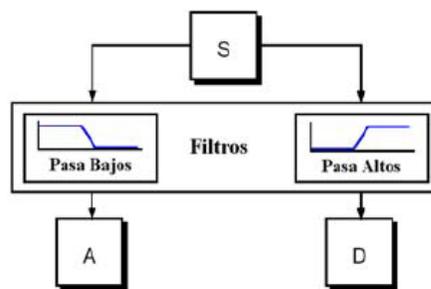


Figura 2.16. Diagrama de descomposición de señales.
Fuente: Kouro R y Musalem M. 2001.

Donde S es la señal que se desea analizar, A la salida del pasabajos y D la salida del filtro pasaaltos. Naturalmente, los filtros son diseñados de tal manera que sean complementarios, es decir, la suma de A y D debe ser S . Si se diseñaran los filtros en forma muy separada se perdería información, o en caso contrario se estaría amplificando la banda de entrecruzamiento. Sin embargo, este procedimiento tiene la desventaja que se aumenta al doble el número de datos originales, pues por cada muestra de S se genera un par de muestras (A, D), por lo que el costo matemático y computacional se incrementa. Para remediar esta falencia se propone un método que guarda la mitad de los puntos (A, D), sin perder en ello información de la señal S . Este procedimiento es conocido como submuestreo. La idea se ilustra en la figura 2.17.

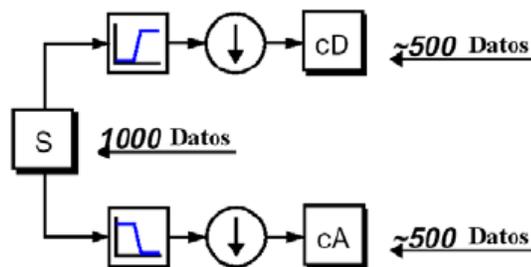


Figura 2.17. Diagrama de descomposición de señales.

Fuente: Kouro R y Musalem M. 2001

Los círculos con flechas representan la eliminación de datos o submuestreo. Luego, cD y cA son los nuevos coeficientes obtenidos de la etapa de filtración. Intuitivamente se puede concluir que al tener cD y cA , en conjunto, se tiene la misma cantidad de datos que las de la señal original S , y se ha mantenido la información

necesaria. En la figura 2.14 se ejemplifica la idea para una señal S de 1000 datos, obteniéndose en la salida dos series de *aproximadamente* 500 datos cada una.

La idea de *aproximado*, se debe a que el proceso de filtración es realizado a través de convolución de la señal de entrada con la función de transferencia (discreta) del filtro, lo que puede introducir eventualmente una o dos muestras más. Sin embargo, para muchas señales de mayor complejidad, no basta con dos bandas de frecuencias (alta y baja), sino que más bien debe hacerse una descomposición de más niveles para poder separar las características y poder analizarlas independientemente. Surge la idea entonces de filtros multiniveles.

2.2.5.2 FILTROS MULTINIVELES.

Para realizar la motivación expuesta en el punto anterior, basta con iterar el proceso de filtrado, es decir, aplicar el mismo procedimiento a las señales de salida de la primera etapa, y así sucesivamente hasta el nivel de precisión que se desee. Lo anterior da origen a una descomposición multinivel conocida como ramificación o árbol de descomposición Wavelet, cuya idea es expuesta en la figura 2.18.

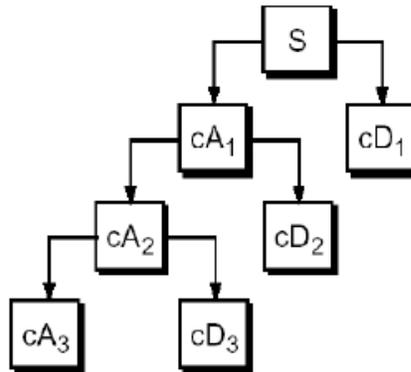


Fig. 2.18. Árbol de descomposición Wavelet.
Fuente: Kouro R y Musalem M. 2001.

Note que cD_1 resulta ser la componente de más alta frecuencia de la señal, y cA_3 la de menor frecuencia. Al ser descompuesta la señal en mayor cantidad de bandas de frecuencia se posee una información más detallada acerca de S , por lo que esta metodología es conocida como *multiresolución*. Surge en forma inmediata la inquietud acerca del diseño del algoritmo, relativo al número de niveles a utilizar.

CAPITULO III

MARCO METODOLOGICO

3.1 NIVEL Y TIPO DE INVESTIGACIÓN

De acuerdo a los propósitos de este proyecto, el mismo se enmarca dentro de un nivel de investigación explicativa, siendo el tipo de investigación documental y de campo. La investigación es explicativa porque se persigue a través del análisis de las variables eléctricas del motor, determinar cuál es su estado de funcionamiento, según Fidias Arias “La investigación explicativa se encarga de buscar *el por qué* de los hechos mediante el establecimiento de relaciones causa-efecto” (1999-p.20)

Por otro lado, la investigación es de tipo documental porque se utilizaran como una de las técnicas de recolección de datos, la revisión de fuentes bibliográficas, tesis y artículos relacionados con el tema bajo estudio, según la definición de Fidias Arias “La investigación documental es aquella que se basa en la obtención y análisis de datos provenientes de materiales impresos u otro tipo de documentos” (1999-p.21) y es de campo porque una de las etapas de la investigación contempla la medición de las variables eléctricas del motor de inducción que se utilizaran para diagnosticar el estado del mismo, de acuerdo con la definición de Fidias Arias “La investigación de campo consiste en la recolección de datos directamente de la realidad donde ocurren los hechos, sin manipular o controlar variable alguna”

3.2 PROCEDIMIENTO METODOLOGICO

El procedimiento metodológico que aquí se siguió para el desarrollo de la investigación se estructuró en cuatro etapas:

Etapas I: Revisión bibliográfica:

En esta primera etapa se hizo una revisión exhaustiva en trabajos de investigación, texto de consulta y documentos publicados en Internet acerca de los principios de funcionamiento del motor de inducción y las principales técnicas utilizadas para el análisis y detección de fallas, así mismo, se hizo una revisión de las dos técnicas que se utilizaron para el diseño del clasificador que son la transformada de wavelet y las máquinas de vectores de soporte.

Etapas II: Selección de las variables eléctricas del motor.

En esta fase se diagnosticaron las variables eléctricas del motor de inducción que se utilizarían para estimar el estado de funcionamiento del mismo. Las señales seleccionadas fueron la corriente estatorica y el flujo de la maquina, las cuales fueron tomadas de la base de datos existente en el laboratorio de mantenimiento preventivo de la Universidad de Carabobo

Etapa III: Extracción de características de las variables seleccionadas

En esta tercera etapa se le aplicó a las variables seleccionadas en la etapa anterior, la transformada de Wavelet para extraer rasgos o características de la señal que faciliten el proceso de clasificación. Para ello primero se seleccionó la Transformada Wavelet a utilizar y el nivel de descomposición, la cual fue aplicada a la data original seleccionada para determinar los coeficientes de detalles o de alta frecuencia y de aproximación o de baja frecuencia. Una vez obtenidos estos coeficientes se emplearan herramientas estadísticas como el cálculo de los momentos, para definir los criterios de clasificación.

Etapa IV: Desarrollo del clasificador con máquinas de vectores de soporte

En esta última etapa se desarrolló el clasificador empleando máquina de vectores de soporte, para ello lo primero a resolver fue la determinación de la función “kernel” apropiada, así como los parámetros de sintonía de dicho “kernel”, para ello se evaluaron varias topologías (lineal, RBF, Polinomial, Gausiana) las cuales se contrastaron, en base a la velocidad de convergencia y exactitud en el diagnóstico, eligiendo de esta forma la que arrojo mejor desempeño. Del conjunto de datos totales se tomó un grupo para el entrenamiento de la máquina y otro para la fase de validación. Como plataforma para desarrollar el clasificador se utilizó el programa MATLAB.

Etapa V: Validación del clasificador binario diseñado para determinar el estado de funcionamiento de los motores de Inducción

En esta última etapa se validó el clasificador diseñado para el análisis de los efectos que tiene la aplicación de la transformada de Wavelet y la máquina de vectores de soporte como técnicas de procesamiento de señales para clasificar.

3.3 TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

La recolección de datos para la realización de esta investigación se basó en primer lugar en la investigación documental de publicaciones especializadas, textos y revistas. De igual forma, se realizaron entrevistas con investigadores del tema pertenecientes a la Universidad de Carabobo con el propósito de obtener información que permitiera orientar la investigación de la mejor manera.

Así mismo la autora, contó con dos posibles formas para obtener la data, la primera opción fue evaluar la data disponible de trabajos realizados en motores de inducción en el laboratorio de mantenimiento preventivo de la facultad de ingeniería de la Universidad de Carabobo y en caso de que la misma no sea adecuada, se procederá a realizar en el laboratorio mencionado las mediciones de las variables eléctricas seleccionadas del motor.

3.4 TÉCNICAS DE PROCESAMIENTO Y ANÁLISIS DE DATOS

En esta investigación se agrupó la data obtenida en dos categorías: motores buenos y motores con falla. A cada una se le aplicó la transformada de Wavelet considerando varios niveles de descomposición, con los coeficientes obtenidos aquí, se calcularan los momentos de orden superior, finalmente se analizan los valores encontrados y se extrajeron las características de cada grupo. Seguidamente, se le suministró a la máquina de vectores de soporte las características que arrojaron cada grupo, las cuales sirvieron para entrenarla. Una vez que la maquina fue entrenada quedo lista para clasificar y estimar el estado del motor para una entrada determinada.

Para el procesamiento y análisis de los datos se utilizaron dos herramientas del software matemático MATLAB, la primera de ellas es el toolbox de Wavelet, la cual dispone de funciones que aplicadas en la data permiten determinar los coeficientes de detalle y aproximación para diferentes niveles de descomposición y la segundo el toolbox de MVS, el cual cuenta con funciones para calcular los parámetros de la máquina de vectores, clasificar, graficar las salidas y evaluar el error producido en la estimación.

CAPITULO IV

DISEÑO DEL CLASIFICADOR BINARIO PARA DETECTAR EL ESTADO DE FUNCIONAMIENTO DE LOS MOTORES DE INDUCCIÓN

Los motores de inducción son los equipos eléctricos de mayor aplicación en la industria. La importancia que tienen en los diferentes procesos productivos hace necesario asegurar su continuidad operativa. La detección anticipada de una posible causa de falla permite planear, con fines de mantenimiento, la remoción programada del motor mediante la detección oportuna de fallas incipientes. La detección anticipada de una posible causa de falla permite planear, con fines de mantenimiento, la remoción programada del motor y reducir pérdidas de producción. Una de las técnicas empleadas actualmente para conocer a tiempo el estado de funcionamiento de los motores, es la denominada “Mantenimiento Predictivo”, en la cual, midiendo las variables características del motor como la corriente estática, es posible predecir a tiempo si el motor está presentando algún problema.

De esta manera, conociendo el estado actual y la evolución histórica de las variables del motor, pueden predecirse fallas en estado prematuro. Más aún, las técnicas de diagnóstico en línea permiten realizar las tareas de mantenimiento predictivo sin necesidad de sacar las máquinas de servicio, dando lugar a que durante las paradas planificadas del proceso se efectúen los cambios y reparaciones necesarias en los motores.

En el presente capítulo se detalla el diseño de una herramienta alternativa que permitirá determinar el estado de funcionamiento de los motores de inducción a partir de información obtenida de las corrientes estatoricas y mediante la aplicación de la Transformada de Wavelet y la Máquina de Vectores de Soporte.

4.1. DATA SELECCIONADA PARA REALIZAR LOS ENSAYOS

Dentro de las fallas que afectan el funcionamiento del motor de inducción, las más frecuentes son las producidas en los rodamientos, como consecuencia del permanente movimiento y variados estados de carga a los que están sometidos los mismos. Las estadísticas pueden variar un poco entre los autores pero la distribución de las fallas es en general la mostrada en la figura 4.1

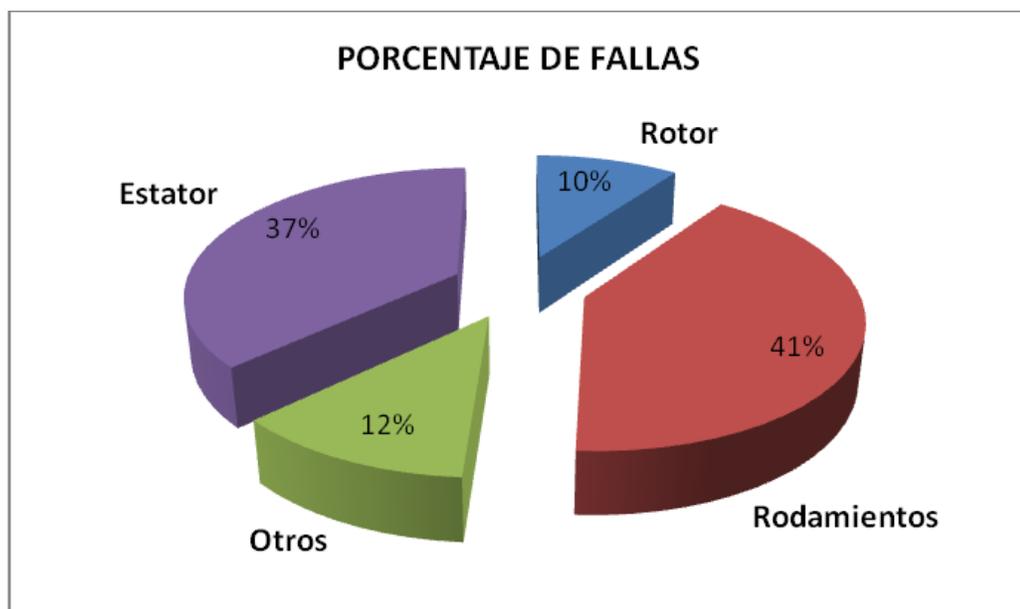


Fig 4.1. Porcentaje de fallas de componentes de motores eléctricos.

Fuente: A. Castellino, P. Donolo, G. Bossio, G. Garcia. Octubre 2007.

Como se puede observar en la figura 4.1 el porcentaje más alto (41%) corresponde a las fallas en los rodamientos, de allí, que para efectos de esta investigación se seleccionó como data aquella que tomara en cuenta este tipo de fallas.

En uno de los trabajos realizados en el laboratorio de mantenimiento preventivo de la Universidad de Carabobo titulado “Detección de fallas en los cojinetes del motor de inducción a través del análisis espectral de la corriente aplicando máquinas de vectores de soporte” se realizaron mediciones de las corrientes y voltajes en motores de inducción en buen estado y en motores con fallas en los rodamiento, como esta data se ajusta a las necesidades de investigación planteadas por la autora se tomó la misma para el abordaje de este proyecto.

A continuación se describe brevemente el proceso seguido para la obtención de la data, realizado en la investigación mencionada en el párrafo anterior, la cual fue desarrollada por Gonzales R., y Muñoz J.:

A. Esquema de montaje del banco de mediciones de las corrientes y voltajes de los motores de inducción.

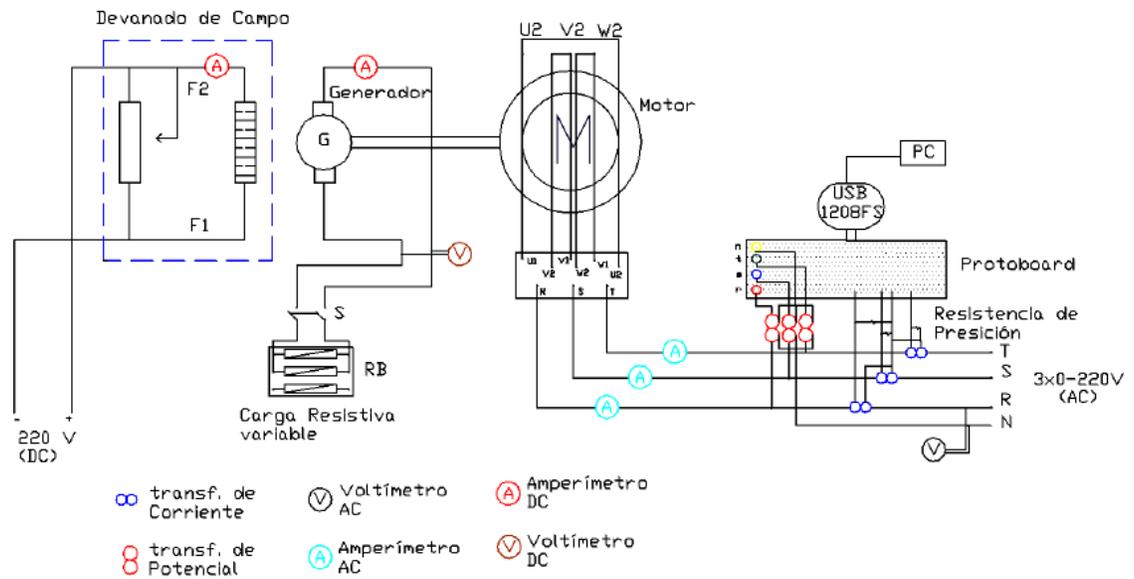


Figura 4.2. Esquema de montaje para la medición del voltaje y la corriente de los motores

Fuente: Gonzales R., Muñoz J., Junio 2009

B. Fallas introducidas en los motores de inducción

Para la simulación de las fallas en las pistas internas y externas de los rodamientos de los motores de inducción se tomaron dos rodamientos en buen estado y se le realizó una perforación en la pista interna de uno de los rodamientos y en la pista externa del otro, para ello se utilizó una mecha WIDEA 3mm de diámetro. Por otra parte la falla en los elementos rodantes consistió en tomar un rodamiento en buen

estado y lubricarlo con una grasa que contiene virutas de hierro, lo cual genera roce y desgasta el rodamiento a medida que el motor aumenta la velocidad.

C. Condiciones de operación de los motores de inducción

Para la medición de las señales eléctricas en los motores se desarrollaron los ensayos en los siguientes niveles de carga:

- Carga nominal: Corriente de 7A
- 5/7 de carga nominal: Corriente de 5A

D. Obtención de las señales de los motores de inducción en condiciones de falla y en buen estado:

Para medir las señales eléctricas de los motores de inducción se empleó el esquema de adquisición desarrollado en LabVIEW. Inicialmente se realizó la medición de las señales eléctricas para los motores en condiciones óptimas de rodamientos y posteriormente se realizó la medición para las condiciones de fallas en los rodamientos señaladas a continuación:

- Falla en pista interna
- Falla en pista externa
- Falla en los elementos rodantes

4.2. APLICACIÓN DE LA TRANSFORMADA DE WAVELET Y LA MÁQUINA DE VECTORES DE SOPORTE A LA DATA SELECCIONADA

En los últimos tiempos se ha incrementado la búsqueda de técnicas que permitan diagnosticar el estado de funcionamiento de los motores. En la presente investigación se combinan la transformada de Wavelet y las máquinas de vectores de soporte para lograr crear una herramienta que permita clasificar o diagnosticar el estado de los motores de inducción.

Para definir el clasificador más óptimo se realizaron diferentes ensayos considerando variaciones en los parámetros de la transformada de Wavelet TW y de la máquina de vectores de soporte SVM. En el caso de SVM se realizaron los ensayos modificando su función Kernel y sus parámetros de sintonía, por otro lado, para la TW se varió la Wavelet Madre y el nivel de descomposición. En definitiva, una serie de parámetros fueron ajustados adecuadamente hasta conseguir resultados satisfactorios, para ello fue necesario evaluar el clasificador de forma que al cambiar un parámetro por ejemplo de la Transformada Wavelet se pudiera observar su efecto sobre el rendimiento de éste. A continuación se describe el proceso de experimentación llevado a cabo:

4.2.1 PROCESO DE EXPERIMENTACIÓN

1. Se seleccionó aleatoriamente una muestra (240) del total de los datos disponible (720) para realizar las pruebas, esta muestra se separó en dos, una parte para entrenamiento (160) y otra para validación (80).

2. Se aplicó a la data seleccionada la transformada de Wavelet, para ello se trabajó con la función 'wavedec' de MATLAB, considerando hasta 2 niveles de descomposición (ver fig. 4.2) y diferentes wavelet madre (Los tipos de Wavelet utilizadas en esta investigación fueron: Haar, Daubechies, Coiflets y Symlets), luego se utilizó las funcion 'appcoef' para obtener los coeficientes de aproximación, vector CA (CA1: Coeficientes de Aproximación del nivel de descomposición 1, CA2: Coeficientes de Aproximación del nivel de descomposición 2) y la funcion 'detcoef' para obtener los coeficientes de detalles, vector CD (CD1: Coeficientes de Detalle del nivel de descomposición 1, CD2: Coeficientes de Detalle del nivel de descomposición 2).

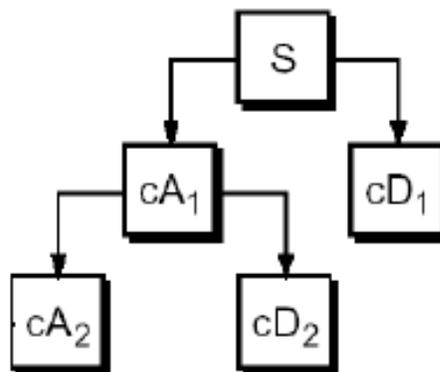


Fig 4.3. Árbol de descomposición Wavelet considerado

Fuente: Tutorial introductorio a la teoría de Wavelet

```

dataA7A                                     %Funcion para cargar la data
data=cat(2,FB,PE,PI,S);                     %Crea el vector data formado
for i=1:120
[CS(:,i),LS(:,i)]=wavedec(data(1:1000,i),2,'sym5'); %Se aplica la T. de Wavelet a la data
CD1(:,i)=detcoef(CS(:,i),LS(:,i),1);         %Calcula los coef. de detalle de nivel 1
CD2(:,i)=detcoef(CS(:,i),LS(:,i),2);         %Calcula los coef. de detalle de nivel 2
CA1(:,i)=appcoef(CS(:,i),LS(:,i), 'sym5',1); %Calcula los coef. de aprox. de nivel 1
CA2(:,i)=appcoef(CS(:,i),LS(:,i), 'sym5',2); %Calcula los coef. de aprox. de nivel 2
end
%FB= Falla en bola, PE= Falla en pista externa
%PI =Falla en pista interna, S =sano

```

Fig 4.4. Calculo de los coeficiente de aproximación y detalle en Matlab

Fuente: Hernández, E. (2013)

3. Seguidamente, a los coeficientes calculados en el paso anterior se le calcularon los momentos de diferente orden utilizando la función ‘moment’ de MATLAB. Se ensayo hasta el momento de orden 20.

```

for i = 1:20                               %Calcula los momentos hasta el orden
momentosCD1(i,:)=moment(CD1,i);           %20 a los coeficientes CA y CD
momentosCD2(i,:)=moment(CD2,i);
momentosCA1(i,:)=moment(CA1,i);
momentosCA2(i,:)=moment(CA2,i);
end

```

Fig. 4.5. Calculo de los momentos a los coeficientes CD y CA en matlab.

Fuente: Hernández, E. (2013)

4. Se seleccionaron dos momentos de cada muestra de corriente y con ellos se armaron los vectores de entrenamiento y validación que serían introducidos a la máquina de vector de soporte.

5. Para la aplicación de la máquina de vector de soporte se utilizó una librería de funciones ya creada. Esta librería es un toolbox de matlab denominado SVM y es de uso libre y gratuito el cual puede ser descargado en: <http://www.aic.uniovi.es/SSII/P11/svm.zip>. Con la mencionada aplicación instalada, para comenzar su utilización se escribe desde la línea de comando de Matlab 'iuclass', con lo que se visualiza el entorno grafico de la aplicación.

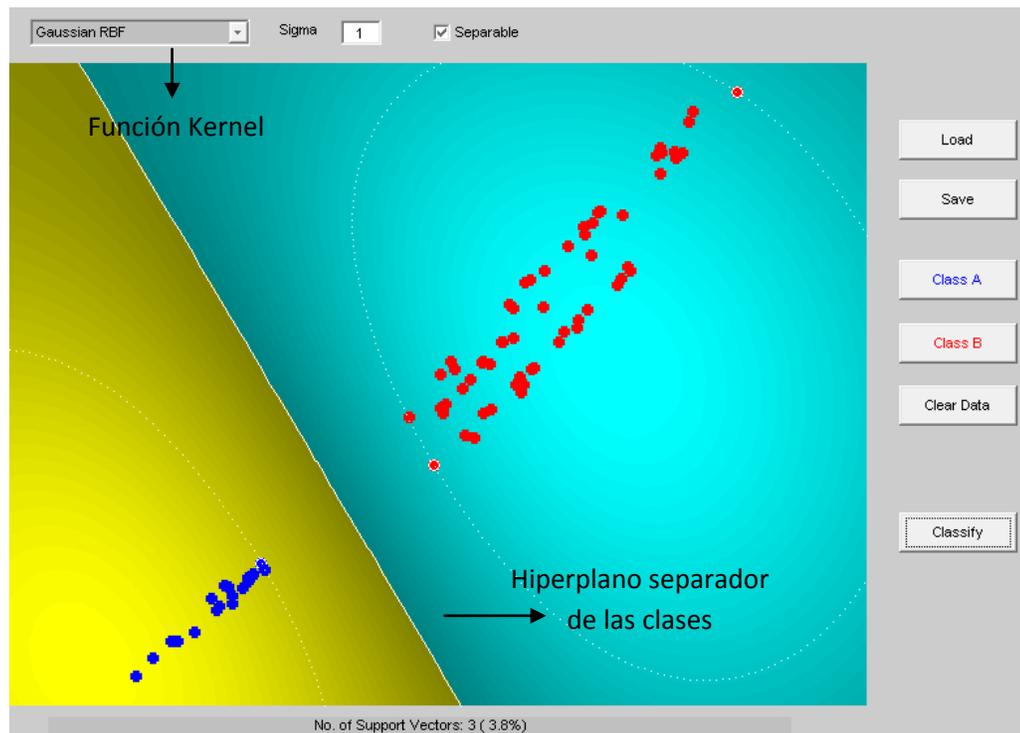


Fig. 4.6. Entorno grafico de la aplicación de MVS

Luego se selecciona la función Kernel y los parámetros asociados a ella, se carga la data con el botón *load* y se pulsa *classify*. Con esto se entrena el sistema y en la interfaz se muestra el resultado, donde se puede apreciar el hiperplano que separa

las clases. Las funciones Kernel consideradas en esta investigación fueron: **Lineal**: El único parámetro a ajustar fue C . **Polinomial**: Aquí se ajustaron los parámetros C , γ , grado del polinomio y término independiente a_0 . **Base radial**: los parámetros a ajustar fueron C y γ .

6. Se repitieron los pasos 2, 3, 4 y 5 hasta lograr encontrar los parámetros de la TW, de los momentos y de la MVS que permitieran obtener el clasificador más óptimo. Se realizaron 8 tipos de ensayos considerando las dos condiciones de funcionamiento del motor mencionadas anteriormente, quedando distribuidos de la siguiente manera:

a) Motor operando a 5A (5/7 de su plena carga)

- Ensayo I(EA-PB): Entrenamiento con datos del motor A y prueba con datos del motor B
- Ensayo II(EB-PA): Entrenamiento con datos del motor B y prueba con datos del motor A
- Ensayo III (EA-PA): Entrenamiento con datos del motor A y prueba con datos del motor A
- Ensayo IV (EB-PB): Entrenamiento con datos del motor B y prueba con datos del motor B

b) Motor operando a 7A (Plena carga)

- Ensayo V (EA-PB): Entrenamiento con datos del motor A y prueba con datos del motor B
- Ensayo VI (EB-PA): Entrenamiento con datos del motor B y prueba con datos del motor A
- Ensayo VII (EA-PA): Entrenamiento con datos del motor A y prueba con datos del motor A
- Ensayo VIII (EB-PB): Entrenamiento con datos del motor B y prueba con datos del motor B

Parámetro de evaluación del clasificador

Para evaluar al clasificador se consideraron los parámetros que a continuación se detallan:

Tiempo de Procesamiento: Periodo de tiempo empleado por el clasificador desde el momento en que la señal ingresa hasta que la clasificación es realizada. Este tiempo involucra tres tiempos de procesamiento principales: el de la aplicación de la Transformada Wavelet, el del cálculo de los momentos y el de la evaluación de la función de clasificación por medio de la MVS. Evidentemente este valor depende fundamentalmente del hardware utilizado.

Tasa de Éxito o porcentaje de acierto: Indica el porcentaje de coincidencias entre las predicciones realizadas por el clasificador y la clasificación esperada. Este fue el parámetro más importante a considerar para la selección de los parámetros definitivos del clasificador.

CAPÍTULO V

ANÁLISIS E INTERPRETACIÓN DE LOS RESULTADOS

Con la finalidad de cumplir con los objetivos planteados al inicio de la investigación, se realizaron un conjunto de pruebas donde a los datos de la corrientes estatoricas en el tiempo, se les aplico el clasificador diseñado para determinar el estado de funcionamiento del motor, y así comprobar la eficiencia del modelo generado (Clasificador binario). Se muestra inicialmente la tabla resumen de los resultados obtenidos, considerando como data original aquella a la que no se le aplico la Transformada de Wavelet y de este modo poder evaluar el beneficio que aporta al clasificador la aplicación de dicha técnica sobre la data antes de introducirla a la máquina de vectores de soporte.

GRUPO I: Motor operando a 5A (5/7 de su plena carga)

En este ensayo a la data de corriente estatotica en el tiempo para la condición de 5A se le aplico la TW, utilizando como Wavelet madre la db5, de donde se tomaron los coeficientes de aproximación 1 y a los cuales se le determinaron los momentos de orden 12 y 20. El tamaño de la data es de 120, de los cuales se tomaron 80 para la etapa de entrenamiento y 30 para la fase de prueba, finalmente estos momentos se aplicaron a la MVS utilizando como función kernal la 'rbf'. Lo indicado

anteriormente define las características del clasificador más óptimo y los mismos fueron determinados después de realizar diferentes ensayos en los cuales se modificaban los parámetros de la transformada de Wavelet, de los momentos y de la máquina de vectores hasta lograr alcanzar el mayor porcentaje de acierto.

Condición	ENSAYO	DATOS ORIGINALES (sin TW)		APLICANDO WAVELET	
		Nº de errores	% de acierto	Nº de errores	% de acierto
5A	EA_PB	0	100	0	100
	EB_PA	5	93,75	2	97,5
	EA_PA	0	100	0	100
	EB_PB	0	100	0	100

Tabla 5.1. Porcentaje de acierto del clasificador para la condición de operación de 5A

GRUPO II: Motor operando a 7A (Plena carga)

En este grupo solo se modifica la data, considerando aquí la corriente estatorica para la condición de operación de plena del motor. Los parámetros del clasificador siguen siendo: wavelet madre db5, coeficiente de aproximación 1, momentos 12 y 20 y MVS con kernel igual a ‘rbf’.

Condición	ENSAYO	DATOS ORIGINALES		APLICANDO WAVELET	
		Nº de errores	% de acierto	Nº de errores	% de acierto
7A	EA_PB	10	87,5	2	97,5
	EB_PA	1	98,75	0	100
	EA_PA	6	92,5	3	96,25
	EB_PB	0	100	0	100

Tabla 5.2. Porcentaje de acierto del clasificador para la condición de operación de 7A

ANÁLISIS DE LAS PRUEBAS DESARROLLADAS

El grupo de pruebas realizadas se enfocaron en la generación de un clasificador basado en SVM y TW, queal ser entrenado con un conjunto de datos de corrientesestatoricas asociados al motor con rodamientosen buen y mal estado, podría predecir la condición de funcionamiento asociada a los datosintroducidos en la fase de prueba. El análisis de los resultados obtenidos se agrupa en dos casos:

- **Caso I:** Se encuentran las pruebas en las cuales se realizó el entrenamiento con los datosasociados a un motor y la predicción con los datos pertenecientes a otro motor,

esto permitió medir la capacidad de predicción del modelo frente a datos pertenecientes a otro motor que no intervinieron en la etapa de entrenamiento. En las condiciones de 5/7 carga y carga nominal se obtuvieron porcentajes de predicción mayores al 97 por ciento, lo cual demuestra la gran capacidad del modelo generado para la detección de fallas en estado incipiente a través del análisis de las corrientes estatoricas del motor.

- **Caso I:** Aquí se encuentran las pruebas en las cuales se realizó el entrenamiento y la predicción con los datos pertenecientes a un mismo motor, en esta etapa se apreció el comportamiento del modelo frente a datos pertenecientes al mismo motor pero que no intervinieron en el entrenamiento. Se observó que en la mayoría de los casos el modelo generado presenta una capacidad de predicción del 100 por ciento, a excepción de los datos pertenecientes al ensayo VII en el cual se obtuvo 96,25 por ciento de acierto. No obstante, se demuestra un error de predicción bajo en el reconocimiento de patrones que pertenecen a un mismo motor. En términos generales se puede decir que la clasificación basada en SVM y TW es aplicable a la detección de fallas incipientes en los cojinetes del motor de inducción, al tomar como patrones de entrenamiento y prueba la data asociada a las corrientes estatoricas.

Los resultados obtenidos en la presente investigación permiten asegurar que son un método efectivo y exitoso para monitorear la condición de funcionamiento de los motores eléctricos y resulta una herramienta valiosa para fundamentar programas

de mantenimiento de tipo preventivo y predictivo. Se verificó igualmente la utilidad de la Transformada Wavelet como una herramienta adicional, pues en 4 de los 8 ensayos se mejoró el porcentaje de acierto gracias a la aplicación de esta herramienta y en ningún caso arrojó un porcentaje menor.

Adicionalmente, se observó que el cálculo de los momentos de la señal de corriente es un parámetro apropiado para determinar el estado de los motores pues al aplicar los mismos a la MVS se logró separar fácilmente las clases y predecir con un elevado porcentaje de acierto la condición de funcionamiento del motor.

En cuanto al tiempo de procesamiento de los datos se puede apreciar en la simulación de los ensayos que el mismo fue de 0,3s para la MVS y de menos de 4s para el cálculo de los momentos y la transformada de Wavelet, el cual resulta en un tiempo de respuesta rápido. Es importante considerar que la evaluación de los Tiempos de procesamiento está fuertemente asociada a la capacidad de cálculo del hardware donde se ejecuta la aplicación. Para los resultados que se presentaron se utilizó un computador con procesador Pentium IV con frecuencia de trabajo de 2.1 Giga Hertz y con 512 MB de RAM. A continuación se muestran los resultados obtenidos en cada ensayo:

ENSAYO I: ENTRENAMIENTO CON LOS DATOS DEL MOTOR A Y PRUEBA CON LOS DATOS DEL MOTOR B, CONDICIÓN DE CARGA IGUAL A 5 A.

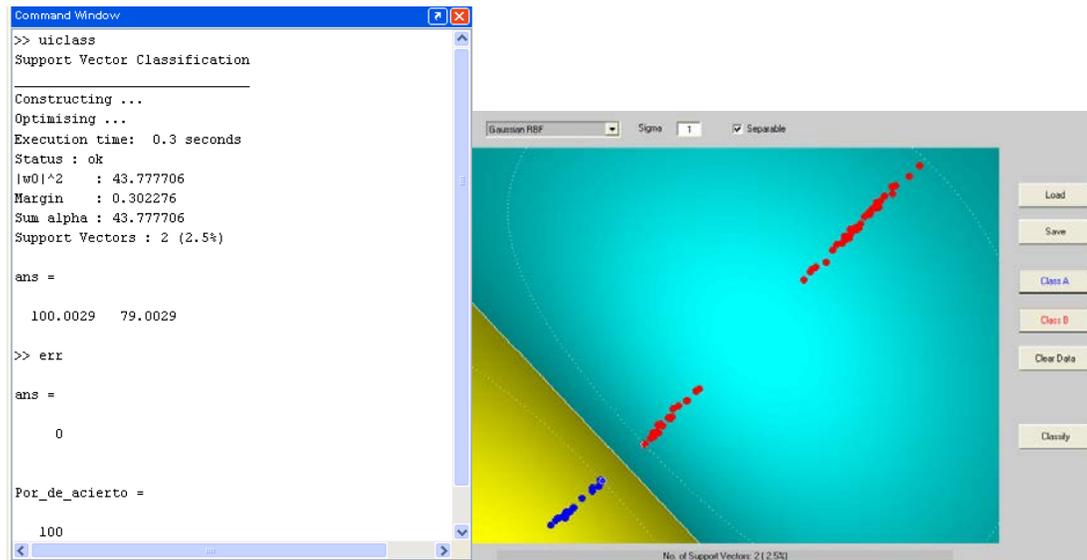


Fig. 5.1 Fase de entrenamiento y prueba correspondiente al ensayo I

ENSAYO II: ENTRENAMIENTO CON LOS DATOS DEL MOTOR B Y PRUEBA CON LOS DATOS DEL MOTOR A, CONDICIÓN DE CARGA IGUAL A 5 A.

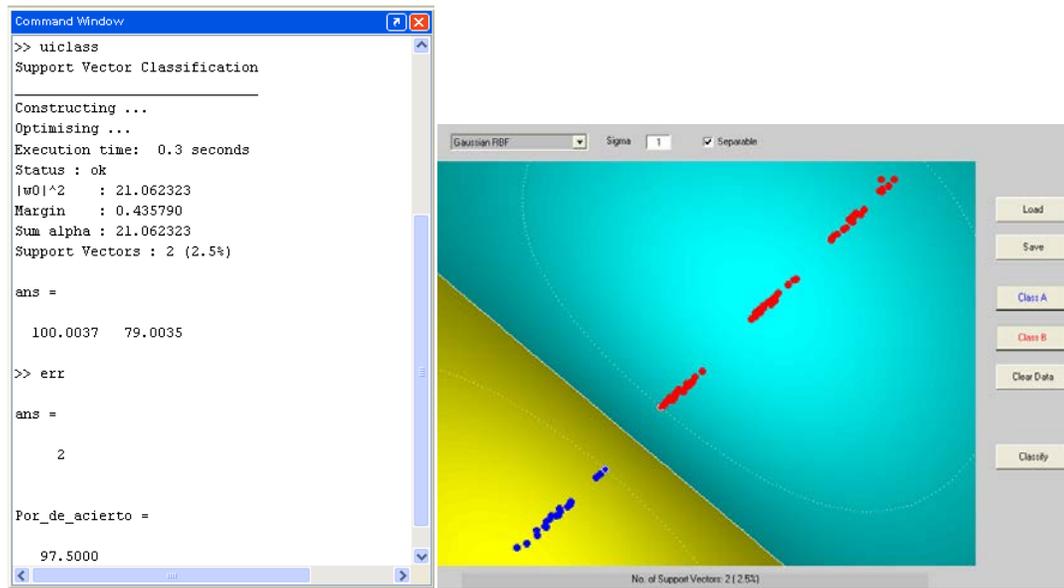


Fig. 5.2 Fase de entrenamiento y prueba correspondiente al ensayo II

ENSAYO III: ENTRENAMIENTO Y PRUEBA CON LOS DATOS DEL MOTOR A, CONCONDICIÓN DE CARGA IGUAL A 5A.

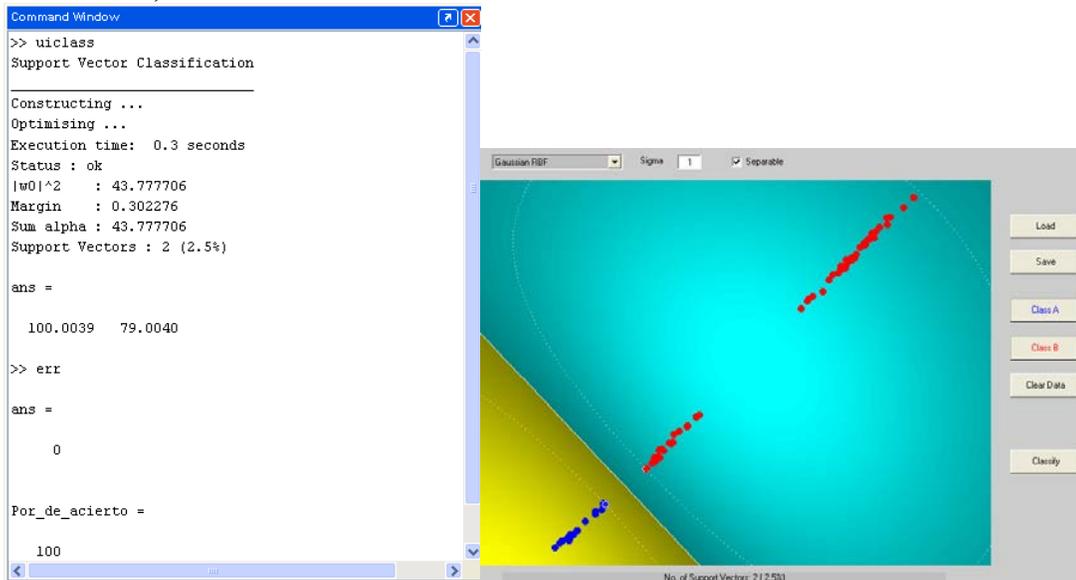


Fig. 5.3 Fase de entrenamiento y prueba correspondiente al ensayo III

ENSAYO IV: ENTRENAMIENTO Y PRUEBA CON LOS DATOS DEL MOTOR B, CONCONDICIÓN DE CARGA IGUAL A 5A.

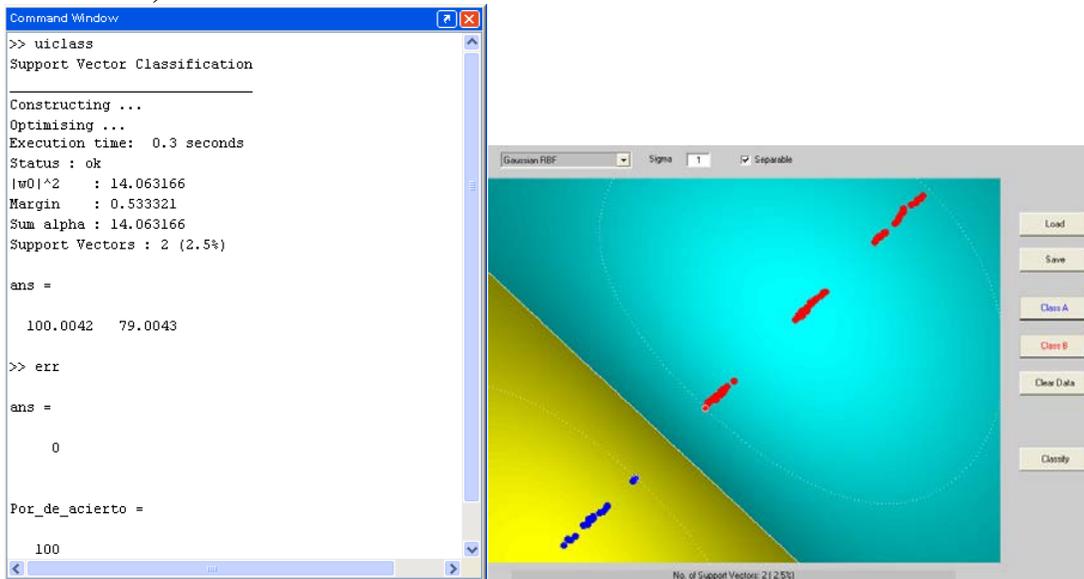


Fig. 5.4 Fase de entrenamiento y prueba correspondiente al ensayo IV

ENSAYO V: ENTRENAMIENTO CON LOS DATOS DEL MOTOR A Y PRUEBA CON LOS DATOS DEL MOTOR B, PARA CORRIENTE NOMINAL.

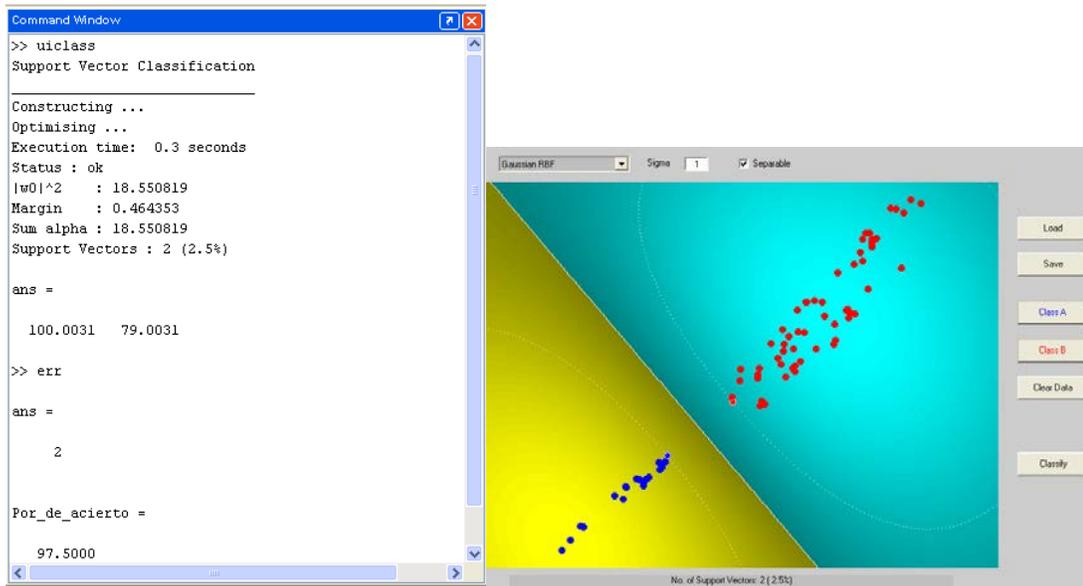


Fig. 5.5 Fase de entrenamiento y prueba correspondiente al ensayo V

ENSAYO VI: ENTRENAMIENTO CON LOS DATOS DEL MOTOR B Y PRUEBA CON LOS DATOS DEL MOTOR A, PARA CORRIENTE NOMINAL.

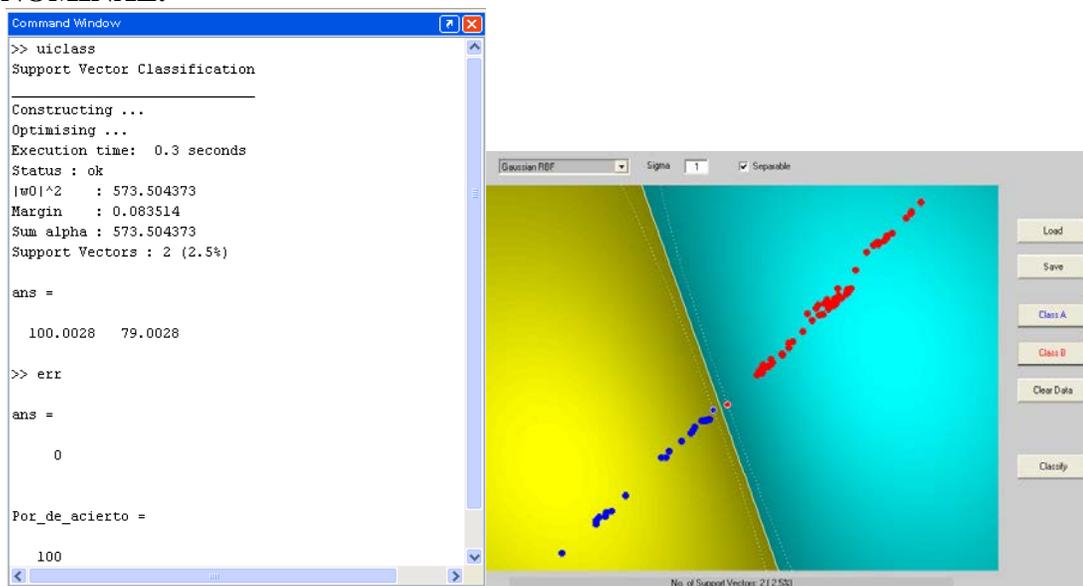


Fig. 5.6 Fase de entrenamiento y prueba correspondiente al ensayo VI

ENSAYO VII: ENTRENAMIENTO Y PRUEBA CON LOS DATOS DEL MOTOR A, PARACORRIENTE NOMINAL.

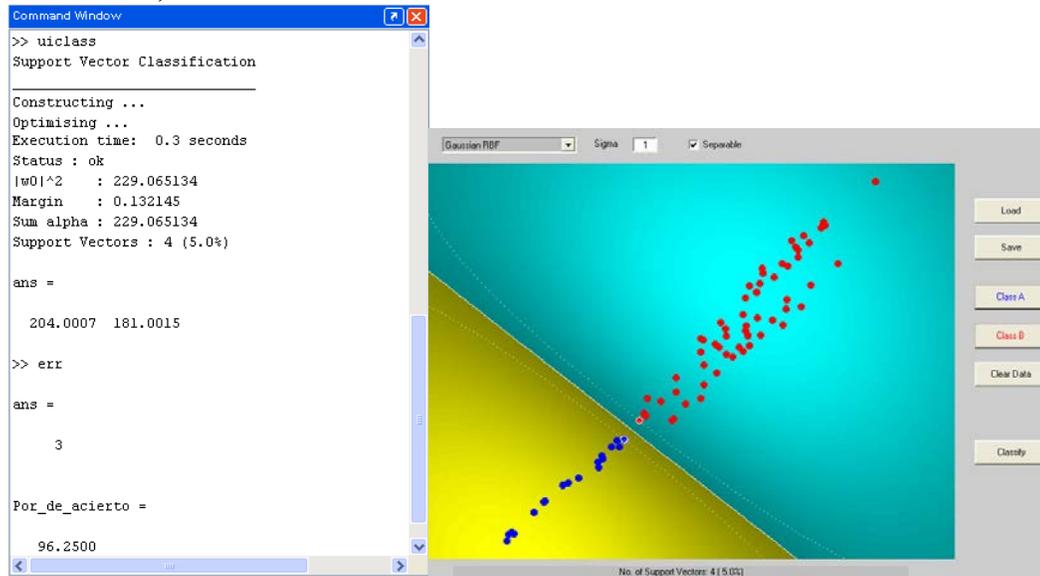


Fig. 5.7 Fase de entrenamiento y prueba correspondiente al ensayo VII

ENSAYO VIII: ENTRENAMIENTO Y PRUEBA CON LOS DATOS DEL MOTOR B, PARACORRIENTE NOMINAL.

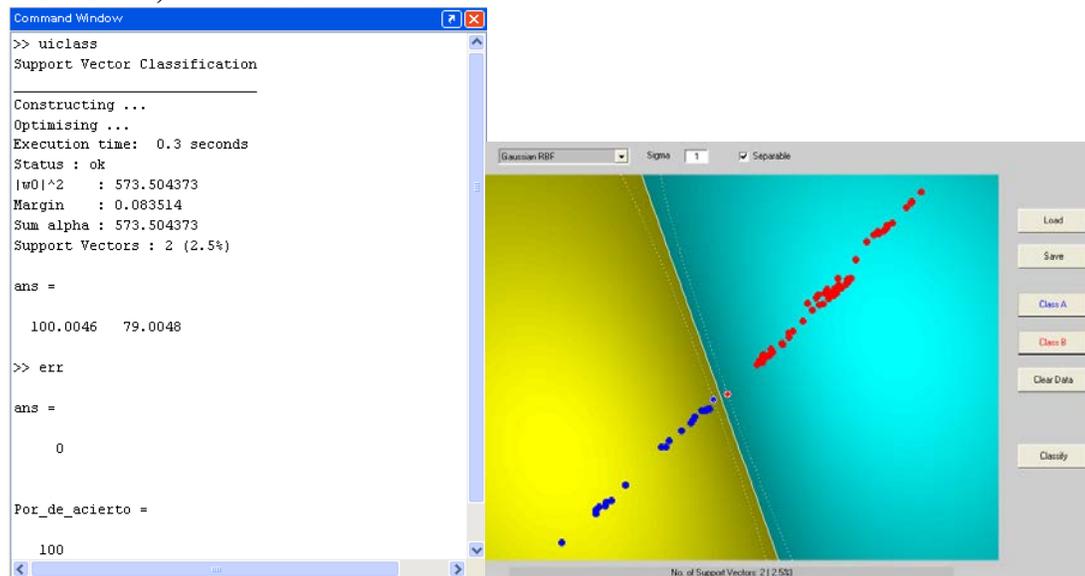


Fig. 5.8 Fase de entrenamiento y prueba correspondiente al ensayo VIII

A continuación se muestran los resultados correspondientes a los 8 ensayos anteriores pero sin aplicarle a la data original la transformada de Wavelet antes del cálculo de los momentos.

ENSAYO I (Sin TW): ENTRENAMIENTO CON LOS DATOS DEL MOTOR A Y PRUEBA CON LOS DATOS DEL MOTOR B, CONDICIÓN DE CARGA IGUAL A 5A.

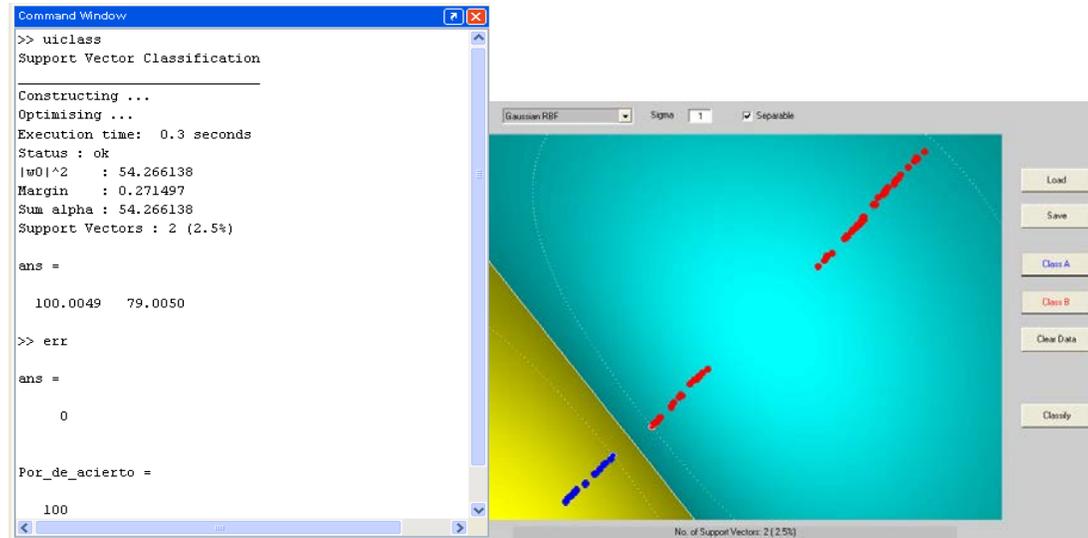


Fig. 5.9 Fase de entrenamiento y prueba correspondiente al ensayo I sin TW.

ENSAYO II (Sin TW): ENTRENAMIENTO CON LOS DATOS DEL MOTOR B Y PRUEBA CON LOS DATOS DEL MOTOR A, CONDICIÓN DE CARGA IGUAL A 5A.

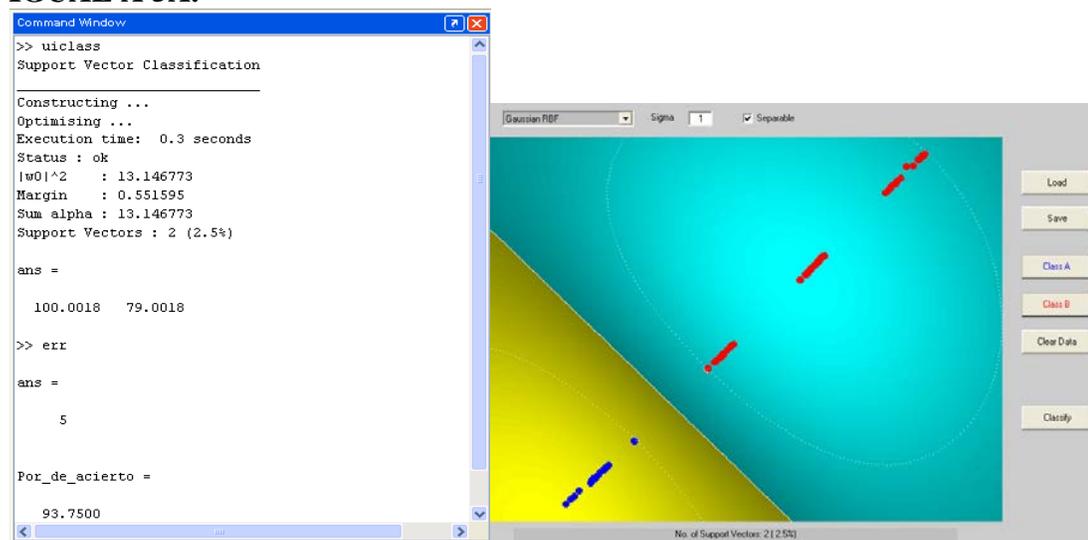


Fig. 5.10 Fase de entrenamiento y prueba correspondiente al ensayo II sin TW.

ENSAYO III (Sin TW): ENTRENAMIENTO Y PRUEBA CON LOS DATOS DEL MOTOR A, CONCONDICIÓN DE CARGA IGUAL A 5A.

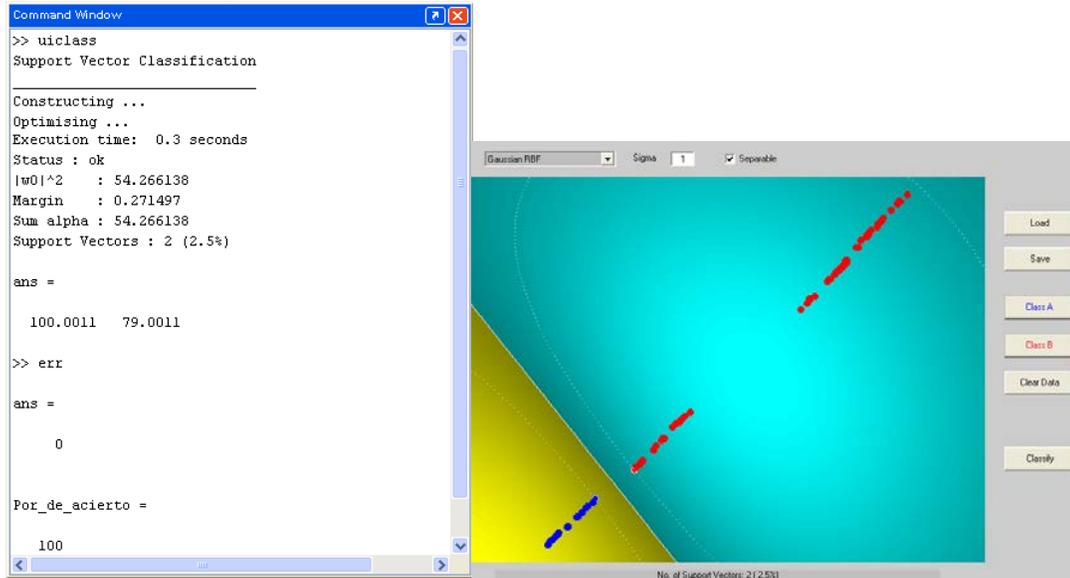


Fig. 5.11 Fase de entrenamiento y prueba correspondiente al ensayo III sin TW.

ENSAYO IV (Sin TW): ENTRENAMIENTO Y PRUEBA CON LOS DATOS DEL MOTOR B, CONCONDICIÓN DE CARGA IGUAL A 5A.

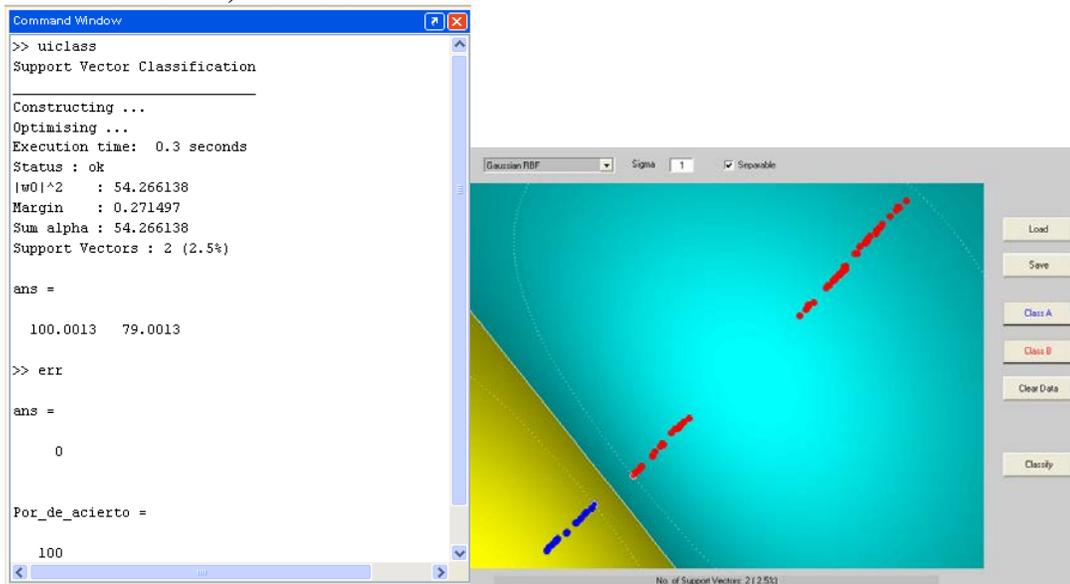


Fig. 5.12 Fase de entrenamiento y prueba correspondiente al ensayo IV sin TW.

ENSAYO V (Sin TW): ENTRENAMIENTO CON LOS DATOS DEL MOTOR A Y PRUEBA CON LOS DATOS DEL MOTOR B, PARA CORRIENTE NOMINAL

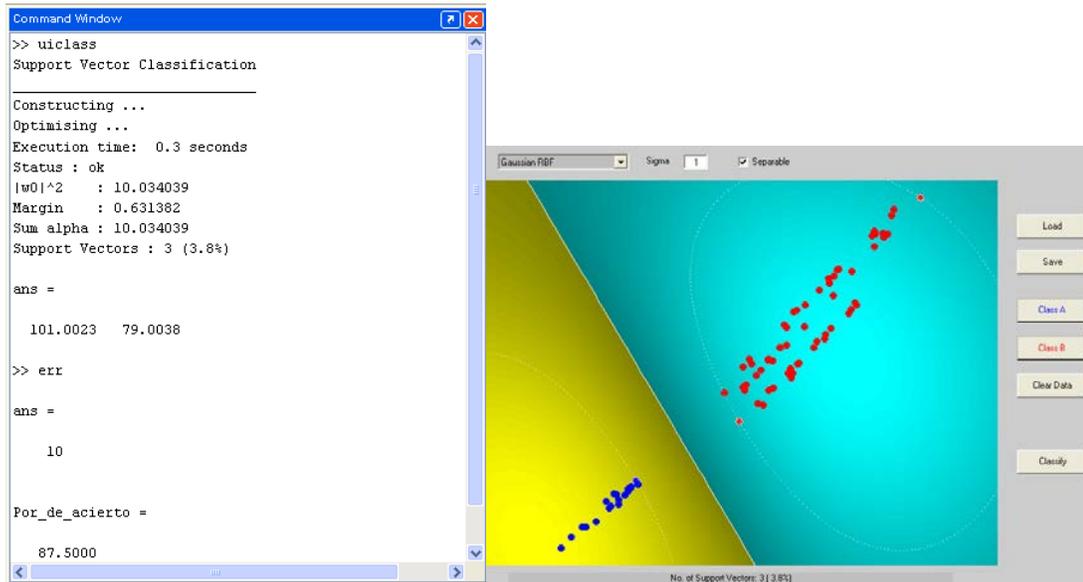


Fig. 5.13 Fase de entrenamiento y prueba correspondiente al ensayo V sin TW.

ENSAYO VI (Sin TW): ENTRENAMIENTO CON LOS DATOS DEL MOTOR B Y PRUEBA CON LOS DATOS DEL MOTOR A, PARA CORRIENTE NOMINAL

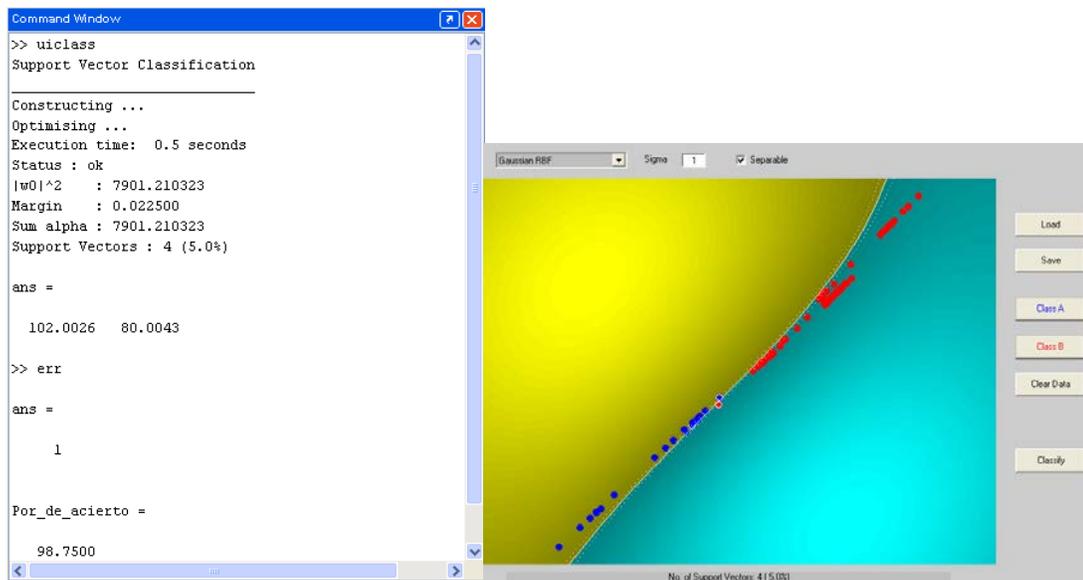


Fig. 5.14 Fase de entrenamiento y prueba correspondiente al ensayo VI sin TW.

ENSAYO VII (Sin TW): ENTRENAMIENTO Y PRUEBA CON LOS DATOS DEL MOTOR A, PARACORRIENTE NOMINAL.

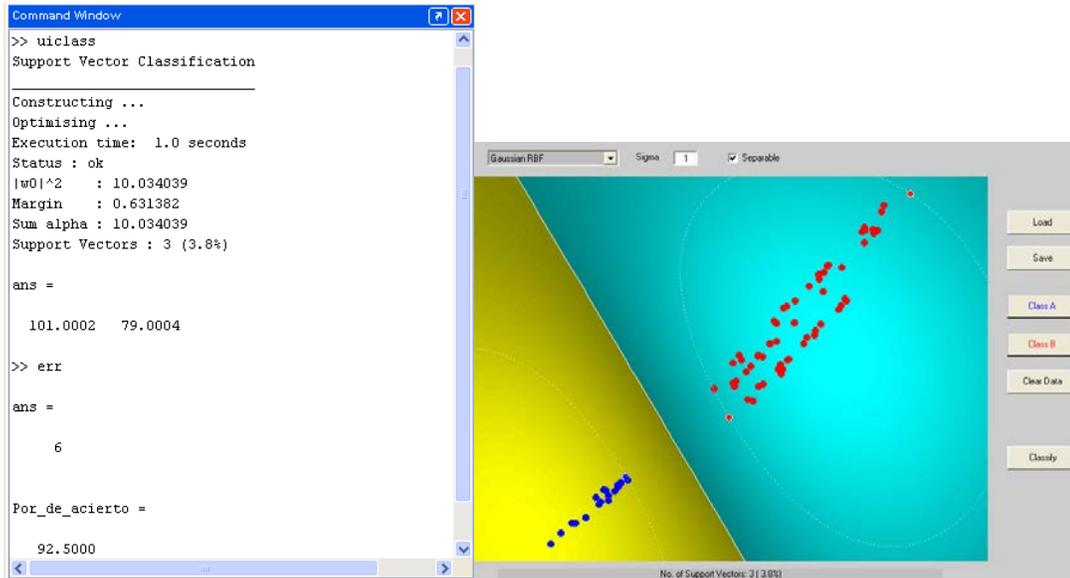


Fig. 5.15 Fase de entrenamiento y prueba correspondiente al ensayo VII sin TW.

ENSAYO VIII (Sin TW): ENTRENAMIENTO Y PRUEBA CON LOS DATOS DEL MOTOR B, PARACORRIENTE NOMINAL.

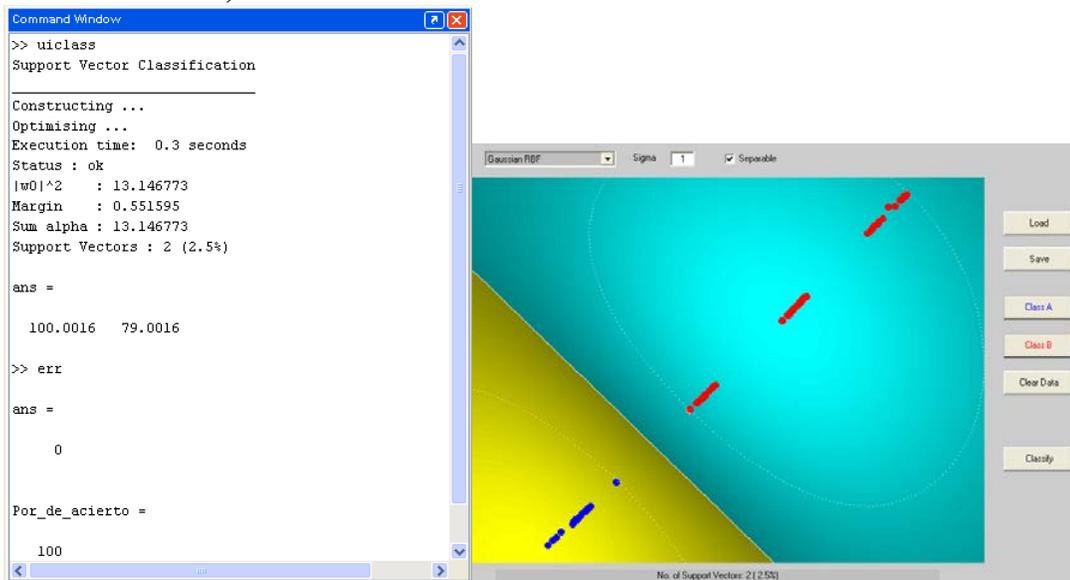


Fig. 5.16 Fase de entrenamiento y prueba correspondiente al ensayo VIII sin TW.

CONCLUSIONES

La presente investigación demostró que la Máquina de vectores de soporte empleada como clasificador es capaz de estimar con alto porcentaje de acierto el estado de funcionamiento de los motores y que su combinación con las TW mejora su rendimiento disminuyendo en la mayoría de los casos el porcentaje de error en la estimación. Adicionalmente se encontró que al extraer los momentos de orden superior a los coeficientes obtenidos de la transformada se logra una mejor capacidad de discriminación entre las diferentes clases.

Los ensayos se realizaron aplicando como entrada la corriente estatorica en el tiempo. Estos ensayos también se realizaron con el flujo de la maquina como entrada al clasificador sin embargo para este caso la capacidad de acierto fue menor, incluso la separación de la clases no fue tan efectiva.

El problema del diseño del diagnosticador del estado de funcionamiento de los motores consistió en la determinación de los parámetros de la TW, la MVS y orden de los momentos que arrojaran mayores porcentajes de acierto en la etapa de validación, para lo que se inició como primer paso con la aplicación de la transformada a la data seleccionada, de donde se obtuvieron los coeficientes de detalle y aproximación a los que se le determino los momento, los cuales constituirían

la información de entrada a la máquina de vectores, finalmente con la estimación del número de errores se iban ajustando sus parámetros.

El análisis de los momentos de los coeficientes de la transformada mostró que los momentos pares generan lo que se considera una buena agrupación y separación de las clases, específicamente en este trabajo se seleccionaron los momentos 12 y 20.

Se verificó la utilidad de la Transformada Wavelet como una herramienta adicional para el procesamiento previo de la data a ser aplicada a la máquina de vectores pues, en el 50% de los ensayos realizados se logró mejorar el porcentaje de acierto en la predicción del estado del motor y en ningún caso se obtuvo un porcentaje menor con respecto a aquellos que no incluían la Transformada de Wavelet. La Wavelet madre que permitieron un mejor diagnóstico fueron la Daubechies-5 y la Symlets-5.

El modelo desarrollado presentó una capacidad de predicción mayor del 96% de acierto. Durante los ensayos se entrenó con los datos asociados a un motor y la predicción con los datos pertenecientes a otro motor, así mismo se entrenó y probó con los datos de un mismo motor pero que no intervinieron en la etapa de entrenamiento. Los resultados obtenidos en la presente investigación permiten asegurar que son un método efectivo y exitoso para predecir la condición de

funcionamiento de los motores eléctricos y resulta una herramienta valiosa para fundamentar programas de mantenimiento de tipo preventivo y predictivo.

BIBLIOGRAFIA

- [1] Verucchi C. y Acosta G. “Técnicas de Detección y Diagnóstico de Fallos en Máquinas Eléctricas de Inducción” (2004)
- [2] Carvajal F., Ramirez J. y Arco L. “Diagnostico en línea y fuera de línea de motores de inducción de baja, media y alta tensión” (1999)
- [3] Valenzuela A, “Sistema de detección de fallas eléctricas en motores del área de Carbón de CVG-VENALUM” de Valenzuela A.(2006)
- [4] A.Nurnberger, W.Pedrycz , R.Kruse, “Data mining tasks and methods: Classification: neural network approaches, Oxford University Press, New York, 2002
- [5] Cercantes J, “Clasificación de grandes conjuntos de datos vía Máquinas de Vectores Soporte y aplicaciones en sistemas biológicos. Instituto Politécnico Nacional, Departamento de computación. Mexico.2009
- [6] Safavian R, Landgrebe D, “A survey of decision tree classifier methodology, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 21, No3, pp. 660-674, 1991
- [7] Marin J, Muñoz P, Ibarque F, “Reconocimientos de comandos de voz usando transformada de wavelet y maquinas de vectores de soporte”. Scientia et Technica año XII, N°31. 2006.
- [8] Rychetsky M, “Algorithms and Architectures for Machine Learning based on Regularized Neural Networks and Support Vector Approaches”, Shaker Verlag, 2001
- [9] Kouro S. y Musalem R, “Tutorial introductorio a la Teoría de Wavelet”. 2001
- [10] Farias G, Santos M, Marron F, Dormido-Canto S. “Determinación de parámetros de la transformada de Wavelet para la clasificación de señales”. Dpto. Informatica y Automatica UNED. 2004
- [11] Rodríguez I, Rubén T, Alves R, “Diagnóstico de Fallas en Motores de Inducción, empleando la Técnica de Vectores de Soporte”. 2009
- [12] Chapman S. Maquinas eléctricas. Segunda edición. 1993

- [13] Seijas C., Caralli A. Villasana S y Arteaga F, “Predicción de hipertensión arterial usando maquinas de vectores de soporte”. Universidad de Carabobo. 2006
- [14] Jiménez C, “Análisis de señales de voz utilizando la Transformada de Wavelet”.Universidad de Carabobo (2004)
- [15] Verucchi C. y Acosta G, “Técnicas de Detección y Diagnóstico de Fallos enMáquinas Eléctricas de Inducción”. (2004)
- [16] Valenzuela A, “Sistema de detección de fallas eléctricas en motoresdel área de Carbón de CVG-VENALUM”.2006
- [17] Carvajal F., Ramirez J. y Arco L,“Diagnostico en línea y fuera de línea de motores de inducción de baja, media y ata tensión” (1999)

ANEXOS

Algoritmo para cargar la data

```
for i=1:30
cadena='C:\MATLAB6p5\toolbox\svm\DataU\MA5A\Bueno\';
cadena=[cadena,'ir_'];
cadena=[cadena,int2str(i)];
cadena=[cadena,'.txt'];
A=load(cadena);
S(:,i)=(A(:,2));
end
for i=1:30
cadena='C:\MATLAB6p5\toolbox\svm\DataU\MA5A\FB\';
cadena=[cadena,'ir_'];
cadena=[cadena,int2str(i)];
cadena=[cadena,'.txt'];
A=load(cadena);
FB(:,i)=(A(:,2));
end
for i=1:30
cadena='C:\MATLAB6p5\toolbox\svm\DataU\MA5A\PI\';
cadena=[cadena,'ir_'];
cadena=[cadena,int2str(i)];
cadena=[cadena,'.txt'];
A=load(cadena);
PI(:,i)=(A(:,2));
end
for i=1:30
cadena='C:\MATLAB6p5\toolbox\svm\DataU\MA5A\PE\';
cadena=[cadena,'ir_'];
cadena=[cadena,int2str(i)];
cadena=[cadena,'.txt'];
A=load(cadena);
PE(:,i)=(A(:,2));
end
clear('A','i','cadena')
```

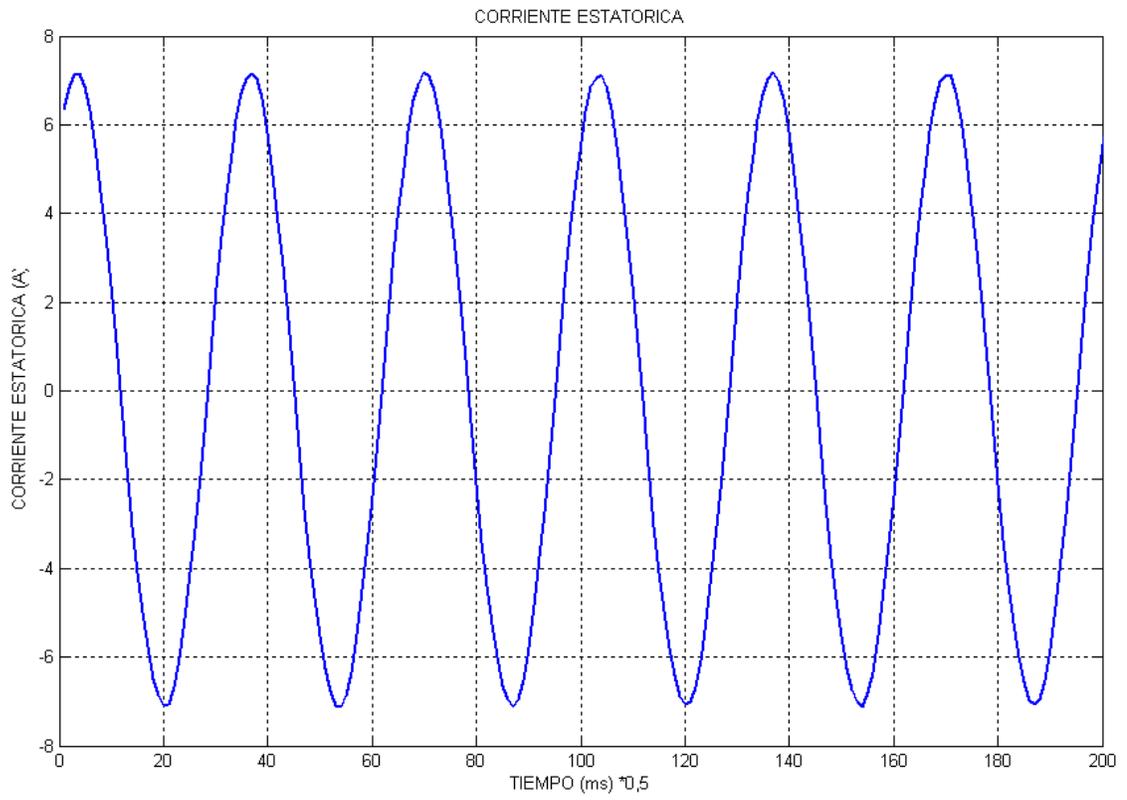
Algoritmo para aplicar la transformada de Wavelet, calcular los momentos y aplicar la maquina de vectores de soporte a la data cargada

```
dataA7A          %Carga la data de entrenamiento
data=cat(2,FB,PE,PI,S); %Crea el vector data
for i=1:120
[CS(:,i),LS(:,i)]=wavedec(data(1:1000,i),3,'db5');
CD1(:,i)=detcoef(CS(:,i),LS(:,i),1);      %Coef. detalle 1
CD2(:,i)=detcoef(CS(:,i),LS(:,i),3);      %Coef. detalle
CA1(:,i)=appcoef(CS(:,i),LS(:,i), 'db5',1); %Coef. aproximacion 1
CA2(:,i)=appcoef(CS(:,i),LS(:,i), 'db5',2); %Coef. aproximacion 2
end
for i = 1:20
momentosCD1(i,:)=moment(CD1,i);
momentosCD2(i,:)=moment(CD2,i);
momentosCA1(i,:)=moment(CA1,i);
momentosCA2(i,:)=moment(CA2,i);
end
X=cat(2,momentosCA1(12:8:20,1:20),momentosCA1(12:8:20,31:50),
momentosCA1(12:8:20,61:80),momentosCA1(12:8:20,91:110));
X=X';
Y=cat(1,-ones(60,1),ones(20,1));
clear('CA1','CA2','CD1','CD','FB','PI','PE','S','LC','CS',
'LS','i','data','momentosCA1','momentosCA2','momentosCD1','momentosCD2')
dataA7A          %Carga la data de prueba
data=cat(2,FB,PE,PI,S); %Crea el vector data
for i=1:120
[CS(:,i),LS(:,i)]=wavedec(data(1:1000,i),3,'db5');
CD1(:,i)=detcoef(CS(:,i),LS(:,i),1);      %Coef. detalle 1
CD2(:,i)=detcoef(CS(:,i),LS(:,i),3);      %Coef. detalle 2
CA1(:,i)=appcoef(CS(:,i),LS(:,i), 'db5',1); %Coef. aproximacion 1
CA2(:,i)=appcoef(CS(:,i),LS(:,i), 'db5',3); %Coef. aproximacion 2
end
for i = 1:20
momentosCD1(i,:)=moment(CD1,i);
momentosCD2(i,:)=moment(CD2,i);
momentosCA1(i,:)=moment(CA1,i);
momentosCA2(i,:)=moment(CA2,i);
end
X1=cat(2, momentosCA1(12:8:20,21:30),momentosCA1(12:8:20,51:60),
momentosCA1(12:8:20,81:90),momentosCA1(12:8:20,111:120));
X1=X1';
Y1=cat(1,-ones(30,1),ones(10,1));
clear('CA1','CA2','CD1','CD2','CD','FB','PI','PE','S','LC','CS',
'LS','i','data','momentosCA1','momentosCA2','momentosCD1','momentosCD2')
C=inf;
p1=1;
p2=0;
ker='rbf';
```

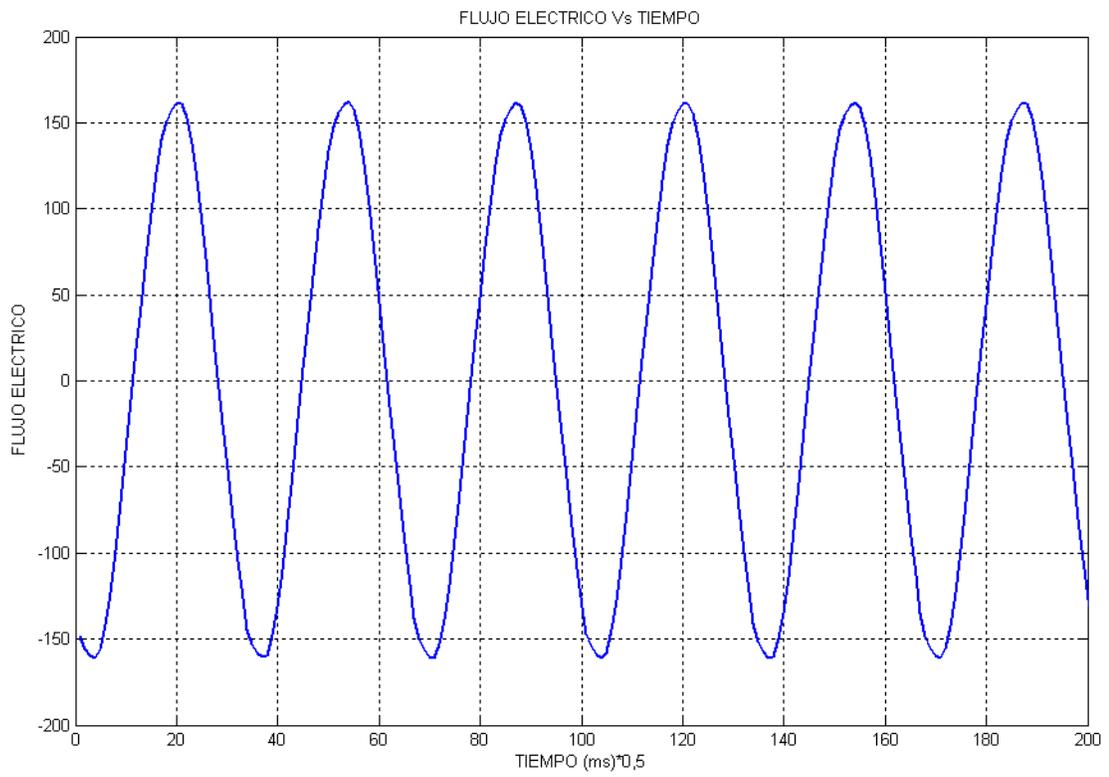
Algoritmo simplificado considerando Wavelet madre db5, Coeficientes de aproximación 1, momentos 12 y 20 y función kernel 'rbf'

```
dataA7A           %Carga la data de entrenamiento
data=cat(2,FB,PE,PI,S); %Crea el vector data
for i=1:120
[CS(:,i),LS(:,i)]=wavedec(data(1:1000,i),3,'db5');
CAL(:,i)=appcoef(CS(:,i),LS(:,i), 'db5',1); %Coef. aproximacion 1
end
for i = 1:20
momentosCAL(i,:)=moment(CAL,i);
end
X=cat(2,momentosCAL(12:8:20,1:20),momentosCAL(12:8:20,31:50),
momentosCAL(12:8:20,61:80),momentosCAL(12:8:20,91:110));
X=X';
Y=cat(1,-ones(60,1),ones(20,1));
clear('CAL','FB','PI','PE','S','CS',
'LS','i','data','momentosCAL')
dataA7A           %Carga la data de prueba
data=cat(2,FB,PE,PI,S); %Crea el vector data
for i=1:120
[CS(:,i),LS(:,i)]=wavedec(data(1:1000,i),3,'db5');
CAL(:,i)=appcoef(CS(:,i),LS(:,i), 'db5',1); %Coef. aproximacion 1
end
for i = 1:20
momentosCAL(i,:)=moment(CAL,i);
end
X1=cat(2, momentosCAL(12:8:20,21:30),momentosCAL(12:8:20,51:60),
momentosCAL(12:8:20,81:90),momentosCAL(12:8:20,111:120));
X1=X1';
Y1=cat(1,-ones(30,1),ones(10,1));
clear('CAL','FB','PI','PE','S','CS',
'LS','i','data','momentosCAL')
C=inf; p1=1; p2=0; ker='rbf';
```

CORRIENTE ESTATORICA EN EL TIEMPO



FLUJO ELECTRICO EN EL TIEMPO



COEFICIENTES DE LA TRANSFORMADA WAVELET

