

DETECCION DE FALLAS EN BOMBAS HIDRAULICAS USANDO MAQUINAS DE
SOPORTE VECTORIAL Y MÉTODOS ESTADÍSTICOS

FABIAN HORACIO DIAZ PALENCIA

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
MAESTRIA EN INGENIERÍA MECÁNICA
BUCARAMANGA
2017

DETECCION DE FALLAS EN BOMBAS HIDRAULICAS USANDO MAQUINAS DE
SOPORTE VECTORIAL Y ANALISIS DE COMPONENTES PRINCIPALES

FABIAN HORACIO DIAZ PALENCIA

Monografía presentada como requisito para optar al título de Magister en
Ingeniería Mecánica

DIRECTOR:

CARLOS BORRÁS PINILLA

Phd Ingeniería Mecánica

CODIRECTOR:

PEDRO DIAZ GUERRERO

MSc Ingeniería Mecánica

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
MAESTRIA EN INGENIERÍA MECÁNICA
BUCARAMANGA

2017

AGRADECIMIENTOS

El autor expresa sus agradecimientos a:

La Universidad Industrial de Santander y Escuela de Ingeniería Mecánica, por los recursos tanto físicos como humanos facilitados para el desarrollo de este trabajo.

El profesor Carlos Borrás P. director del proyecto, por su orientación técnica, apoyo y constante respaldo.

El profesor Pedro Díaz G. codirector del proyecto, por su orientación sobre la metodología de investigación y documentación.

DEDICATORIA

A mi hijos Tatiana, Valeria y Mateo, por quienes me inspiro y motivo cada día por crecer y ser mejor persona.

A mi adorada madre, por su dedicación, empeño y apoyo incondicional.

A mi hermosa compañera de vida y amada Carolina, por su amor, comprensión, apoyo y compañía a lo largo de todo este proceso.

A mis hermanos Yesi, Pao y Michael, por estar en todo momento ahí.

A mis amigos.

TABLA DE CONTENIDO

INTRODUCCIÓN	14
1. DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN.....	17
2. OBJETIVOS DEL PROYECTO	18
2.1. OBJETIVO GENERAL	18
2.2. OBJETIVOS ESPECÍFICOS.....	18
3. SISTEMAS DE DETECCIÓN Y DIAGNÓSTICO DE FALLAS ANTECEDENTES	19
3.2 SISTEMAS EXPERTOS BASADOS EN REGLAS.....	20
3.3 SISTEMAS DE RAZONAMIENTO BASADO EN CASOS.....	20
3.4 RAZONAMIENTO BASADO EN MODELOS	21
3.5 SISTEMAS DE APRENDIZAJE	22
3.5.1 Detección de fallas basado en modelos con señales..	22
3.5.2 Detección de fallas basado en modelos del proceso.	23
3.5.3 Basados en razonamiento y sistemas de aprendizaje.	23
3.6 SISTEMAS DE APRENDIZAJE Y SU APLICACIÓN AL DIAGNÓSTICO DE FALLAS.....	24
3.7 CASO DE ESTUDIO BOMBA DE PISTONES AXIALES	25
4. ANÁLISIS DE COMPONENTES PRINCIPALES	30
5. CARACTERÍSTICAS DE UNA SEÑAL	33
6. MAQUINAS DE SOPORTE VECTORIAL	35
6.1 CASO LINEALMENTE SEPARABLE.....	35
6.2 CLASIFICADORES NO LINEALES BASADOS EN KERNEL.....	40
6.3 CLASIFICADORES MULTI-CLASE	41
6.3.1 One against all (uno contra todos)..	42
6.3.2 One against one (uno contra uno).	42
6.3.3 Directed Acyclic Graph (grafo acíclico dirigido).....	43

7. DESARROLLO DEL ALGORITMO PARA DETECCIÓN Y CLASIFICACIÓN Y DE FALLAS.....	45
7.1 ADQUISICIÓN Y ALMACENAMIENTO DE DATOS EN DIFERENTES CONDICIONES DE FALLA.....	45
7.1.1 Vibraciones mecánicas..	46
7.2 ADAPTACIÓN DEL ALGORITMO DE DETECCIÓN Y DIAGNOSTICO USANDO PCA-SVM.....	51
7.2.1 Procesamiento de datos.	52
7.2.2 Aplicación de análisis de componentes principales.	55
7.3 EXTRACCIÓN DE CARACTERÍSTICAS	59
7.3.1 Análisis exploratorio de los datos.....	60
7.3.2 Selección de parámetros.	66
7.4 ADAPTACIÓN DEL ALGORITMO CLASIFICADOR	70
7.4.1 Datos en formato libsvm.	70
7.4.2 Validación cruzada.	70
7.4.3 Modelo de diagnóstico.	71
8. PRUEBAS Y RESULTADOS	74
8.1 PRUEBAS	74
8.1.1 Prueba 1.	75
8.2.2 Prueba 2	76
8.2.3 Prueba 3.	77
8.2.4 Prueba 4.	78
8.2.5 Prueba 5.....	79
8.2.6 Prueba 6.	80
8.3 ANÁLISIS DE RESULTADOS.....	81
9. APORTES	86
10. RECOMENDACIONES	87
11. CONCLUSIONES	88
12. CITAS BIBLIOGRÁFICAS.....	89
BIBLIOGRAFÍA.....	95

LISTA DE FIGURAS

Figura 1 Bomba de pistones axiales de desplazamiento variable.....	15
Figura 2 Esquema general para detección y diagnóstico de fallas con conocimiento analítico y heurístico.	19
Figura 3 Detección de fallas basado en modelos con señales.	23
Figura 4 Resumen técnicas de detección y diagnóstico	28
Figura 5 Hiperplano óptimo maximización del margen	37
Figura 6 Transformación de datos en un nuevo espacio donde las clases son linealmente separables.	¡Error! Marcador no definido.
Figura 7 Estructura de un algoritmo SVM uno contra todos.....	42
Figura 8 Estructura de un algoritmo DAGSVM	43
Figura 9 puntos de medición en la bomba	47
Figura 10 Comparación PSD para las condiciones uno y cinco de la bomba	48
Figura 11 Espectro de vibración para las diferentes condiciones de falla en la bomba	49
Figura 12 Banco de pruebas a) real; b) esquema	50
Figura 13 Señal sin filtrar y filtrada a) Señal de presión b) Señal de vibración	52
Figura 14 Varianza acumulada e individual	56
Figura 15 Datos originales	57
Figura 16 Datos estandarizados	58
Figura 17 Datos transformados.....	58
Figura 18 Gráfica de la media de los datos.....	60
Figura 19 Gráfica de desviación estándar de los datos	61
Figura 20 Gráfica de la varianza de los datos	62
Figura 21 Gráfica del valor de la curtosis de los datos	63
Figura 22 Gráfica del valor de la asimetría de los datos	64
Figura 23 Histograma del primer componente principal de los datos	65

Figura 24 Histograma del indicador RMS en el dominio del tiempo de los datos ..	66
Figura 25 Esquema del proceso	73
Figura 26 Resumen resultados de pruebas	81
Figura 27 Exactitud de predicción condición 1.....	82
Figura 28 Exactitud de predicción condición 2.....	83
Figura 29 Exactitud de predicción condición 3.....	83
Figura 30 Exactitud de predicción condición 4.....	84
Figura 31 Exactitud de predicción condición 5.....	84

LISTA DE TABLAS

Tabla 1 Causas y efectos de falla en una bomba de pistones axiales.....	16
Tabla 2 Uso de sistemas de aprendizaje y su aplicación a FDD	28
Tabla 3 Kernels populares para el modelado no lineal.	41
Tabla 4 Condiciones de severidad de la falla, puntos de medición y tipos de señales.....	49
Tabla 5 Distribución de ejemplos de las señales	53
Tabla 6 Conformación del vector de etiquetas.....	67
Tabla 7 Matriz de características combinación 1	68
Tabla 8 Matriz de características combinación 2	68
Tabla 9 Matriz de características combinación 3	68
Tabla 10 Matriz de características combinación 4	69
Tabla 11 Matriz de características combinación 5	69
Tabla 12 Matriz de características combinación 6	69
Tabla 13 Resultados prueba 1	75
Tabla 14 Parámetros prueba 1	75
Tabla 15 Resultados prueba 2	76
Tabla 16 Parámetros prueba 2	76
Tabla 17 Resultados prueba 3.....	77
Tabla 18 Parámetros prueba 3	77
Tabla 19 Resultados prueba 4.....	78
Tabla 20 Parámetros prueba 4	78
Tabla 21 Resultados prueba 5.....	79
Tabla 22 Parámetros prueba 5	79
Tabla 23 Resultados prueba 6.....	80
Tabla 24 Parámetros prueba 6	80
Tabla 25 Estructura del modelo	85

RESUMEN

TITULO: DETECCION DE FALLAS EN BOMBAS HIDRAULICAS USANDO MAQUINAS DE SOPORTE VECTORIAL Y ANALISIS DE COMPONENTES PRINCIPALES*

AUTOR: FABIAN HORACIO DIAZ PALENCIA**

PALABRAS CLAVE: Bomba de pistones axiales, detección y diagnóstico de fallas, máquinas de aprendizaje, vibraciones mecánicas.

DESCRIPCIÓN:

El objetivo principal de este trabajo consiste en implementar técnicas avanzadas de detección y diagnóstico de fallas basándose en sistemas de aprendizaje, particularmente usar métodos estadísticos (análisis de componentes principales) y sistemas de aprendizaje (máquinas de soporte vectorial) para la detección y diagnóstico de fallas por pérdida de eficiencia volumétrica debida a desgaste en el plato de válvulas en una bomba de pistones axiales, a través del uso de señales de vibración y presión utilizando un banco de pruebas en el cual se indujo la falla en cinco condiciones de severidad y una carga específica.

El algoritmo de PCA se implementa para reducir la dimensión de los datos en el dominio del tiempo y luego de eliminar el ruido transformarlos nuevamente al espacio original lo cual permite detectar la existencia de la falla, luego algunos parámetros estadísticos son implementados para la extracción de las características del set de datos, estos se utilizaron para entrenar el algoritmo SVM multiclase uno contra el resto y usando validación cruzada se determinaron los parámetros óptimos C y γ con los cuales se funda la arquitectura del modelo final para el entrenamiento del algoritmo SVM multiclase uno contra uno y el mejor desempeño en cuanto a precisión y tiempo de procesamiento se obtuvo con los Kernel lineal y RBF.

* Trabajo de Grado

**Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería Mecánica. Director: Carlos Borrás Pinilla. Codirector: Pedro Díaz Guerrero.

ABSTRACT

TITLE: FAULT DETECTION IN HYDRAULICS PUMPS BASED ON SUPPORT VECTOR MACHINE AND PRINCIPAL COMPONENTS ANALYSIS*

AUTHOR: FABIAN HORACIO DIAZ PALENCIA**

Key Words: Axial piston pump, failure detection and diagnostic, support vector machines, principal components analysis and mechanical vibration.

DESCRIPTION:

The main aim of this work is to implement advanced techniques for fault detection and diagnostic based on learning systems, particularly is to use statistical methods (principal component analysis) and learning systems (support vector machines) for failures detection and diagnosis due to loss of volumetric efficiency due to wear on the valve plate in an axial pistons pump, through use of vibration and pressure signals using a workbench in which the fault was induced in five conditions of severity and a specific load.

The PCA algorithm was implemented to reduce the dimension of the data in the time domain and after eliminating the noise, transforming them again to the original space, which allows to detect the existence of the fault, then some statistical methods were implemented for the features extraction of the data set, this features were used to train the multiclass SVM algorithm one against the rest and using cross validation the optimal parameters were determined and the architecture of the final model was constructed for the training of the multiclass SVM algorithm one against one. And the best performance in terms of accuracy and processing time was obtained with the linear and RBF Kernel.

* Work degree

**Faculty of Physical-mechanical Engineering. School of Mechanical Engineering. Advisor: Carlos Borrás Pinilla. Co advisor: Pedro Diaz Guerrero.

INTRODUCCIÓN


La bomba hidráulica de pistones axiales se emplea para transmitir potencia en diversas aplicaciones como: maquinaria móvil, sistemas estacionarios e industria en general y del buen desempeño de la misma depende el éxito de las operaciones dentro de cada proceso, por ende que las compañías inviertan gran parte de su tiempo y capital en sistemas de mantenimiento predictivo, preventivo y correctivo para prolongar su tiempo de funcionamiento y mitigar las fallas que puedan presentar, no obstante, su naturaleza no lineal acoplada a varios dominios físicos del equipo aumentan la dificultad para la detección a tiempo e identificación de las fallas.

En las industrias de procesos, servicios y manufactura, hay una gran presión y demanda por producir artículos confiables o servicios con alto grado de calidad, reducir drásticamente los rechazos de producto, incrementar la disponibilidad y mejorar las regulaciones ambientales. Los procesos operacionales de las plantas que una vez fueron considerados aceptables hoy en día no son aceptados ni adecuados. Para asegurar la confiabilidad operacional del sistema y garantizar que la operación satisfaga los requerimientos de desempeño especificados, las fallas deben, y necesitan ser detectadas, diagnosticadas y solucionadas para garantizar la operación confiable y rentable al mínimo costo operativo de la planta productiva. La tarea asociada con garantizar y asegurar el éxito de la operación planeada es reconocer las anomalías del sistema y en este caso de investigación, el sistema (ver figura 1) es una Bomba Hidráulica de pistones axiales. [1].

El desarrollo de sistemas de detección y diagnóstico de fallas (FDD) para bombas de pistones axiales es un tema de investigación actual. Los sistemas FDD se basan en modelos matemáticos contruidos a partir del conocimiento del sistema, estos realizan comparaciones entre los resultados teóricos y reales para determinar la

existencia o no de una falla y su efectividad depende directamente de la capacidad del modelo matemático para interpretar la dinámica del sistema; como alternativa a este enfoque se encuentran los sistemas de detección de fallas basados en datos, los cuales a partir de una compilación de datos provenientes de un sistema de monitoreo identifican patrones que permiten la elaboración de tendencias y cuando se presenta una variación en ellas, se puede inferir la existencia de un comportamiento anormal.

Figura 1. Bomba de pistones axiales de desplazamiento variable



Fuente: LI, Z. Condition Monitoring of Axial Piston Pump. Canadá. Universidad de Saskatchewan, 2005. Pág. 10

Este tipo de enfoque disminuye en gran medida la cantidad de información analítica necesaria acerca de un sistema, sin embargo son necesarios algoritmos y técnicas que sean capaces de identificar y extraer patrones sobre grandes conjuntos de datos (extracción de conocimiento). En ese sentido el área de sistemas de aprendizaje nos provee de algoritmos y metodologías para la construcción de sistemas FDD basados en datos.

Para el caso particular, los datos de entrada al sistema FDD provienen de las señales de vibración, del ruido y del comportamiento de la presión de flujo para la validación de la existencia de la falla, según [3] estas señales son las fuentes de datos dominantes en el monitoreo de condición para sistemas de potencia fluida, ya

que aportan valiosa información sobre el estado y funcionamiento de los equipos como se puede observar en la tabla 1

Tabla 1. Causas y efectos de falla en una bomba de pistones axiales

Componente	Causas	Efectos
Rodamientos	Desgaste	1 Eleva el nivel de ruido y vibración
		2 Incremento de la temperatura en punto de operación
		3 Requiere más torque mover la bomba
		4 Perdida de eficiencia
Barrel y eje estriado	Desgaste	1 Eleva el nivel de ruido y vibración
		2 Incremento rápido de temperatura del aceite
		3 Requiere más torque mover la bomba
		4 Perdida de eficiencia
Barrel cara frontal	Desgaste	1 Eleva el nivel de ruido
		2 Incremento rápido de temperatura de aceite
		3 Aumento de caudal de perdidas
		4 Requiere más torque mover la bomba
		5 Perdida de eficiencia
Plato de válvula	Desgaste	1 Eleva el nivel de ruido y vibración
		2 Incremento rápido de temperatura del aceite
		3 Aumento de caudal de perdidas
		4 Requiere más torque mover la bomba
		5 Perdida de eficiencia
Retenedor	Desgaste	1 Fugas en el eje
Pistones	Desgaste	1 Perdida de eficiencia
		2 Caída de presión de descarga
		3 Eleva el nivel de ruido
		4 Incremento rápido de temperatura del aceite
		5 Perdida de presión de succión
Resorte de retorno	Fin de vida útil	1 La presión de salida no es la designada
		2 El control de flujo no es exacto
Pistón de control	Desgaste	1 La presión de salida no es la designada
		2 El control de flujo no es exacto
		3 Incremento de la temperatura del aceite
Patín	Desgaste	1 La presión de salida no es la designada
		2 Eleva el nivel de ruido
		3 Incremento de la temperatura del aceite
		4 Perdida de eficiencia
Plato deslizante	Desgaste	1 Incremento de la temperatura del aceite
		2 Eleva el nivel de ruido
		3 Requiere más torque mover la bomba
		4 Perdida de eficiencia

Fuente: LI, Z. Condition Monitoring of Axial Piston Pump. Canadá. Universidad de Saskatchewan, 2005. Pág. 11

1. DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN

TITULO DEL PROYECTO

“DETECCIÓN DE FALLAS EN BOMBAS HIDRÁULICAS USANDO MÁQUINAS DE SOPORTE VECTORIAL (SVM) Y MÉTODOS ESTADÍSTICOS”

DIRECTOR DEL PROYECTO

CARLOS BORRÁS PINILLA

Ingeniero Mecánico, Ph.D., MSc. Ingeniería Mecánica

Universidad Industrial de Santander (Colombia)

Escuela de Ingeniería Mecánica

CODIRECTOR DEL PROYECTO

PEDRO JOSÉ DÍAZ

Ingeniero Mecánico, MSc. Ingeniería Mecánica

Universidad Industrial de Santander (Colombia)

Escuela de Ingeniería Mecánica

AUTOR DEL PROYECTO

FABIAN HORACIO DÍAZ PALENCIA

Ingeniero Mecánico, Candidato a Magíster en Ingeniería Mecánica

ENTIDADES INTERESADAS EN EL PROYECTO

UNIVERSIDAD INDUSTRIAL DE SANTANDER – UIS (Colombia)

Grupo de Investigación en Dinámica, Control y Robótica DICBOT

Industria Local

2. OBJETIVOS DEL PROYECTO

2.1. OBJETIVO GENERAL

Desarrollar un algoritmo clasificador basado en máquinas de soporte vectorial (SVM) y Análisis de componentes principales PCA, para detección y diagnóstico de fallas en bombas hidráulicas de pistones axiales.


2.2. OBJETIVOS ESPECÍFICOS

- Establecer el estado del arte sobre técnicas avanzadas de diagnóstico de fallas en bombas hidráulicas de pistones axiales.
- Desarrollar e implementar un algoritmo para detección y clasificación de fallas en bombas hidráulicas de pistones axiales, basado en máquinas de soporte vectorial usando la información transportada por las señales de presión y vibración.
- Realizar la detección y análisis de las fallas offline por pérdida de eficiencia volumétrica en una bomba de pistones axiales Eaton 54 correspondientes a cinco grados de desgaste en el plato de válvula (Condición normal, desgaste moderado, desgaste medio, desgaste alto, desgaste severo ver tabla 4).
- Validar experimentalmente el algoritmo propuesto, usando un banco de pruebas diseñado y construido por el grupo de investigación Dicbot dedicado especialmente para este tipo de ensayos.

3. SISTEMAS DE DETECCIÓN Y DIAGNÓSTICO DE FALLAS ANTECEDENTES

La tarea de detección y diagnóstico de fallas consiste en la determinación del tipo de falla con tantos detalles como sea posible, la figura 2, resume los pasos individuales, tanto para la medición automática de variables como para la inspección humana. En ambos casos, una extracción de características y una detección de los cambios de la situación normal o nominal del sistema se dan lugar. Los síntomas ya sean analíticos o heurísticos deben ser llevados en una representación unificada con el fin de realizar el diagnóstico [1][4].

Figura 2. Esquema general para detección y diagnóstico de fallas con conocimiento analítico y heurístico.



Fuente: ISERMANN, R. Fault-diagnosis systems: An introduction from fault detection to fault tolerance. [En línea]. Recuperado en 11 febrero 2017. Disponible en: <http://www.springer.com/us/book/9783540241126>

Existen diversas tecnologías disponibles para detección y diagnóstico de fallas[5]: sistemas expertos basados en reglas, sistemas de razonamientos basados en casos, modelos basados en razonamiento y sistemas de aprendizaje que es la técnica que se investigará más a fondo en este trabajo.

3.2 SISTEMAS EXPERTOS BASADOS EN REGLAS

Tienen gran aplicación en tareas de diagnóstico donde la experiencia está disponible, pero el conocimiento de las propiedades físicas del sistema no lo están o es demasiado costoso obtenerlas. Los procedimientos que un caza-fallas experto realiza pueden ser desglosados en múltiples pasos y codificados como reglas. Una regla describe la acción que deberá ser tomada si se observa un síntoma y constituye la base del conocimiento del experto.

Emplea dos métodos de razonamiento para el diagnóstico: el primero partiendo de una hipótesis, un algoritmo de encadenamiento hacia atrás recoge o verifica la evidencia que la apoya y si esta se comprueba, entonces la hipótesis se describe como el resultado de diagnóstico y en el segundo método de encadenamiento hacia adelante, se examinan las reglas para ver cuáles coinciden con la evidencia observada si sólo hay una regla que coincide, el proceso es simple, pero, si más de una regla lo hace, se presentan conflictos y se debe asignar prioridad a las normas aplicables. Las reglas con mayor prioridad se aplican primero para obtener conclusiones de diagnóstico.

3.3 SISTEMAS DE RAZONAMIENTO BASADO EN CASOS

Es el proceso de solucionar nuevos problemas basándose en las soluciones de problemas desarrollados en el pasado, la experiencia de comportamientos normal y anormal es esencial para construir un efectivo sistema de diagnóstico basado en casos, incluye un componente de aprendizaje que hace posible lo mencionado anteriormente. Un sistema de razonamiento basado en casos consiste en una

biblioteca de casos que contiene características que describen el problema, los resultados, las soluciones, los métodos utilizados y una evaluación de su eficacia. Un mecanismo de codificación se utiliza para indexar la información del caso a fin de que los casos puedan ser organizados en estructuras significativas como las agrupaciones, lo que permite la recuperación eficiente.

Su estructura conlleva 4 pasos básicos:

Recordar. Casos similares al que analizamos.

Reutilizar. Encontrar la diferencia entre casos del pasado y presente y transferir o modificar la solución adaptándola a la nueva situación, para resolver el problema.

Revisar. Si la solución propuesta fue exitosa o no.

Retener. Incorporar la nueva solución en el conocimiento existente.

3.4 RAZONAMIENTO BASADO EN MODELOS

En estos métodos se encuentran dos tipos: los que hacen uso de modelos para la generación explícita de residuos a modo de redundancia analítica y aquellos que hacen uso de modelos cualitativos para expresar relaciones causa-efecto. El modelo es usualmente desarrollado con base en el entendimiento previo de las leyes físicas que gobiernan el sistema, en los modelos contruidos para generación de residuos este entendimiento es expresado en términos de relaciones matemáticas entre las entradas y salidas del sistema. En los modelos cualitativos dichas relaciones se expresan en términos de funciones cualitativas.[6]

Para una revisión detallada de las aplicaciones de los tres sistemas mencionados anteriormente puede remitirse a [5], [6], [7] y [8].

3.5 SISTEMAS DE APRENDIZAJE


Se derivan directamente de las rutinas de monitoreo de operación del sistema, basados en la suposición de que las características estadísticas de los datos (Calibración, potencia, vibración, temperatura, presión, contaminación de aceite, ruido, corrientes o voltajes), son estables a menos que un evento de mal funcionamiento ocurra en el sistema, es decir, las variaciones de causa común son del todo debido a las incertidumbres y el ruido aleatorio, mientras que las variaciones de causa especial, son debido a fallas. La fuerza de las técnicas basadas en datos, es la capacidad para transformar datos de ruido de altas dimensiones en información de menor dimensión para detección y decisión de diagnóstico y el principal inconveniente de este enfoque es que su eficacia es altamente dependiente de la cantidad y la calidad de los datos operacionales del sistema. [1] resume las tecnologías de la siguiente forma:

3.5.1 Detección de fallas basado en modelos con señales. Como son: funciones de correlación, análisis de fourier- FFT-PSD, análisis de componentes principales, análisis de wavelet, cuyas características de identificación son: cambios en los umbrales, variación de las amplitudes, variación en la energía, frecuencias de las componentes y modelo de ecuaciones diferenciales lineales o no lineales, se conocen como modelos de Caja Blanca.

3.5.2 Detección de fallas basado en modelos del proceso. Como son: estimadores de parámetros, ecuaciones de paridad, observadores, estimadores de estados, análisis de componentes principales, cuya característica de identificación son: los parámetros, variables de estado y variación de los residuales y modelos de ecuaciones diferenciales con parámetros estimados, se conocen como modelos de caja ligeramente gris, también, sistemas inferenciales, o cajas grises, basados en reglas y sistemas de razonamientos basados en casos.

3.5.3 Basados en razonamiento y sistemas de aprendizaje. Estos son sistemas de modelado experimental, donde se establece una relación entrada/salida y se asume una estructura de modelo, son los modelos “Black Box”, tales como: las redes neuronales y máquinas de soporte vectorial.

Figura 3. Detección de fallas basado en modelos con señales.



Fuente: BORRÁS PINILLA, Carlos. Técnicas avanzadas de mantenimiento. B Universidad Industrial de Santander, 2016. Pág. 22

3.6 SISTEMAS DE APRENDIZAJE Y SU APLICACIÓN AL DIAGNÓSTICO DE FALLAS

En los últimos años ha ido en aumento el uso de sistemas de aprendizaje para clasificación de anomalías en diferentes disciplinas de la ingeniería, actualmente las más implementadas y recomendadas por la comunidad científica por presentar un mejor desempeño en la clasificación son las redes neuronales y las máquinas de soporte vectorial [9] destacándose entre ellas SVM.

Muchas de estas investigaciones sugieren el uso de SVM para la detección de fallas como:

Oviedo et al [10] proponen un sistema basado en SVM y análisis MCSA, para detección de fallas en motores de inducción usando la información transportada por la señal de corriente del estator, realizó la detección y análisis de las fallas correspondientes a: Corto circuito en el devanado del estator y barras rotas en el rotor basado MCSA y SVM.

Castañeda y Borrás [11] proponen una arquitectura, para diagnóstico de fallas en maquinaria rotativa usando FFT para extracción de características y SVM para clasificación detectando con una precisión de 100 % aproximadamente fallas por desbalanceo, desalineamiento y paso de alabes.

Liu y Liu [12] establecen una arquitectura para diagnóstico de fallas en maquinaria rotativa, comparando el rendimiento de diagnóstico entre SVM y BPNN para fallas en rodamiento de bolas y mostró que SVM presenta un mejor tiempo en entrenamiento, pruebas y mayor exactitud en la clasificación.

Ravikumar et al [13] para diagnóstico de fallas en sistemas de transmisión de potencia Laouti [14] para detección de fallas en turbinas de viento, Demetgul [15] para diagnóstico de fallas en sistemas de producción, Hu [16] y Tian et al [17] para

diagnóstico de fallas en bombas dónde todos los resultados obtenidos mostraron que SVM es un algoritmo clasificador muy potente en las situaciones donde se requiere separar aquellos rasgos de los cuales depende la detección a partir de un conjunto cuantioso de datos y evaluar los indicadores obtenidos, para así poder determinar la condición del sistema.

Helwig et al [18] realizaron un estudio en sistemas hidráulicos para identificación de fallas basado en métodos estadísticos usando características del espectro de vibración a través de FFT, indujo fallas de desgaste en una válvula de conmutación de un banco de pruebas. Concluyeron que las fallas son cuantificables y clasificables y que además se podrían caracterizar otras como fugas internas.

Borrás y stalford [19] plantearon una metodología para detección de fallas en actuadores por exceso de backlash, para tal fin utilizaron tres redes neuronales Adaptive Linear Network Mode, One Layer Adaptive, Non-Linear neuron Network y Multilayer Perceptron Network mostrando esta última mejor rendimiento en todo el experimento en comparación con las otras dos.

Por otro lado Oviedo y Quiroga [20] Aplica la transformada wavelet discreta a la señal de emisiones acústicas para generar un indicador de falla que permite detectar cavitación en bombas centrifugas.

3.7 CASO DE ESTUDIO BOMBA DE PISTONES AXIALES

Las bombas de pistones axiales operan bajo condiciones de trabajo exigentes, por lo que los tipos y formas de fallas son variados, adicionalmente el acceso al componente puede llegar a ser muy complicado. Por estas razones es indispensable un sistema de detección automática de fallas lo suficientemente fiable

que permita evitar daños que afecten de forma permanente la operación y permita planear de forma eficiente los procesos de mantenimiento. Las bombas de pistones axiales son un excelente escenario para investigar el diseño de sistemas FDD. A continuación se presentan algunos autores que trabajaron FDD enfocándose en Sistemas de aprendizaje y datos obtenidos por la captación de señales.

He et al [21] presentaron un método de predicción híbrida basado en EMD, PSO y SVM que pronostica el restante de vida útil de la bomba mediante SVM midiendo el incremento del flujo de pérdidas de aceite por desgaste en el plato de válvulas obteniendo una precisión de diagnóstico del 98.8764%.

Wang [22] desarrollo un sistema de diagnóstico de fallas basado en SVM y caos, calculan el error residual lo caracterizan y así agrupan las fallas; pérdida de patín y desgaste en el plato de válvulas lo comparan con datos de referencia experimentales logrando una precisión de diagnóstico del 100 %.

Sheng [23] propone un algoritmo basado en el modelo DAGSVM para diagnóstico de 5 condiciones de falla en un sistema hidráulico y los resultados los compara con un algoritmo de Red Neuronal, mostrando que DAGSVM ofrece mejor rendimiento en entrenamiento, pruebas y exactitud de diagnóstico.

Wang y Cheng [24] presentaron un método de diagnóstico basado en la transformada wavelet, rough set y redes neuronales. La función wavelet extraía las características de la falla de la señal de vibración, luego el aprendizaje adquirido por el rough set fue usado como entrada para la red neuronal y la salida fue el diagnóstico de las diferentes fallas.

Pawel [25] aplicando tres tipos de redes neuronales (MLP), (GRNN) y (PNN) y basado en presión dinámica o vibración pudo estimar cuatro estados de consumo en una bomba. El estudio fue realizado trabajando con señales tanto en el dominio del tiempo como en el de la frecuencia. Compararon la efectividad de las 3 NN

mediante exactitud (error generado) y complejidad (número de parámetros y tiempo de entrenamiento) concluyendo que la eficacia de la estimación del consumo de la bomba es mayor en el dominio de la frecuencia con la MLP y en el dominio del tiempo la red que presentó mayor precisión fu la GRNN.

Dong y He [26] realizaron diagnóstico con el modelo oculto de Markov (HSMM), procesando las señales de vibración mediante un paquete de descomposición wavelet, los coeficientes obtenidos se usaban como entrada al HSMM. Pudiendo clasificar de manera acertada diferentes condiciones de desgaste en bombas hidráulicas.

Hongzhi y Guanzheng [27] usando MLPNN crearon un algoritmo capaz de detectar fallas por cavitación. Silan Liu [28] Utiliza la FFT para transformar señales de presión en el dominio del tiempo al dominio de la frecuencia en el diagnóstico de fallas de bombas hidráulicas mediante el método de parámetros pulsantes,

Gao [29] [30] usa el método de análisis wavelet para mejorar la capacidad de diagnóstico en bombas de pistones aprovechando la información que puede ser obtenida con los datos de presión de descarga. Los resultados experimentales mostraron que el método permite identificar diferentes tipos de falla pero solo cuando ocurren individualmente.

L. Siyuan [31] Muestra un estudio sobre la aplicación de PCA para la detección de fallas en Bombas Hidráulicas, y en [32] Combina Rough Set (RS) y PCA para diagnosticar fallas basado en las características de la energía de las señales de Vibración en bombas hidráulicas.

Zhao [33] Presenta un método basado en caos intermitente y estadística de secuencia de símbolos por ventanas deslizantes para detectar fallas tempranas en pistones que pierden el patín. El método analiza la presión de descarga a través del

diagrama de historial de tiempo de un oscilador Duffing y mediante el método de secuencia de símbolos por ventanas verifica su comportamiento para realizar un diagnóstico temprano.

Figura 4. Resumen técnicas de detección y diagnóstico




Tabla 2. Uso de sistemas de aprendizaje y su aplicación a FDD

Sistema/Equipo	Referencias	Tecnicas
Bombas	Hu (2012) [16]	SS-SVM
	Tian et al (2007) [17]	SVM
	Oviedo Quiroga (2012) [20]	Wavelet
	He et al (2012) [21]	EMD-PSO-SVM
	Wang y Wang (2013) [22]	SVM-Caos
	Wang y Cheng (2007) [24]	Wavelet-Rough set-NN
	Pawel (2014) [25]	MLP-GRNN-PNN
	Dong y He (2007) [26]	Wavelet-HSMM
	Hongzhi y Guanzheng (1995) [27]	MLPNN
	Silan Liu (1991) [28]	FFT-pulsating parameter
	Gao (2003/2006) [29][30]	Wavelet/Residual Analysis
	Siyuan (2010) [32]	PCA
	Siyuan (2011) [31]	RS-PCA
Maquinaria rotativa	Zhao (2009) [33]	Intermittent chaos-sliding window
	Diaz, Borrás y Diaz Trabajo presente	PCA-SVM
Motores de inducción	Castañeda y Borrás (2014) [11]	FFT-SVM
	Liu y Liu (2010) [12]	SVM-BPNN
Sistemas hidráulicos	Oviedo et al (2011) [10]	MCSA-SVM
	Sheng (2010) [23]	DAGSVM-NN
	Borrás y Stalford (2002) [19]	NN
Sistemas de producción	Helwig et al (2015) [18]	FFT-Statistical methods
	Demetgul (2013) [15]	SVM-DTA
Sistemas de transmisión de potencia	Ravikumar et al (2008) [13]	SVM
Turbinas de viento	Laouti (2011) [14]	SVM

4. ANÁLISIS DE COMPONENTES PRINCIPALES

El análisis de componentes principales, introducido por Pearson (1901) y Hotelling (1933) es una herramienta estadística aplicable a sistemas multivariados, que permite la transformación de los datos a un espacio de menor dimensión el cual retiene la información más relevante acerca del proceso.

A fin de lograr estos objetivos, se construyen nuevas variables llamadas componentes principales, tal que:

- Cada componente principal debe ser combinación lineal de las variables originales.
- Los componentes principales son no correlacionados dos a dos, eliminándose información redundante.
- Los componentes principales deben tener varianza máxima, conteniendo el máximo de información posible.

A continuación se indica el procedimiento que se debe llevar a cabo para realizar análisis de componentes principales a un conjunto de datos[34]. Considerando una matriz de datos $X \in \Re^{n \times m}$:

Obtener el set de datos analizar.

$$X = [x_1(k), x_2(k), x_3(k), \dots, x_m(k)], k = 1, 2, 3 \dots n \quad (3.1)$$

En general, el set de datos será pre-procesado antes del análisis. Las columnas de X estarán centradas de manera que la media de cada columna sea igual a cero y su varianza igual a uno.

$$x_{ij} = x_{ij} - x_{jmean} \quad (3.2)$$

$$x_{ij} = \frac{x_{ij} - x_{jmean}}{s(x_j)}, \quad j = 1, \dots, m; i = 1, \dots, n \quad (3.3)$$

Donde $s(x_j)$ es la desviación estándar de la columna j

Calcular la matriz de covarianza. Esta matriz se calcula mediante la fórmula 3.4

$$S = \frac{1}{n-1} X^T X \quad (3.4)$$

Calcular los valores propios de la matriz de covarianza. Por descomposición en valores singulares:

$$S = V \Lambda V^T \quad (3.5)$$

Dónde Λ es una matriz diagonal con los valores propios o “eigenvalues” de S ordenados en orden decreciente ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m \geq 0$), las columnas de la matriz V son los vectores propios o “eigenvectors” de S .

Seleccionar componentes y formar el vector de características. La matriz de transformación $P \in \mathbb{R}^{m \times a}$ es generada seleccionando a vectores propios o columnas de V correspondientes a los a valores propios.

$$P = [p_1, \quad p_2, \quad p_3, \dots, p_a] \quad (3.6)$$

Algunos criterios para determinar el número de componentes principales son[35]:

Criterio del porcentaje de variabilidad explicada: El número a de componentes principales se toma de modo que P_a sea próximo a un valor especificado por el usuario, por ejemplo el 90%.

$$\frac{\sum_{i=1}^a \Lambda_{ii}}{\sum_{i=1}^m \Lambda_{ii}} \geq 0.9 \quad (3.7)$$

Criterio de Kaiser Obtener las componentes principales a partir de la matriz de correlaciones R equivale a suponer que las variables observables tengan varianza 1. Por lo tanto una componente principal con varianza inferior a 1 explica menos variabilidad que una variable observable. El criterio, llamado de Kaiser, es entonces:

Retenemos las a primeras componentes tales que $\lambda_a \geq 1$; donde $\lambda_1 \geq \dots \geq \lambda_m$ son los valores propios de R ; que también son las varianzas de las componentes.

Obtener el nuevo conjunto de datos. El nuevo conjunto de datos de dimensión menor al original viene dado por:

$$T = X \times P \quad (3.8)$$

Ahora el set de datos original puede ser representado en términos de sus vectores propios, los cuales definen la dirección de los principales componentes

$$X = t_1 p_1^T + t_2 p_2^T + \dots + t_a p_a^T + \dots + t_m p_m^T \quad (3.9)$$

Donde cada $t_j = X p_j$ es el $(n \times 1)$ vector score, una proyección de los datos en el j -ésimo vector componente principal.

5. CARACTERÍSTICAS DE UNA SEÑAL

Un conjunto de datos medidos, puede ser representado por otro no redundante que contiene la información relevante, de modo que los pasos posteriores de aprendizaje y generalización puedan ser llevados a cabo utilizando esta representación reducida en lugar de los datos iniciales de una manera más eficiente. Este proceso se conoce como extracción o selección de características. Algunas características que pueden representar un set de datos son:

Rango intercuartil: Es una medida de dispersión, calculada mediante la diferencia entre el tercer y el primer cuartil.

$$R_Q = Q_3 - Q_1 \quad (4.1)$$

Entropía: La entropía es una medida estadística de aleatoriedad que puede usarse para caracterizar un set de datos, se define como

$$E(P) = - \sum_j P_j \log P_j \quad (4.2)$$

Donde P_j es la probabilidad de ocurrencia de un evento

Media Aritmética: describe la localización de distribución de la variable y por su gran estabilidad es ampliamente utilizada en el muestreo de datos pero cuando la distribución es marcadamente asimétrica, debe considerarse siempre la posibilidad de que el promedio aritmético pueda no ser el valor único representativo de la serie.

$$\bar{x} = \frac{\sum_{i=1}^n \mathbf{x}_i}{n} \quad (4.3)$$

RMS: Raíz cuadrada del valor de la media al cuadrado y se calcula de acuerdo a:

$$x_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n \mathbf{x}_i^2} \quad (4.4)$$

Varianza: Nos permite identificar la diferencia promedio que hay entre cada uno de los valores respecto a su punto central (media) y se define en la ecuación (4.5) donde $\bar{x}$ es la media del vector $\mathbf{x}$.

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{x})^2 \quad (4.5)$$

Desviación estándar: Esta medida nos permite determinar el promedio aritmético de fluctuación de los datos respecto a su punto central (media) y es la raíz cuadrada de la varianza.

$$s = \sqrt{s^2} \quad (4.6)$$

Curtosis y Asimetría (Kurtosis and Skewness): describen los valores de asimetría de las variables. Kurtosis es una medida de que tan concentrada es una distribución en su región central, baja concentración (*Platicúrtica*), concentración normal (*Mesocúrtica*) o una gran concentración de valores (*Leptocúrtica*) y skewness es una medida de la asimetría de los datos alrededor de la media de la muestra[36]. Se calculan de acuerdo a las ecuaciones (4.7) y (4.8) dónde s es la desviación estándar de $\mathbf{x}$.

$$S = \frac{1}{s^3} \sum_{i=1}^n (\mathbf{x} - \bar{x})^3 \quad (4.7)$$

$$K = \frac{1}{s^4} \sum_{i=1}^n (\mathbf{x} - \bar{x})^4 \quad (4.8)$$

6. MAQUINAS DE SOPORTE VECTORIAL

Las máquinas de soporte vectorial [37] son una técnica de inteligencia artificial que ha sido establecida como un enfoque de alto nivel para el aprendizaje supervisado dentro de los ambientes de investigación teórica y práctica[38], basada en una máquina de aprendizaje estadístico está propiamente relacionada con problemas de clasificación y regresión, en esencia, dado un conjunto de ejemplos de entrenamiento (muestras) podemos etiquetar las clases y entrenar una SVM para construir un modelo que prediga la clase de una nueva muestra [11].

El éxito de la técnica de SVM radica en tres ventajas fundamentales: la primera consiste en que posee una sólida fundamentación matemática, la segunda en que se basa en el concepto de la minimización del riesgo estructural, esto es minimizar la probabilidad de una clasificación errónea sobre nuevos ejemplos, particularmente importante cuando se disponen de pocos datos de entrenamiento y la tercer ventaja radica en que dispone de potentes herramientas y algoritmos para hallar la solución de manera rápida y eficiente. [39]

6.1 CASO LINEALMENTE SEPARABLE

Consideramos un problema de clasificación con un conjunto de datos de entrenamiento (características) $\{x_i\}$ en un espacio n dimensional con clases correspondientes (valores de clasificación) [40]:

$$\{y_i: y_i \in \{-1,1\}\} \tag{5.1}$$

Cuando los conjuntos son linealmente separables, se debe seleccionar el hiperplano H_0 que maximiza el margen de separación. [41].

Un plano N dimensional es de la forma:

$$a_n x_n + a_{n-1} x_{n-1} + \dots + a_1 x_1 + a_0 = 0, \quad (5.2)$$

Tomando $w = [a_n, a_{n-1}, \dots, a_1]$, $x = [x_n, x_{n-1}, \dots, x_1]$, y $b = a_0$

El hiperplano óptimo revisar figura 5 puede ser representado por:

$$H_0 : y = (w \cdot x) + b = 0 \quad (5.3)$$

Ahora, definiendo la distancia entre el punto más cercano al hiperplano óptimo como $\frac{1}{|w|}$ se pueden obtener las ecuaciones de los hiperplanos paralelos:

$$H_1 : y = (w \cdot x) + b = 1 \quad (5.4)$$

$$H_2 : y = (w \cdot x) + b = -1 \quad (5.5)$$


El trabajo consiste en hallar el vector w de pesos que contiene la ponderación de cada atributo, indicando qué tanto aportan en el proceso de clasificación, en tanto que b define el umbral de decisión, llamado usualmente *bias* en inglés [39], $\frac{b}{|w|}$ es la distancia perpendicular entre el hiperplano de separación y el origen y $|w|$ es la norma de w . [42]

Para que el caso sea linealmente separable se debe cumplir que no existan puntos de datos entre H_1 y H_2 es decir:

$$(w \cdot x) + b \geq +1 \text{ para } y_i = +1 \quad (5.6)$$

$$(w \cdot x) + b \leq -1 \text{ para } y_i = -1 \quad (5.7)$$

Figura 5. Hiperplano óptimo maximización del margen



Luego la función decisión:

$$f_{w,b}(x_i) = y_i, \quad (5.8)$$

Puede definirse como el signo que resulta de evaluar un dato en la ecuación de H_0 :
[42]

$$f_{w,b}(x_i) = \text{sign}[(w \cdot x_i) + b] \quad (5.9)$$

Combinando (5.6) y (5.7) [41]:

$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad \forall_i \quad (5.10)$$

Tal como se aprecia en la figura 5 el margen es igual a dos veces la distancia entre el hiperplano optimo y un hiperplano paralelo, luego el margen será: $\frac{2}{\|w\|}$. Ahora encontrar el mejor hiperplano separador se convierte en un clásico problema de maximización, se debe maximizar el margen sujeto a la restricción (5.10), por tanto el margen máximo será aquel que tenga menor norma o equivalentemente, con mínimo $\|w\|^2$ y se formula de la siguiente manera [43]:

$$\min \frac{\|w\|^2}{2} \quad \text{sujeto a: } y_i(w \cdot x_i + b) \geq 1 \quad \forall_i \quad (5.11)$$

Aplicando los multiplicadores de Lagrange (α_i) la ecuación (5.11) se reformula como [44]:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i (y_i [(w \cdot y_i) + b] - 1) \quad (5.12)$$

Para hallar el punto de silla (w_0, b_0, α_0), se debe minimizar $L(w, b, \alpha)$ con respecto a w y b y maximizar con respecto a $\alpha \geq 0$. En el punto óptimo tenemos las siguientes ecuaciones de puntos de silla [45]:

$$\frac{\partial L}{\partial w} = 0 \quad \Rightarrow \quad w = \sum_{i=1}^n \alpha_i y_i x_i \quad (5.13)$$

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^n \alpha_i y_i = 0 \quad (5.14)$$

Substituyendo (5.13) y (5.14) en (5.12) obtenemos:

$$\max L(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (5.15)$$

Sujeto a:

$$\alpha_i \geq 0, i = 1, \dots, n, \sum_{i=1}^n \alpha_i y_i = 0 \quad (5.16)$$

Los multiplicadores que cumplen con $\alpha_i > 0$ son llamados *vectores de soporte*, ya que son los únicos que participan en la construcción del hiperplano de clasificación [43].

Resolviendo la ecuación (5.15) sujeto a las restricciones (5.16) se determinan los multiplicadores de Lagrange y la ecuación del hiperplano óptimo de separación y la función de decisión se pueden expresar como:

$$g(x) = \sum_{i,j=1}^n \alpha_i y_i (x_i \cdot x_j) + b \quad (5.17)$$

$$f(x) = \text{sign} \left(\sum_{i,j=1}^n \alpha_i y_i (x_i \cdot x_j) + b \right) \quad (5.18)$$


6.2 CLASIFICADORES NO LINEALES BASADOS EN KERNEL

Para los casos no lineales, SVM proyecta el conjunto de datos a un espacio de mayor dimensión, donde los datos son separables linealmente. La función de transformación ϕ es definida en términos del producto escalar de los datos de entrada en el espacio original de clasificación. En lugar de especificar la función de transformación, se especifican sus funciones Kernel, porque éstos realizan la transformación y el producto escalar en un solo paso[46].

$$K(\mathbf{x}_i, \mathbf{x}_j) \equiv \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j) \quad (5.19)$$

Usando una apropiada función Kernel, las máquinas de soporte vectorial pueden separar datos de diferentes clases en un nuevo espacio, así los algoritmos de clasificación lineal pueden ser extendidos a casos no lineales, usando una función Kernel apropiada.[39]

Figura 6. Transformación de datos en un nuevo espacio donde las clases son linealmente separables



Todo lo derivado para el caso linealmente separable es aplicable para el caso no lineal usando un Kernel conveniente K . La función de decisión en el espacio de características es:

$$f(x) = \text{sign} \left(\sum_{i,j=1}^n \alpha_i y_i K(x_i, x_j) + b \right) \quad (5.20)$$

Tabla 3. Kernels populares para el modelado no lineal.

Kernel Lineal	$K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$
Kernel polinomial	$K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^T \mathbf{x}_j + r)^d, \quad \gamma > 0$
Kernel función de base radial	$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \ \mathbf{x}_i - \mathbf{x}_j\ ^2), \quad \gamma > 0$
Kernel Sigmoide	$K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\gamma \mathbf{x}_i^T \mathbf{x}_j + r)$

Donde γ , r y d son parámetros del kernel

6.3 CLASIFICADORES MULTI-CLASE


Los SVM multi-clase crean varios clasificadores de dos clases que resuelven por separado las tareas correspondientes, los más empleados comúnmente son: one-against-all, one-against-one y directed acyclic graph. Las funciones de decisión SVM resultantes se consideran como un todo y la clase para cada muestra en el conjunto de prueba se decide por el sistema correspondiente[38].

6.3.1 One against all (uno contra todos). Fue la primera implementación para clasificación multiclase con SVM. Descompone un problema multiclase con k clases en otros tantos problemas binarios, en los cuales cada una de las clases se enfrenta al resto. Así, se construyen k clasificadores que definen otros tantos hiperplanos que separan la clase i de los $k-1$ restantes. Como función de decisión, a cada nuevo documento se le asigna aquella clase sobre la que su clasificador maximice el margen (ver figura 7).

6.3.2 One against one (uno contra uno). Este método construye $k(k-1)/2$ clasificadores, cada uno es entrenado sobre datos de dos clases, las muestras etiquetadas con i se consideran positivas mientras que las de la clase j se toman como negativas. El objetivo de cada SVM es por lo tanto, determinar los coeficientes óptimos del hiperplano de decisión para discriminar las muestras con el resultado i de las muestras con el resultado j . Existen diferentes métodos para realizar pruebas futuras después de que los $k(k-1)/2$ clasificadores son construidos. Entre ellos están:

- Estrategia “Máximo Ganador Modificado”
- Estrategia de “Probabilidades”


Figura 6. Estructura de un algoritmo SVM uno contra todos



Fuente: YUAN, S.F. & CHU, F.L. Support vector machines-based fault diagnosis for turbo-pump rotor: Mechanical Systems and Signal Processing, vol. 20, no. 4, pp. 939–952, 2006.

6.3.3 Directed Acyclic Graph (grafo acíclico dirigido). El algoritmo fue propuesto con el objetivo de resolver el problema de regiones no clasificables durante la fase de entrenamiento de SVM con múltiples clases. El método de entrenamiento es similar al método uno contra uno, resolviendo $k(k-1)/2$ SVM binarias. Sin embargo, en la fase de prueba, DAGSVM emplea un grafo acíclico dirigido binario con $k(k-1)/2$ nodos internos y k ramificaciones. Cada nodo es una SVM binaria de la i -ésima y la j -ésima clase[48].

Figura 7. Estructura de un algoritmo DAGSVM



Fuente: CAMPBELL, YING, C, Y. Learning with Support Vector Machines. Morgan & Claypool Publisher. [En línea]. Recuperado en 12 enero 2017. Disponible en: <http://www.morganclaypool.com/doi/abs/10.2200/S00324ED1V01Y201102AIM010?journalCode=aim>

Información más detallada acerca de los clasificadores multiclase se puede obtener de: [38][45][48][50]

Software disponibles en las siguientes fuentes[49]:

- LIBSVM:
<https://www.csie.ntu.edu.tw/~cjlin/libsvm/oldfiles/>
- SVMlight:

<http://svmlight.joachims.org>

- simpleSVM:

<http://asi.insa-rouen.fr/~gloosli/simpleSVM.html>

- SVQP:

<http://leon.bottou.org/projects/svqp>

- MINOS:

http://www.sbsi-sol-optimize.com/asp/sol_products_minos.htm

- LOQO:

<http://www.princeton.edu/~rvdb/loqo>

- CPLEX:

<http://www-01.ibm.com/software/integration/optimization/cplex-optimizer/>

7. DESARROLLO DEL ALGORITMO PARA DETECCIÓN Y CLASIFICACIÓN Y DE FALLAS

En este capítulo se presenta cada uno de los pasos realizados en la construcción del algoritmo para detección y diagnóstico, junto a un análisis exploratorio del conjunto de datos con el objeto de determinar las características especiales que mejor representan las señales involucradas.

7.1 ADQUISICIÓN Y ALMACENAMIENTO DE DATOS EN DIFERENTES CONDICIONES DE FALLA

Esta etapa incluye la generación de cada una de las condiciones de severidad para la falla de pérdida de eficiencia volumétrica por desgaste en el plato de válvulas y la toma de datos de la bomba en operación bajo una carga específica.

Para tal fin se empleó un banco de pruebas equipado con un motor eléctrico Siemens de 40 [HP] @ 1200 rpm y una bomba de pistones axiales Eaton serie 54, en la cual se indujeron las condiciones de falla a prueba y error desgastando intencionalmente el plato de válvulas hasta producir la pérdida de eficiencia esperada, (ver tabla 4). La carga fue generada por medio de un manifold que consiste de dos válvulas de alivio cruzadas con el cual fue posible mantener las mismas condiciones de carga durante el experimento.


A una carga preestablecida de 700 psi y procurando mantener las variables de medición como estabilización del régimen de funcionamiento, ruidos externos y temperatura del aceite hidráulico un rango constante, se procede a captar señales

de presión de precarga, presión de descarga, vibraciones mecánicas y medición de caudal de pérdidas, para ello se usaron los siguientes instrumentos:

- Caudalímetro Flow metrics modelo FM-8 para medir caudal de pérdidas.
- Transductor de presión WIKA modelo ECO-1 para medir presión de descarga.
- Transductor de presión MSI serie MSP300 para medir presión de precarga.
- Acelerómetro PCB piezotronics modelo 352C33 para medir las vibraciones mecánicas.

7.1.1 Vibraciones mecánicas. Las vibraciones mecánicas se midieron en cuatro sitios diferentes sobre la carcasa de la bomba de la siguiente manera: según la distribución de las horas en el reloj, tres mediciones se llevaron a cabo a las 12, una se tomó sobre el barril de pistones (posición 1), otra sobre el plato rodante (posición 2), y la tercera medición captada a las 12 sobre el plato de válvulas (posición 3), por otro lado una cuarta medición sobre la bomba de precarga se hizo a las 10 (posición 4). Para una ilustración grafica sobre las posiciones mencionadas revise la figura 9.

Figura 8. Puntos de medición en la bomba



Fuente: Eaton Hydrostatic pumps, Repair Information. Series 1 models 33-64. Catálogo. [En línea] Recuperado en 28 diciembre 2016. Disponible en: http://www.fizner.com/3RDP/eaton/site/trans_heavy_duty.htm

Para el acondicionamiento (conversión análogo-digital) de las señales entregadas por los instrumentos descritos se utilizan dos tarjetas National Instrument NI USB-6215 y NI USB-9162 más chasis NI USB-9162, un diagrama de bloque en LabVIEW permite exportar los datos en formato xls y se procede a almacenar 15 muestras de cada instrumento en el dominio de tiempo bajo los siguientes parámetros. ⁵

- Frecuencia de muestreo de 100ks/s, para datos de caudal y presión
- Frecuencia de muestreo de 50ks/s, para datos de vibraciones
- Se tomaron 2^{16} datos por muestra
- Ventana Hanning
- 15 muestras de cada instrumento

⁵ Castillo G. Sergio A, Serrano A. Jhoan R. Metodología de mantenimiento predictivo para diagnóstico de fallas en bombas hidráulicas de pistones axiales asociadas con desgaste de los platos rodantes de presión, Universidad Industrial de Santander 2016

La figura 10 muestra la comparación de la densidad espectral de potencia para las condiciones uno y cinco, como se puede observar existe una diferencia considerable en el comportamiento de la cantidad de energía contenida a bajas y altas frecuencias para ambas condiciones, lo que demuestra la presencia de un comportamiento anómalo. La figura 11 muestra el espectro de la señal de vibración medido en la posición 2 (ver figura 9) para cada condición, allí se nota claramente la variación en aumento de la amplitud de los picos en el intervalo de frecuencias de 10.000 a 15.000 Hz, con esto también se infiere la presencia de un comportamiento anormal por causa del aumento en la severidad de la falla.

Figura 9. Comparación PSD para las condiciones uno y cinco de la bomba




Figura 10. Espectro de vibración para las diferentes condiciones de falla en la bomba




Tabla 4. Condiciones de severidad de la falla, puntos de medición y tipos de señales

CONDICIÓN		Tipo de señal captada					
		Presión de descarga promedio [psi]	Presión de precarga promedio [psi]	Vibración			
				P1	P2	P3	P4
1	Plato de válvulas nuevo 90-95 % eficiencia	717	252	✓	✓	✓	✓
2	Desgaste moderado 85-90 % eficiencia	712	249	✓	✓	✓	✓
3	Desgaste medio 80-85 % eficiencia	707	240	✓	✓	✓	✓
4	Desgaste alto 75-80 % eficiencia	530	131	✓	✓	✓	✓
5	Desgaste severo menor 75 %	484	101	✓	✓	✓	✓

A continuación se muestra una representación matricial de, los datos captados. Cada una de estas matrices se construyó para las cinco condiciones de falla.

$$(Presion\ de\ descarga\ y\ precarga)_i = \begin{bmatrix} P_1(1) & \cdots & P_1(15) \\ \vdots & \ddots & \vdots \\ P_n(1) & \cdots & P_n(15) \end{bmatrix} \quad (6.1)$$

$$(Vibración\ en\ cada\ posición)_i = \begin{bmatrix} V_1(1) & \cdots & V_1(15) \\ \vdots & \ddots & \vdots \\ V_n(1) & \cdots & V_n(15) \end{bmatrix} \quad (6.2)$$


$$i = 1, \dots, 5$$

Figura 11. Banco de pruebas a) real; b) esquema

a) Banco Real



b) Esquema del banco de pruebas




7.2 ADAPTACIÓN DEL ALGORITMO DE DETECCIÓN Y DIAGNOSTICO USANDO PCA-SVM

En esta Sección, se definen los diversos métodos empleados para obtener el algoritmo clasificador con una alta habilidad de generalización. Se aplicó análisis de componentes principales a los requerimientos de detección de la falla y se realizó una adecuación de la técnica de inteligencia artificial máquinas de soporte vectorial para la clasificación de la severidad de las fallas implementadas. Tanto el set de datos entrenamiento como el de validación fue un conjunto de señales reales obtenidas de la simulación de las fallas y los experimentos mencionados en la sección anterior, por lo que se puso a prueba la robustez del sistema de clasificación basado en PCA-SVM. El algoritmo de SVM corresponde al empleado por [51].

7.2.1 Procesamiento de datos. Al set de datos le es aplicado un filtro pasa bajas con la intención de eliminar cualquier presencia de ruido a altas frecuencias (ver figura 13). La frecuencia de corte fue de 25000 Hz pues se notó que las frecuencias de interés en este trabajo estaban entre 10000 y 18000 Hz aproximadamente.

Figura 12. Señal sin filtrar y filtrada a) Señal de presión b) Señal de vibración



Tanto los datos de entrenamiento como los de validación están dispuestos en forma de una matriz $X \in \mathbb{R}^{n \times m}$ con cada columna m representando una variable diferente y donde n es el número de veces de la medición de cada una de ellas.

Para la construcción de la matriz tanto de entrenamiento del modelo como de prueba se tomaron los datos de la siguiente forma (ver tabla 5).

Tabla 5. Distribución de ejemplos de las señales

Tipo de señal	# de ejemplos
Presión de descarga de la bomba: Pd	2
Presión de precarga de bomba: Pp	2
Vibración posición uno: Vp1	2
Vibración posición dos: Vp2	2
Vibración posición tres: Vp3	2
Vibración posición cuatro: Vp5	2

Luego:

$$X_{train} = [Pd_1 Pd_2 Pp_1 Pp_2 Vp1_1 Vp1_2 Vp2_1 Vp2_2 Vp3_1 Vp3_2 Vp4_1 Vp4_2] \quad (6.3)$$

$$X_{test} = [Pd_1 Pd_2 Pp_1 Pp_2 Vp1_1 Vp1_2 Vp2_1 Vp2_2 Vp3_1 Vp3_2 Vp4_1 Vp4_2] \quad (6.4)$$

Y cada vector Pd , Pp , $Vp1$, $Vp2$, $Vp3$, $Vp4$ es de dimensiones $[n \times 1]$ donde

$$n = \text{tiempo de una vuelta del motor} * f_{muestreo} = \frac{1}{20} * 100.000 = 5000 \quad (6.5)$$

Por tanto:

$$X_{train} = \begin{bmatrix} Pd_1 & \cdots & Vp4_1 \\ \vdots & \ddots & \vdots \\ Pd_n & \cdots & Vp4_n \end{bmatrix} \quad (6.6)$$

$$X_{test} = \begin{bmatrix} Pd_1 & \cdots & Vp4_1 \\ \vdots & \ddots & \vdots \\ Pd_n & \cdots & Vp4_n \end{bmatrix} \quad (6.7)$$

Ahora cada matriz de entrenamiento y prueba será de dimensión **5.000**× **12**. Cada una de estas matrices debe ser estandarizada para evitar la posibilidad de que variables particulares dominen inapropiadamente en el procedimiento de la reducción de dimensión. Si $\bar{x}_i$ es la media de la columna x_i con $i = 1, 2, 3 \dots m$ entonces:

$$p_i = x_i - \bar{x}_i \quad (6.8)$$

Cada columna de la matriz centrada respecto a la media **P**, es dividida por su correspondiente desviación estándar

$$p_i^{std} = \frac{p_i}{\sigma_{p_i}} \quad (6.9)$$

$$P_{std} = [p_1^{std} \ p_2^{std} \ p_3^{std} \ \dots \ p_i^{std}] \quad (6.10)$$

Donde la matriz P_{std} ahora es estandarizada con media cero y desviación estándar uno.

7.2.2 Aplicación de análisis de componentes principales. Se desea encontrar una matriz score $T = [t_1, t_2, t_3 \dots t_r]$ también n mediciones pero de menor dimensión $r < m$ con la cual se pueda representar la varianza de la matriz original sin pérdida de información para después transformar el set datos nuevamente al sistema de coordenadas inicial y con esto obtener las variables originales solamente con las varianzas significativas, en esencia, remover efectos de ruido.

Para tal fin se llevó a cabo la metodología planteada en [4] a través de la plataforma MATLAB de la siguiente forma:

Paso 1. Se calculan los valores propios de la matriz X por descomposición en valores singulares (ver capítulo tres).

Paso 2. Es necesario determinar el número a de componentes principales, para ello se diseñó un código el cual basado en el enfoque de porcentaje de varianza acumulada encuentra el número de componentes principales que mejor representa la variabilidad del set de datos de acuerdo a un porcentaje límite definido. Una vez esta cantidad es encontrada se determinan sus correspondientes vectores propios y se procede a armar la matriz de peso P .


La figura 14 muestra que el set de datos original se puede representar con una matriz de menor dimensión conservando aproximadamente el 91% de la variabilidad total si escogemos $a = 10$.

Este resultado muestra una vez más la no linealidad en los equipos con sistemas hidráulicos, porque se evidencia incorrelación en las variables medidas, sin embargo existe una reducción de dimensionalidad que favorece el experimento en este trabajo.

Paso 3: Ahora se tiene la matriz de peso $P \in \mathbb{R}^{m \times a}$ conformada en sus columnas por los a vectores propios de la matriz X ordenados en orden descendiente respecto a la varianza explicada.

Paso 4: Se calcula la matriz score.

Figura 13. Varianza acumulada e individual



$$T = X \times P \quad (6.11)$$

Paso 5: Transformación al sistema de coordenadas inicial.

$$X^* = T \times P^T \quad (6.12)$$

Paso 6: Detección de falla, a cada set de datos:

$$X_{cond_2}, \quad X_{cond_3}, \quad X_{cond_4}, \quad X_{cond_5} \quad \in \quad \mathbb{R}^{n \times m} \quad (6.13)$$

Correspondientes a las cuatro severidades de desgaste le es aplicado el mismo procedimiento descrito en los pasos anteriores y se encuentra:

$$X_{cond_2}^*, \quad X_{cond_3}^*, \quad X_{cond_4}^*, \quad X_{cond_5}^* \quad (6.14)$$

Así, la existencia de un comportamiento anómalo se puede inferir visualmente graficando los datos o midiendo el error $e = X^* - X$.

En las siguientes figuras se puede revisar lo señalado anteriormente. En la figura 15 se observa el set de datos originales para las cinco severidades de falla sobre un espacio tridimensional conformado en el eje x por datos de presión de precarga, en el eje y por datos de presión de descarga y en el eje z por datos de vibración mecánica. En la figura 16 se muestran los mismos datos al ser estandarizados y en la figura 17 se aprecia que después de aplicar el algoritmo de PCA a los datos cada condición se muestra como un clúster que se puede diferenciar sin ningún problema de los demás; característica importante para la clasificación posteriormente.

Figura 14. Datos originales




Figura 15. Datos estandarizados





Figura 16. Datos transformados



7.3 EXTRACCIÓN DE CARACTERÍSTICAS

Se realizó un análisis exploratorio de los datos para determinar cuáles parámetros estadísticos podrían representarlos adecuadamente. Los empleados en este trabajo corresponden a la mayoría de aquellos utilizados en la literatura, especialmente en fuentes como [52][53][36], donde se utilizan para describir las características básicas de los datos en el dominio del tiempo.

Los parámetros extraídos a partir de las señales de presión y vibración se listan a continuación:


- Media
- Desviación estándar
- Varianza
- Kurtosis
- Skewness
- PCA
- RMS de la señal de vibración

7.3.1 Análisis exploratorio de los datos. A continuación se presentan algunas graficas que se usaron para inferir qué parámetros pueden ayudar a diferenciar las condiciones del experimento, estas graficas permiten observar el comportamiento de los sets de datos previamente a la clasificación usando cada uno de los parámetros enunciados anteriormente.

En las figuras 18, 19, 20 y 21 los primeros 5.000 datos corresponden a la condición uno, de 5.001 a 10.000 a la condición dos, de 10.001 a 15.000 a la condición tres, de 15.001 a 20.000 a la condición cuatro y de 20.001 a 25.000 a la condición cinco.

En la figura 18 se grafica el set de datos de entrenamiento después de haber sido tratados con el algoritmo de PCA contra su respectiva media y se puede apreciar que es una característica altamente diferenciadora entre las clases, demuestra la incidencia que tiene como parámetro clasificador importante a la hora del aprendizaje de la máquina de soporte vectorial.

Figura 17. Gráfica de la media de los datos



En las figura 19 y 20 se puede establecer que bajo los parámetros de la desviación estándar y la varianza del set de datos de entrenamiento tratado con el algoritmo de PCA, es posible diferenciar con claridad la condición uno de las condiciones dos, tres y cuatro, sin embargo es fácil observar que estos parámetros pueden no funcionar por sí mismos para diferenciar claramente la condición uno y la condición cinco debido a que tienden al mismo valor.

Figura 18. Gráfica de desviación estándar de los datos






Figura 19. Gráfica de la varianza de los datos



De la figura 21 que representa el resultado del cálculo de la curtosis de los datos se puede llegar a una conclusión similar a la descrita para la figura 18 es una característica altamente diferenciadora entre las clases, aunque podría presentar cierta debilidad a la hora de diferenciar entre las condiciones cuatro y cinco.


Figura 20. Gráfica del valor de la curtosis de los datos



La figura 22 muestra que el parámetro skewness es diferenciador entre las condiciones uno, dos y tres, entre las condiciones uno y cuatro, entre las condiciones uno y cinco, entre las condiciones dos, tres y cuatro y entre las condiciones dos, tres y cinco, sin embargo tendría dificultades a la hora de intentar clasificar entre las condiciones cuatro y cinco.

Al igual que las figuras anteriores, con los siguientes histogramas de frecuencia también es posible deducir el comportamiento de las señales. Un histograma es una representación gráfica de una variable en forma de barras, donde la superficie de cada barra es proporcional a la frecuencia de los valores representados. En el eje vertical se representan las frecuencias, y en el eje horizontal los valores de un parámetro para una determinada clase. En términos matemáticos, puede ser definida como una función inyectiva (o mapeo) que acumula (cuenta) las observaciones que pertenecen a cada subintervalo de una partición.


Figura 21. Gráfica del valor de la asimetría de los datos



La figura 23 muestra los histogramas del primer componente principal del set de datos en el dominio del tiempo de la señales correspondientes a la bomba sin falla (condición uno) en contraste con las cuatro condiciones de severidad (condición dos a la cinco).


En este caso el histograma sugiere que el primer componente principal puede ayudar a diferenciar las cinco condiciones, dado que el histograma correspondiente a las diferentes condiciones en falla tiene una variación significativa en el valor de su respectivo primer componente principal, por cuanto el histograma asociado no es tan uniforme como aquel correspondiente a la condición normal, mostrando una diferencia notable en el comportamiento. Lo que se establece con la simple inspección de cada histograma.

Figura 22. Histograma del primer componente principal de los datos



La figura 24 muestra los histogramas del valor RMS de la señal de vibración para la condición sin falla, en contraste con las demás condiciones en falla y puede establecerse de antemano que este indicador para la señal descrita en el dominio del tiempo es un indicador débil para diferenciar entre la condición uno y las condiciones dos y tres porque su distribución es similar y aunque puede diferenciar entre la condición cuatro y cinco por el valor de su curtosis, existe la probabilidad que se genere confusión a la hora de generalizar. Esto sugiere que este indicador requiere complementarse con algunos otros para evitar problemas de falta de generalización.

Figura 23. Histograma del indicador RMS en el dominio del tiempo de los datos



7.3.2 Selección de parámetros. Esta etapa consiste en seleccionar de los parámetros mencionados, aquellos candidatos que representen completamente el comportamiento del set de datos original para la realización de la clasificación con el fin de simplificar el problema, es decir, nuevos atributos pueden ser creados a partir de los atributos originales para mejorar la capacidad del clasificador y en algunas ocasiones para hacerlo más sensible a una clase en particular. Para ello se realizaron diferentes combinaciones en la creación de la matriz de características de dimensiones $(n + 1)$ columnas, donde n es el número de parámetros y la otra columna almacena las respectivas etiquetas; el número de filas coincide con el número de observaciones y número de filas del vector etiquetas. Por medio de pruebas experimentales en el algoritmo de clasificación se chequeo el rendimiento y eficiencia de la mejor combinación y el resultado de cada prueba se puede verificar en la sección siguiente.

$$\text{Matriz de características } [m \times n] = \begin{bmatrix} 1 & C1 & \dots & Cn \\ \vdots & \vdots & \dots & \vdots \\ m & C1n & \dots & Cnm \end{bmatrix} \quad (6.15)$$

Donde m = número de ejemplos y n = número de características más uno

Cada registro del conjunto de datos tanto de entrenamiento como de prueba contiene un atributo nominal (etiqueta) que determina si existe la falla y su condición de severidad (Cond2,...,Cond5) o no (Cond1). La tabla 6 muestra la etiqueta que corresponde a cada condición.

Tabla 6. Conformación del vector de etiquetas

Clases posibles	Etiqueta
Condición 1	1
Condición 2	2
Condición 3	3
Condición 4	4
Condición 5	5

Basándose en un análisis inferencial de los resultados de la sección anterior, se construyen las combinaciones de parámetros (características) para conformar diferentes matrices y posteriormente validar la que presente mejor desempeño. A continuación, se presentan unos arreglos donde cada V_i con $i = 1, 2, \dots, 5$ representa un vector de $(n \times 1)$ que contiene la característica indicada para la respectiva condición.

Tabla 7. Matriz de características combinación 1

Col/1 Etiquetas	Col/2 Mean	Col/3 Standard	Col/4 Kurtosis
1	V2	V3	V4
2	V2	V3	V4
3	V2	V3	V4
4	V2	V3	V4
5	V2	V3	V4

Tabla 8. Matriz de características combinación 2

Col/1 Etiquetas	Col/2 Mean	Col/3 Skewness	Col/4 Kurtosis
1	V2	V3	V4
2	V2	V3	V4
3	V2	V3	V4
4	V2	V3	V4
5	V2	V3	V4

Tabla 9. Matriz de características combinación 3

Col/1 Etiquetas	Col/2 Mean	Col/3 Standard	Col/4 Kurtosis	Col/5 PCA
1	V2	V3	V4	V5
2	V2	V3	V4	V5
3	V2	V3	V4	V5
4	V2	V3	V4	V5
5	V2	V3	V4	V5

Tabla 10. Matriz de características combinación 4

Col/1 Etiquetas	Col/2 Mean	Col/3 Standard	Col/4 Kurtosis	Col/5 RMS
1	V2	V3	V4	V5
2	V2	V3	V4	V5
3	V2	V3	V4	V5
4	V2	V3	V4	V5
5	V2	V3	V4	V5

Tabla 11. Matriz de características combinación 5

Col/1 Etiquetas	Col/2 Mean	Col/3 Standard	Col/4 Kurtosis	Col/5 RMS	Col/6 PCA
1	V2	V3	V4	V5	V6
2	V2	V3	V4	V5	V6
3	V2	V3	V4	V5	V6
4	V2	V3	V4	V5	V6
5	V2	V3	V4	V5	V6

Tabla 12. Matriz de características combinación 6

Col/1 Etiquetas	Col/2 Mean	Col/3 Standard	Col/4 Kurtosis	Col/5 Skewness	Col/6 PCA
1	V2	V3	V4	V5	V6
2	V2	V3	V4	V5	V6
3	V2	V3	V4	V5	V6
4	V2	V3	V4	V5	V6
5	V2	V3	V4	V5	V6

7.4 ADAPTACIÓN DEL ALGORITMO CLASIFICADOR

En esta sección se presenta la metodología desarrollada para la aplicación del algoritmo clasificador SVM de [51] con los parámetros propuestos en la sección anterior.

7.4.1 Datos en formato libsvm. Después de determinar la matriz de características tanto para el set de entrenamiento como para el set de pruebas, es necesario convertir los datos a un formato compatible con la librería utilizada. Es importante que las clases estén definidas adecuadamente, así como los atributos correspondientes que hacen que un conjunto de datos defina a que clase pertenece.

Paso 1: Convertir los datos de formato .mat a formato .csv.

Paso 2: Leer el formato .csv y convertir las columnas de las características en datos sparse.

Paso 3: convertir en formato libsvm el vector de etiquetas junto con los datos sparse creados antes.

7.4.2 Validación cruzada. En esta etapa del proceso ya se cuenta con set de entrenamiento robusto y adecuado para la aplicación del algoritmo de clasificación SVM, cuya tarea es buscar un conjunto de patrones que le permitan identificar una clase en función de un conjunto de atributos.

Para el entrenamiento de la máquina de soporte vectorial a través de libsvm es necesario especificar algunos parámetros (C y γ) que tienen una alta influencia en la precisión del algoritmo y la misma librería provee una sencilla herramienta que a través de validación cruzada permite encontrarlos. Esta herramienta utiliza un kernel

de base radial, este kernel no correlaciona las muestras en un espacio dimensional superior a diferencia del kernel lineal, puede manejar casos donde la relación entre los rótulos de la clase y los atributos no es lineal, por otro lado el kernel lineal es un caso especial de RBF puesto que con un parámetro de penalización C tiene el mismo rendimiento que el núcleo RBF con algunos parámetros (C y γ). Otra razón es el número de hiperparámetros que influye en la complejidad de la selección del modelo, el kernel polinomial tiene más hiperparametros que el kernel RBF y finalmente, el kernel RBF tiene menos dificultades numéricas. Hay algunas situaciones en las que el kernel RBF no es adecuado. En particular, cuando el número de características es muy grande.[54]

7.4.3 Modelo de diagnóstico. Una vez encontrados los parámetros C y γ se procede al desarrollo de la arquitectura final que también involucra determinar cuál función kernel optimiza la exactitud del modelo, recordando que el papel de las funciones kernel es mapear los vectores de parámetros en espacios de dimensión superior a la original, por medio de un producto interno en el espacio de dimensión superior. Esto es importante, ya que todas las operaciones del algoritmo de SVM se pueden expresar en términos de productos punto; para lograr resolver el problema de optimización en un espacio de dimensión superior, se evalúan los productos internos como el resultado de las funciones de kernel[10].

En resumen, los pasos a seguir para cada prueba son:

Paso 1: Se fija el valor de γ y se hace un barrido de valores para C evaluando en cada iteración la precisión del clasificador hasta obtener el C que presenta mejor rendimiento.

Paso 2: Con el valor de C fijado en el paso anterior, se procede a realizar el barrido de γ hasta encontrar su óptimo.


Paso 3: Con los valores de C , γ y un kernel RBF se construye un modelo de clasificación multiclase uno contra el resto.

Paso 4: De forma iterativa se calcula nuevamente cada parámetro hasta encontrar aquellos que permitan que el modelo de clasificación presente mayor exactitud.

Paso 5: Con los valores de C y γ se crea la arquitectura de clasificación multiclase uno contra uno y se entrena el modelo.

Paso 6: Se prueba el modelo con el set de datos de prueba midiendo el desempeño y precisión obtenida mediante la variación del kernel.

Figura 24. Esquema del proceso



8. PRUEBAS Y RESULTADOS

Esta sección presenta los resultados obtenidos con la arquitectura a dos niveles expuesta en el capítulo anterior y permite mostrar la fortaleza del sistema de detección y diagnóstico de fallas basado en PCA-SVM planteado.

A continuación se muestra un resumen detallado de las pruebas realizadas al algoritmo de detección y diagnóstico de fallas y los resultados obtenidos en cada una de ellas.

8.1 PRUEBAS

Se realizaron seis pruebas, una por cada matriz de características definida en la sección anterior (6.3.2) y cada una de ellas se evaluó la efectividad de clasificación con cada uno de los cuatro kernels (lineal polinomial, rbf y sigmoide).

El conjunto de pruebas descrito con anterioridad, se desarrolló para dos modelos diferentes, el modelo uno fue entrenado con 5000 muestras y el modelo dos fue entrenado realizando un sub-muestreo de la señal de presión a 50.000 *samples/s* con la intención de manejar la misma frecuencia de muestreo en presión y vibración el tamaño de muestras para este modelo fue de 2500. Ambos modelos se probaron con 1000 muestras de la matriz de pruebas y el modelo uno fue el que presentó mejor desempeño a la hora de la clasificación, por tal motivo no se presentan los resultados obtenidos con el modelo dos sin embargo en las conclusiones se indica el porcentaje de precisión obtenido con dicho modelo.

8.1.1 Prueba 1. La tabla 13 presenta el resultado de la exactitud de clasificación para cada condición por cada Kernel y la tabla 14 los parámetros respectivos arrojados por el modelo cuando este se probó con:

- Matriz de características: Combinación 1 (ver tabla 7).
- Mejor $C = 8$, mejor $\gamma = 1$

Tabla 13. Resultados prueba 1

Set de datos de prueba	Exactitud de clasificación por Kernel [%]			
	Lineal	Polinómica	RBF	Sigmoide
Condición 1	99.8	99.9	99.8	0
Condición 2	100	100	100	0
Condición 3	97.5	89.2	95.8	1.3
Condición 4	100	100	100	0
Condición 5	100	100	100	0

Tabla 14. Parámetros prueba 1

Parámetro	Kernel			
	Lineal	Polinómico	RBF	Sigmoide
optimization finished, #iter	6	7	22	836
rho (término bias)	2,083715	1,26884	0,030142	456
d (exponente)	N/A	3	N/A	N/A
Total nSV	28	19	26	20000

8.2.2 Prueba 2

La tabla 15 presenta el resultado de la exactitud de clasificación para cada condición por cada Kernel y la tabla 16 los parámetros respectivos arrojados por el modelo cuando este se probó con:

- Matriz de características: Combinación 2 (ver tabla 8).
- Mejor $C = 8$, mejor $\gamma = 1$

Tabla 15. Resultados prueba 2

Set de datos de prueba	Exactitud de clasificación por Kernel [%]			
	Lineal	Polinomial	RBF	Sigmoide
Condición 1	99.8	99.5	99.8	0
Condición 2	100	100	100	0
Condición 3	77	75.1	77.2	3.7
Condición 4	100	100	100	0
Condición 5	100	100	100	0

Tabla 16. Parámetros prueba 2

Parámetro	Kernel			
	Lineal	Polinómico	RBF	Sigmoide
optimization finished, #iter	5	13	16	273
rho (término bias)	1,849296	1,27509	0,028676	544
d (exponente)	N/A	3	N/A	N/A
Total nSV	32	19	29	20000

8.2.3 Prueba 3. La tabla 17 presenta el resultado de la exactitud de clasificación para cada condición por cada Kernel y la tabla 18 los parámetros respectivos arrojados por el modelo cuando este se probó con:

- Matriz de características: Combinación 3 (ver tabla 9).
- Mejor $C = 8$, mejor $\gamma = 1$

Tabla 17. Resultados prueba 3

Set de datos de prueba	Exactitud de clasificación por Kernel [%]			
	Lineal	Polinomial	RBF	Sigmoide
Condición 1	99.8	89.2	94.4	31.9
Condición 2	100	100	100	33.9
Condición 3	95.9	87.3	93.3	0.3
Condición 4	100	100	100	38
Condición 5	100	100	100	0

Tabla 18. Parámetros prueba 3

Parámetro	Kernel			
	Lineal	Polinómico	RBF	Sigmoide
optimization finished, #iter	783	260	539	1724
rho (término bias)	2,166456	1,262429	0,113928	-2.908
d (exponente)	N/A	3	N/A	N/A
Total nSV	33	49	152	18289

8.2.4 Prueba 4. La tabla 19 presenta el resultado de la exactitud de clasificación para cada condición por cada Kernel y la tabla 20 los parámetros respectivos arrojados por el modelo cuando este se probó con:

- Matriz de características: Combinación 4 (ver tabla 10).
- Mejor $C = 8$, mejor $\gamma = 1$

Tabla 19. Resultados prueba 4

Set de datos de prueba	Exactitud de clasificación por Kernel [%]			
	Lineal	Polinomial	RBF	Sigmoide
Condición 1	99.8	99.9	99.6	4.6
Condición 2	100	100	100	0.9
Condición 3	96.2	90.4	95.3	8.2
Condición 4	100	100	100	97.5
Condición 5	100	100	100	0

Tabla 20. Parámetros prueba 4

Parámetro	Kernel			
	Lineal	Polinómico	RBF	Sigmoide
optimization finished, #iter	4837	70	736	3816
rho (término bias)	2,096207	1,270644	-0,007583	1,4705
d (exponente)	N/A	3	N/A	N/A
Total nSV	34	32	147	19474

8.2.5 Prueba 5. La tabla 21 presenta el resultado de la exactitud de clasificación para cada condición por cada Kernel y la tabla 22 los parámetros respectivos arrojados por el modelo cuando este se probó con:

- Matriz de características: Combinación 5 (ver tabla 11).
- Mejor $C = 8$, mejor $\gamma = 1$

Tabla 21. Resultados prueba 5

Set de datos de prueba	Exactitud de clasificación por Kernel [%]			
	Lineal	Polinomial	RBF	Sigmoide
Condición 1	99.8	95.2	90.8	33.9
Condición 2	100	100	100	8
Condición 3	96.1	89.2	93.7	1.5
Condición 4	100	100	100	36.1
Condición 5	100	100	99.9	0

Tabla 22. Parámetros prueba 5

Parámetro	Kernel			
	Lineal	Polinómico	RBF	Sigmoide
optimization finished, #iter	7556	1668	2268	2966
rho (término bias)	2,252315	1,321291	-0,080772	10,6587
d (exponente)	N/A	3	N/A	N/A
Total nSV	45	67	571	17414

8.2.6 Prueba 6. La tabla 23 presenta el resultado de la exactitud de clasificación para cada condición por cada Kernel y la tabla 24 los parámetros respectivos arrojados por el modelo cuando este se probó con:

- Matriz de características: Combinación 6 (ver tabla 12).
- Mejor $C = 8$, mejor $\gamma = 1$

Tabla 23. Resultados prueba 6

Set de datos de prueba	Exactitud de clasificación por Kernel [%]			
	Lineal	Polinomial	RBF	Sigmoide
Condición 1	100	84.1	93	25.1
Condición 2	100	100	100	32.4
Condición 3	88.4	83.6	86.4	1.1
Condición 4	100	100	100	16.6
Condición 5	100	100	100	17.7

Tabla 24. Parámetros prueba 6

Parámetro	Kernel			
	Lineal	Polinómico	RBF	Sigmoide
optimization finished, #iter	1159	411	476	2744
rho (término bias)	2,270562	1,270449	-0,088728	6607,09218
d (exponente)	N/A	3	N/A	N/A
Total nSV	43	52	159	18909

A continuación, la figura 26 muestra el resumen de los resultados obtenidos para cada prueba anterior.

Figura 25. Resumen resultados de pruebas



8.3 ANÁLISIS DE RESULTADOS

Los siguientes diagramas de barras resumen los resultados obtenidos en la experimentación para los diferentes escenarios estudiados, presentando la comparación entre los porcentajes de exactitud de predicción obtenidos con las diferentes combinaciones de matrices de características y cada kernel, excepto el

sigmoide que no fue tenido en cuenta por el bajo desempeño que mostró a la hora de clasificar.

Las pruebas experimentales mostraron que los indicadores propuestos basados en la señal de presión y vibración no solo permiten la detección de la falla de pérdida de eficiencia volumétrica por desgaste en el plato de válvulas sino que también permite determinar su grado de severidad.

Figura 26. Exactitud de predicción condición 1




Figura 27. Exactitud de predicción condición 2




Figura 28. Exactitud de predicción condición 3




Figura 29. Exactitud de predicción condición 4





Figura 30. Exactitud de predicción condición 5



Finalmente, después de haber extraído diferentes características de los datos y probado diferentes funciones kernel y los parámetros asociados a dichas funciones, se selecciona el modelo que ofrece el mejor desempeño que para este caso de estudio fue:

Tabla 25. Estructura del modelo

PARÁMETRO	DESCRIPCIÓN
Tipo	Clasificador SVM C-SVC
Kernel	RBF
C	8
Gamma	1
Rho (termino bias)	0.030142
Total nSV	26
Matriz de características	Combinación 1 (Curtosis media y desviación estándar).

9. APORTES

Construcción de un banco de pruebas en el cual se pueden inducir y caracterizar diferentes tipos de fallas concernientes a sistemas equipados con hidrotransmisiones y motores eléctricos.

Se investigó acerca de los parámetros empleados en la detección de fallas en bombas de pistones axiales y se probó el desempeño de las máquinas de aprendizaje en una situación real.

Se adaptó un algoritmo de máquinas de soporte vectorial a una aplicación de mantenimiento predictivo para bombas de pistones axiales. Se encontraron resultados que permiten detectar la falla en distintas condiciones de severidad.

Se realizó una ponencia en una convención científica internacional con la metodología de máquinas de soporte vectorial y detección y diagnóstico de fallas.

Se está escribiendo un artículo para publicación en revista indexada por Colciencias.

Se generaron los siguientes proyectos de pregrado:

- Metodología de mantenimiento predictivo para diagnóstico de fallas en bombas hidráulicas de pistones axiales asociadas con desgaste de los platos rodantes de presión / Sergio Andrés Castillo Gómez, Jhoan Ricardo Serrano Arias; Director Carlos Borrás Pinilla., PhD. Escuela de Ingeniería Mecánica.
- Rediseño y construcción de un banco de pruebas para diagnóstico de fallas en una hidrottransmisión bomba variable - motor fijo / Yosmer David Bolaño Diaz, Arnulfo Javier Niño Duarte; Director Carlos Borrás Pinilla., PhD. Escuela de Ingeniería Mecánica.

10. RECOMENDACIONES

Acondicionar con más sensores el banco de pruebas y caracterizar diferentes tipos de fallas con el fin de probar si el modelo planteado en este trabajo permite detectarlas y clasificarlas, además de proponer otros algoritmos o nuevas estrategias para arquitecturas de detección y diagnóstico de fallas basado en máquinas de aprendizaje

Ampliar el estudio del estado del arte en detección y diagnóstico de fallas.

11. CONCLUSIONES

Se adaptó una arquitectura offline para detección y diagnóstico de falla por pérdida de eficiencia volumétrica en una bomba de pistones axiales basado en SVM y PCA usando la información transportada por la señal de presión y vibración.

Se realizó la detección y clasificación de la falla por pérdida de eficiencia volumétrica debida a desgaste en el plato de válvulas en cuatro grados distintos de severidad en un banco de pruebas industrial construido para tal fin. y se obtuvo una precisión promedio cercana al 99 % para cada caso.

La función kernel sigmoide, mostró bajo desempeño de clasificación en el modelo desarrollado, el promedio estuvo cercano al 13%, por tal motivo fue la primer función que se descartó.

Las funciones kernel Lineal, RBF y polinomial para este caso de estudio exhibieron los mejores desempeños en la validación con datos en las pruebas, promedio 98, 97 y 96 % respectivamente y se propone seleccionar en el modelo final el kernel RBF puesto que presenta buen desempeño y es el más recomendado en la literatura.

Los parámetros estadísticos que representaron mejor los datos fueron: la curtosis, la media y la desviación estándar. Con la matriz de características conformada por ellas y el kernel RBF se obtuvo un desempeño promedio de clasificación del 99%.

La señal de aceleración no fue influyente en este caso, la falla estudiada puede ser detectada y clasificado su grado de severidad con datos obtenidos en señales de presión de descarga y precarga de la bomba.

12. CITAS BIBLIOGRÁFICAS

- [1] BORRAS, C. “Técnicas Avanzadas de mantenimiento,” *Universidad Industrial de Santander*, 2016.
- [2] LI, Z. “Condition Monitoring of Axial Piston Pump,” University of Saskatchewan, 2005.
- [3] WATTON, J. *Modelling, Monitoring and Diagnostic Techniques for Fluid Power Systems*. Wales: Springer, 2007.
- [4] ISERMANN, R. *Fault-diagnosis systems: An introduction from fault detection to fault tolerance*. 2006.
- [5] PATTERSON-HINE G. Aaseng, G. Biswas, S. Narasimhan, and K. Pattipati, “A Review of Diagnostic Techniques for ISHM Applications,” *NASA Ames Research Center Honeywell Defense & Space Electronics Systems*, vol. 1, 2005.
- [6] MANRIQUE, R. F. “Detección y diagnóstico de fallas en turbinas de viento usando técnicas de minería de datos,” p. 126, 2012.
- [7] ISERMANN, R. “Model-based fault-detection and diagnosis – status and applications,” *Annual Reviews in Control*, vol. 29, no. 1, pp. 71–85, 2005.
- [8] ISERMANN, R. “Model based fault detection and diagnosis methods,” *Proceedings of 1995 American Control Conference - ACC’95*, vol. 3, pp. 1605–1609, 1995.
- [9] LAZARO, J. M. B. Prieto-moreno, and O. Llanes-santiago, “Estudio comparativo de clasificadores empleados en el diagnóstico de fallos de sistemas industriales,” *Ingeniería Mecánica ISSN 1815-5944*, vol. 14, no. 2, pp. 87–98, 2011.
- [10] OVIEDO, S., QUIROGA, J. and BORRAS, C. “Detección de fallas en Motores de Inducción usando MCSA (Motor Current Signature Analysis) y Maquinas de Soporte Vectorial,” *Universidad Industrial de Santander*, p. 102, 2011.
- [11] CASTAÑEDA, M. and BORRÁS, C. “Diagnóstico de Fallas en Maquinaria Rotativa por Análisis de Vibraciones Basado en Maquinas de Soporte

Vectorial,” Universidad Industrial de Santander, 2014.

- [12] LIU, Y. and LIU, T. “Rotating Machinery Fault Diagnosis Based on Support Vector Machine,” *2010 International Conference on Intelligent Computing and Cognitive Informatics*, no. 1, pp. 71–74, 2010.
- [13] RAVIKUMAR, B., D. Thukaram, and H. P. Khincha, “Application of support vector machines for fault diagnosis in power transmission system,” *IET Gener. Transm. Distrib.*, vol. 2, no. 1, pp. 119–130, 2008.
- [14] LAOUTI, N. Sheibat-othman, and S. Othman, “Support Vector Machines for Fault Detection in Wind Turbines,” *18th IFAC World Congress*, pp. 7067–7072, 2011.
- [15] DEMETGUL, M. “Fault diagnosis on production systems with support vector machine and decision trees algorithms,” *Int J Adv Manuf Technol*, pp. 2183–2194, 2013.
- [16] HU, X. “Study on Fault diagnosis of hydraulic pump Based on sphere-structured support vector machines,” *IEEE*, pp. 2894–2896, 2012.
- [17] TIAN, J., M. Gao, K. Li, and H. Zhou, “Fault Detection of Oil Pump Based on Classify Support Vector Machine,” *IEEE International Conference on Control and Automation Guangzhou, CHINA*, vol. 0, pp. 549–553, 2007.
- [18] HELWIG, N. S. Klein, and A. Schutze, “Identification and quantification of hydraulic system faults based on multivariate statistics using spectral vibration Features,” *Procedia Engineering*, vol. 120, pp. 1225–1228, 2015.
- [19] BORRÁS, C. “Pattern Recognition in Hydraulic Backlash using Neuronal Network,” *IEEE, Proceedings of the American Control Conference, Anchorage, Alaska*, vol. 1, pp. 400–405, 2002.
- [20] QUIROGA, J. and S. Oviedo, “Detección de cavitación en una bomba centrífuga usando emisiones acústicas Cavitation detection in a centrifugal pump using acoustic emissions,” *Ingeniare. Revista chilena de ingeniería*, vol. 20, no. 3, pp. 343–349, 2012.
- [21] HE, Z., S. Wang, K. Wang, and K. Li, “Prognostic Analysis Based on Hybrid Prediction Method for Axial Piston Pump,” *IEEE*, pp. 688–692, 2012.

- [22] WANG, Z. and Z. Wang, "Chaotic Parallel Support Vector Machine and Its Application for Fault Diagnosis of Hydraulic Pump," *IEEE*, 2013.
- [23] SHENG, L., Z. Peilin, and W. Guode, "Hydraulic System Faults Diagnosis Based on Multi-class Support Vector Machine," *2010 International Conference on Digital Manufacturing & Automation*, pp. 812–814, 2010.
- [24] WANG, H. and P. Chen, "Intelligent Method for Condition Diagnosis of Pump System Using Discrete Wavelet Transform , Rough Sets and Neural Network," *IEEE*, pp. 24–28, 2007.
- [25] PLAWIAK, P. "An estimation of the state of consumption of a positive displacement pump based on dynamic pressure or vibrations using neural networks," *Neurocomputing*, vol. 144, pp. 471–483, 2014.
- [26] DONG, M. and D. He, "A segmental hidden semi-Markov model (HSMM)-based diagnostics and prognostics framework and methodology," *Mechanical Systems and Signal Processing*, vol. 21, no. 5, pp. 2248–2266, 2007.
- [27] HONGZHI, Y. and T. Guanzheng, "Fault Diagnosis of Hydraulic Pumps Using Improved Neural Network," *J. Cent. South Univ. Technol.*, vol. 2, no. 1, pp. 64–68, 1995.
- [28] LIU, S. "Pulsating Parameter Method for Fault Diagnosis for a Hydraulic Pump," *I ECON'91*, vol. 2, pp. 2145–2150, 1991.
- [29] GAO, Y. Q. Zhang, and X. Kong, "Wavelet Based Pressure Analysis for Hydraulic Pump Health Diagnosis," *Transactions of the ASAE*, vol. 46, no. 4, 2003.
- [30] GAO, Y. and Q. Zhang, "A Wavelet Packet and Residual Analysis Based Method for Hydraulic Pump Health Diagnosis," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 220, no. 6, pp. 735–745, 2006.
- [31] SIYUAN, L. D. Linlin, and J. Wanlu, "Study on application of Principal Component Analysis to fault detection in hydraulic pump," *Proceedings of 2011 International Conference on Fluid Power and Mechatronics*, no. 4, pp. 173–178, 2011.

- [32] LIU, S. W. Jiang, and J. Wang, "Fault diagnosis based on characteristics of the vibration energy on the hydraulic pump," *Mechanic Automation and Control Engineering (MACE)*, 2010 International Conference on, no. 50775198, pp. 2601–2605, 2010.
- [33] ZHAO, Z. M. Jia, F. Wang, and S. Wang, "Intermittent chaos and sliding window symbol sequence statistics-based early fault diagnosis for hydraulic pump on hydraulic tube tester," *Mechanical Systems and Signal Processing*, vol. 23, no. 5, pp. 1573–1585, 2009.
- [34] SMITH, L. I. "A tutorial on Principal Components Analysis Introduction," *Statistics*, vol. 51, p. 52, 2002.
- [35] CUADRAS, C. M. *Nuevos métodos de análisis multivariante*. Barcelona, España, 2014.
- [36] KROGERUS, T. *Feature Extraction and Self-Organizing Maps in Condition Monitoring of Hydraulic Systems*. 2011.
- [37] CORTES, C. and V. Vapnik, "Support-Vector Networks," *Machine Learning*, 20, 273-297, vol. 297, pp. 273–297, 1995.
- [38] STOEAN, C. and R. Stoean, *Support Vector Machines and Evolutionary Algorithms for Classification. Single or Together*. 2014.
- [39] JIMENEZ, L. and P. Rengifo, "Al Interior de una Máquina de Soporte Vectorial," *Revista de Ciencias Universidad del Valle*, vol. 14, pp. 73–85, 2010.
- [40] GILLIES, D. F. "Intelligent Data Analysis and Probabilistic Inference Lecture 18: Support Vector Machines," pp. 1–4, 2006.
- [41] BURGESS, C. "A Tutorial on Support Vector Machines for Pattern Recognition," *Data Mining and Knowledge Discovery*, vol. 2, no. 2, pp. 121–167, 1998.
- [42] RODRIGUEZ, J. C. Suarez, "Detección y Localización de Fallas en los Sistemas de Energía Mediante la Técnica Máquinas de Soporte Vectorial (SVM)," Universidad Industrial de Santander, 2006.
- [43] MALDONADO, R. Sebastián; Weber, "Modelos de Selección de Atributos para Support Vector Machines," *Revista Ingeniería de Sistemas*, pp. 49–70, 2012.

- [44] GUNN, S. R. "Support vector machines for classification and regression.," 1998.
- [45] WIDODO, A. and B. S. Yang, "Support Vector Machine in Machine Condition Monitoring and Fault Diagnosis," *Mechanical Systems and Signal Processing*, vol. 21, no. 6, pp. 2560–2574, 2007.
- [46] FLOREZ, J. José, M. España, and S. P. Londoño, "Classification methodology and feature selection to assist fault location in power distribution systems Metodología de clasificación y de selección de atributos para localización de fallas en sistemas de distribución de energía eléctrica," *Rev. Fac. Ing. Univ. Antioquia*, vol. 44, pp. 83–96, 2008.
- [47] YUAN, S. F. and F. L. Chu, "Support vector machines-based fault diagnosis for turbo-pump rotor," *Mechanical Systems and Signal Processing*, vol. 20, no. 4, pp. 939–952, 2006.
- [48] CERVANTES, J. "Clasificación de grandes conjuntos de datos vía máquinas de vectores soporte y aplicaciones en sistemas biológicos," ... *de computación, Centro de investigación y de estudios ...*, 2009.
- [49] CAMPBELL, C. and Y. Ying, *Learning with Support Vector Machines*. 2011.
- [50] HSU, C. W. and C. J. Lin, "A comparison of methods for multiclass support vector machines," *IEEE Transactions on Neural Networks*, vol. 13, no. 2, pp. 415–425, 2002.
- [51] CHANG, C. and C. Lin, "LIBSVM: A Library for Support Vector Machines," *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol. 2, pp. 1–39, 2013.
- [52] LOUTAS, T. and V. Kostopoulos, "Utilising the Wavelet Transform in Condition-Based Maintenance: A Review with Applications," *Advances in Wavelet Theory and Their Applications in Engineering, Physics and Technology*, pp. 273–312, 2012.
- [53] BAYER, C. "Modeling of hydraulic axial piston pumps including specific signs of wear and tear Modelica model," *Proceedings 8th Modelica Conference, Dresden, Germany*, pp. 461–466, 2011.

- [54] HSU, C.-W. C.-C. Chang, and C.-J. Lin, “A Practical Guide to Support Vector Classification,” *BJU international*, vol. 101, no. 1, pp. 1396–400, 2008.

BIBLIOGRAFÍA

BAYER, C. . Modeling of hydraulic axial piston pumps including specific signs of wear and tear Modelica model. *Proceedings 8th Modelica Conference, Dresden, Germany*, 2011. 461–466.

BORRÁS, C. Pattern Recognition in Hydraulic Backlash using Neuronal Network. *IEEE, Proceedings of the American Control Conference, Anchorage, Alaska*, 2002 1, 400–405. [En línea]. Citado en 15 enero 2017. Disponible en: <http://doi.org/10.1017/CBO9781107415324.004>

BORRÁS, C. . Técnicas Avanzadas de mantenimiento. 2016. *Universidad Industrial de Santander*.

BURGES, C. . A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 1998. 2(2), 121–167.

CAMPBELL, C., & Ying, Y. *Learning with Support Vector Machines. Learning with Support Vector Machines*. 2011. Disponible en: <http://doi.org/10.2200/S00324ED1V01Y201102AIM010>

CASTAÑEDA, M., & Borrás, C. *Diagnóstico de Fallas en Maquinaria Rotativa por Análisis de Vibraciones Basado en Maquinas de Soporte Vectorial*. Universidad Industrial de Santander. 2014

CERVANTES, J. Clasificación de grandes conjuntos de datos vía máquinas de vectores soporte y aplicaciones en sistemas biológicos. ... *de Computación, Centro de Investigación Y de Estudios*. 2009.[En línea]. Citado en 15 enero 2017. Disponible en:

<http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Clasificación+de+grandes+conjuntos+de+datos+vía+Máquinas+de+Vectores+Soporte+y+aplicaciones+en+sistemas+biológicos+Tesis+que+presenta+:#0%5Cnhttp://scholar.google.com/scholar?hl=en&btnG=Search&>

CHANG, C., & Lin, C. LIBSVM: A Library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2013. 2, 1–39. <http://doi.org/10.1145/1961189.1961199>

CORTES, C., & Vapnik, V. Support-Vector Networks. *Machine Learning*, 1995. 20, 273–297, 297, 273–297.

CUADRAS, C. M. *Nuevos métodos de análisis multivariante*. CMC Editions. Barcelona, España. 2014

DEMETGUL, M. Fault diagnosis on production systems with support vector machine and decision trees algorithms. *Int J Adv Manuf Technol*, 2013. 2183–2194.

DONG, M., & He, D. A segmental hidden semi-Markov model (HSMM)-based diagnostics and prognostics framework and methodology. *Mechanical Systems and Signal Processing*, 2007. 21(5), 2248–2266.

GAO, Y., & Zhang, Q. A Wavelet Packet and Residual Analysis Based Method for Hydraulic Pump Health Diagnosis. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 2006. 220(6), 735–745.

GILLIES, D. F. Intelligent Data Analysis and Probabilistic 2006. Inference Lecture 18: Support Vector Machines, 1–4.

GUNN, S. R. *Support vector machines for classification and regression*. University

of Southampton. 1998

HE, Z., Wang, S., Wang, K., & Li, K. Prognostic Analysis Based on Hybrid Prediction Method for Axial Piston Pump. 2012. *IEEE*, 688–692.

HELVIG, N., Klein, S., & Schutze, A. Identification and quantification of hydraulic system faults based on multivariate statistics using spectral vibration Features. 2015. [En línea]. *Procedia Engineering*, 120, 1225–1228. Disponible en: <http://doi.org/10.1016/j.proeng.2015.08.835>

HONGZHI, Y., & Guanzheng, T. Fault Diagnosis of Hydraulic Pumps Using Improved Neural Network. *J. Cent. South Univ. Technol.*, 1995. 2(1), 64–68.

HSU, C.-W., Chang, C.-C., & Lin, C.-J. A Practical Guide to Support Vector Classification. *BJU International*, 101(1), 1396–400. 2008. [En línea]. Disponible en: <http://doi.org/10.1177/02632760022050997>

HSU, C. W., & Lin, C. J. A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks*, 13(2), 415–425. 2002. [En línea]. Disponible en: <http://doi.org/10.1109/72.991427>

HU, X. Study on Fault diagnosis of hydraulic pump Based on sphere-structured support vector machines. *IEEE*, 2894–2896. 2012.

ISERMANN, R. Model based fault detection and diagnosis methods. *Proceedings of 1995 American Control Conference - ACC'95*, 3, 1605–1609. 1995. [En línea]. Disponible en: <http://doi.org/10.1109/ACC.1995.529778>

ISERMANN, R. Model-based fault-detection and diagnosis – status and applications. *Annual Reviews in Control*. 2005. 29(1), 71–85. <http://doi.org/10.1016/j.arcontrol.2004.12.002>

ISERMANN, R. *Fault-diagnosis systems: An introduction from fault detection to fault tolerance. Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance*. 2006. [En línea]. Citado en 15 enero 2017. Disponible en: <http://doi.org/10.1007/3-540-30368-5>

JIMENEZ, L., & Rengifo, P. Al Interior de una Máquina de Soporte Vectorial. 2010. *Revista de Ciencias Universidad Del Valle*, 14, 73–85.

JOSÉ, J., FLÓREZ, M., España, G. M., & Londoño, S. P. Classification methodology and feature selection to assist fault location in power distribution systems Metodología de clasificación y de selección de atributos para localización de fallas en sistemas de distribución de energía eléctrica. 2008. *Rev. Fac. Ing. Univ. Antioquia*, 44, 83–96.

KROGERUS, T. *Feature Extraction and Self-Organizing Maps in Condition Monitoring of Hydraulic Systems. ... teknillinen yliopisto. Julkaisu-Tampere University of* 2001. [En línea]. Citado en 15 enero 2017. Disponible en: <http://dspace.cc.tut.fi/dpub/handle/123456789/20613>

LAOUTI, N., Sheibat-othman, N., & Othman, S. Support Vector Machines for Fault Detection in Wind Turbines. 2011. *18th IFAC World Congress*, 7067–7072.

LÁZARO, J. M. B., Prieto-moreno, A., & Llanes-santiago, O. Estudio comparativo de clasificadores empleados en el diagnóstico de fallos de sistemas industriales. 2011. *Ingeniería Mecánica ISSN 1815-5944*, 14(2), 87–98.

LI, Z. *Condition Monitoring of Axial Piston Pump. University of Saskatchewan*. 2005. University of Saskatchewan.

LIU, S. Pulsating Parameter Method for Fault Diagnosis for a Hydraulic Pump. 1991.

I ECON'91, 2, 2145–2150.

LIU, S., Jiang, W., & Wang, J. Fault diagnosis based on characteristics of the vibration energy on the hydraulic pump. *Mechanic Automation and Control Engineering (MACE), 2010 International Conference on*, (50775198), 2601–2605.

LIU, Y., & Liu, T. Rotating Machinery Fault Diagnosis Based on Support Vector Machine. *2010 International Conference on Intelligent Computing and Cognitive Informatics*, (1), 71–74.

LOUTAS, T., & Kostopoulos, V. Utilising the Wavelet Transform in Condition-Based Maintenance : A Review with Applications. *Advances in Wavelet Theory and Their Applications in Engineering, Physics and Technology*. 2012. pp. 273–312.

MALDONADO, Sebastián; Weber, R. Modelos de Selección de Atributos para Support Vector Machines. 2012. *Revista Ingeniería de Sistemas*, 49–70.

MANRIQUE, R. F. Detección y diagnóstico de fallas en turbinas de viento usando técnicas de minería de datos, 126. 2012. [En línea]. Citado en 15 enero 2017. Disponible en: <http://www.bdigital.unal.edu.co/10309/>

OVIEDO, S., Quiroga, J., & Borrás, C. Detección de fallas en Motores de Inducción usando MCSA (Motor Current Signature Analysis) y Maquinas de Soporte Vectorial. 2011. *Universidad Industrial de Santander*, 102.

PATTERSON-HINE, Aaseng, G., Biswas, G., Narasimhan, S., & Pattipati, K. A Review of Diagnostic Techniques for ISHM Applications. *NASA Ames Research Center Honeywell Defense & Space Electronics Systems*, 1. 2005.

PŁAWIAK, P. An estimation of the state of consumption of a positive displacement

pump based on dynamic pressure or vibrations using neural networks. 2014. *Neurocomputing*, 144, 471–483. [En línea]. Citado en 15 enero 2017. Disponible en: <http://doi.org/10.1016/j.neucom.2014.04.026>

QUIROGA, J., & Oviedo, S. Detección de cavitación en una bomba centrífuga usando emisiones acústicas Cavitation detection in a centrifugal pump using acoustic emissions. 2012. *Ingeniare. Revista Chilena de Ingeniería*, 20(3), 343–349.

Ravikumar, B., Thukaram, D., & Khincha, H. P. Application of support vector machines for fault diagnosis in power transmission system. 2008. *IET Gener. Transm. Distrib*, 2(1), 119–130.

RODRIGUEZ SUAREZ, J. C. *Detección y Localización de Fallas en los Sistemas de Energía Mediante la Técnica Máquinas de Soporte Vectorial (SVM)*. 2006. Universidad Industrial de Santander.

SHENG, L., Peilin, Z., & Guode, W. Hydraulic System Faults Diagnosis Based on Multi-class Support Vector Machine. 2010 *International Conference on Digital Manufacturing & Automation*, 812–814.

SIYUAN, L., Linlin, D., & Wanlu, J. Study on application of Principal Component Analysis to fault detection in hydraulic pump. 2011. *Proceedings of 2011 International Conference on Fluid Power and Mechatronics*, (4), 173–178.

SMITH, L. I. A tutorial on Principal Components Analysis Introduction. 2002. *Statistics*, 51, 52.

STOEAN, C., & Stoean, R. *Support Vector Machines and Evolutionary Algorithms for Classification. Single or Together*. 2014. [En línea]. Citado en 15 enero 2017. Disponible en: <http://doi.org/10.1007/978-3-319-06941-8>

TIAN, J., Gao, M., Li, K., & Zhou, H. Fault Detection of Oil Pump Based on Classify Support Vector Machine. 2007. *IEEE International Conference on Control and Automation Guangzhou, CHINA, 0*, 549–553.

WANG, H., & Chen, P. Intelligent Method for Condition Diagnosis of Pump System Using Discrete Wavelet Transform , Rough Sets and Neural Network. 2007. *IEEE*, 24–28.

WANG, Z., & Wang, Z. Chaotic Parallel Support Vector Machine and Its Application for Fault Diagnosis of Hydraulic Pump. 2013. *IEEE*.

WATTON, J. *Modelling, Monitoring and Diagnostic Techniques for Fluid Power Systems*. (J. Watton, Ed.). 2007. Wales: Springer.

WIDODO, A., & Yang, B. S. Support Vector Machine in Machine Condition Monitoring and Fault Diagnosis. *Mechanical Systems and Signal Processing*, 21(6), 2560–2574. 2007.

GAO, Q. Zhang, & X. Kong. Wavelet Based Pressure Analysis for Hydraulic Pump Health Diagnosis. 2003. *Transactions of the ASAE*, 46(4).

YUAN, S. F., & Chu, F. L. Support vector machines-based fault diagnosis for turbo-pump rotor. *Mechanical Systems and Signal Processing*, 20(4), 939–952. 2006. [En línea]. Citado en 15 enero 2017. Disponible en: <http://doi.org/10.1016/j.ymssp.2005.09.006>

ZHAO, Z., Jia, M., Wang, F., & Wang, S. Intermittent chaos and sliding window symbol sequence statistics-based early fault diagnosis for hydraulic pump on hydraulic tube tester. 2009. *Mechanical Systems and Signal Processing*, 23(5), 1573–1585.