## DIAGNÓSTICO DE FALLAS EN BOMBAS HIDRÁULICAS DE PISTONES AXIALES, APLICANDO REDES NEURONALES ARTIFICIALES (ANNS).

# JESSICA GISSELLA MARADEY LÁZARO



UNIVERSIDAD INDUSTRIAL DE SANTANDER FACULTAD DE INGENIERIAS FISICOMECÁNICAS ESCUELA DE INGENIERÍA MECÁNICA MAESTRÍA EN INGENIERÍA MECÁNICA BUCARAMANGA 2017

## DIAGNÓSTICO DE FALLAS EN BOMBAS HIDRÁULICAS DE PISTONES AXIALES, APLICANDO REDES NEURONALES ARTIFICIALES (ANNS).

### Presentado por: JESSICA GISSELLA MARADEY LÁZARO

Trabajo de investigación como requisito para optar al título de Magíster en Ingeniería Mecánica

> Director: CARLOS BORRÁS PINILLA Ph.D Ingeniería Mecánica

Codirector: PEDRO DÍAZ MSc. Ingeniería Mecánica

UNIVERSIDAD INDUSTRIAL DE SANTANDER FACULTAD DE INGENIERIAS FISICOMECÁNICAS ESCUELA DE INGENIERÍA MECÁNICA MAESTRÍA EN INGENIERÍA MECÁNICA BUCARAMANGA 2017

# DEDICATORIA

A Dios por su guía, presencia y bendición. A mi madre por su apoyo y fé en mí. A mi padre (Q.E.P.D) por su legado.

A todas aquellas personas que con sus consejos, sugerencias y paciencia me ayudaron a realizar este trabajo.

Jessica

## AGRADECIMIENTOS

Agradezco a la Vicerrectoría Académica de Investigación y Extensión (VIE) de la Universidad Industrial de Santander por su apoyo económico y moral a la realización de este proyecto.

Agradezco a mi director Ph.D. Carlos Borrás Pinilla por su confianza, paciencia, asesoría y guía en la consecución de los objetivos de esta tesis de grado. A mi codirector el profesor MSc. Pedro Díaz por su apoyo y entusiasmo.

Agradezco a la Universidad Industrial de Santander por permitirme ser una vez más orgullosamente egresada de esta importante Álma Máter.

# CONTENIDO

INTRODUCCI	ÓN	16
1.	DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN	18
2.	PLANTEAMIENTO DEL PROBLEMA	20
3.	JUSTIFICACIÓN	17
4.	OBJETIVOS	22
4.1	OBJETIVO GENERAL	22
4.2	OBJETIVOS ESPECÍFICOS	22
5.	ALCANCE DEL PROYECTO	23
6.	ESTADO DEL ARTE	24
7.	MARCO TEORICO	36
7.1	Diagnóstico de Fallas en Sistemas no Lineales	36
7.1.1	Técnicas de Procesamiento de Señales	37
7.1.1.1	Transformada de Fourier (FFT)	37
7.1.1.2	Transformada Wavelet	40
7.1.1.2.1	Wavelet Packet Transform (WPT)	42
7.1.2	Técnicas de Clasificación	45
7.1.2.1	Redes Neuronales Artificiales (ANN's)	45
7.1.2.1.1	Red Adaline	47
7.1.2.1.2	Multilayer Perceptron (MLP)	50
7.1.2.1.2.1	Propagación hacia atrás (Backpropagation, BP)	52
7.1.2.1.2.2	Algoritmo de Levenberg-Maquart	54
7.1.2.1.3	Red adaptativa no lineal	55
7.3	Caso de Investigación: Desgaste Plato de Válvulas en Bombas de	
	Pistones Axiales de Desplazamiento Variable	56
8.	METODOLOGÍA	59
8.1	Adquisición y Análisis Preliminar de los Datos	59
8.2	Análisis Wavelet	80
8.2.1	Selección de la Wavelet Madre	80
8.2.2	Extracción de Características	84
8.2.3	Selección de Características	84
8.3	Diseño de la Arquitectura de Red Neuronal	88

9.	RESULTADOS Y ANÁLISIS	101
10.	CONCLUSIONES	115
11.	APORTES	117
12.	RECOMENDACIONES Y TRABAJOS FUTUROS	118
13.	BIBLIOGRAFÍA	119
ANEXO A.	Código de metodología WPT+NN desarrollada para las señales de	
vibración		124
ANEXO B.	Código de metodología WPT+NN desarrollada para las señales de	
presión		127

## LISTA DE FIGURAS

Figura 1. Esquema de las diversas técnicas usadas en diagnóstico de Fallas en Bombas de Pistones Axiales
Figura 2. Principios de diagnóstico y detección de falla en sistemas hidráulicos26
Figura 3. Ejemplo de resultados de Wavelet Packet Transform (WPT) para la señal de una bomba hidráulica
Figura 4. Vectores de salida deseados para los vectores de entrada para 5 diferentes condiciones
Figura 5. Proceso de detección de fallas basado en SOM 33
Figura 6. Diagrama de Flujo del método propuesto WPT+SOM 34
Figura 7. Estructura tipo de la SOM entrenada 35
Figura 8. Estructura de la red usada para clasificar diferentes defectos en la bomba hidráulica
Figura 9. Ejemplo función ventana
Figura 10. Esquema de la filosofía Wavelet basada en monitoreo de condición 43
Figura 11. Árbol de descomposición Wavelet de una señal 43
Figura 12. Árbol de WPD (Wavelet Packet Descomposition) de una señal 44
Figura 13. Algunas funciones wavelet madre más conocidas
Figura 14. Clasificación de las Redes Neuronales47
Figura 15. Red Adaline
Figura 16. Red Multilayer Perceptron (MLP) 51
Figura 17. Red Multilayer Perceptron (MLP) Abreviada52
Figura 18. Topología de una red neuronal adaptativa no lineal de una sola capa56
Figura 19. Esquema de una bomba de pistones axiales de desplazamiento variable 58
Figura 20. Estructura del plato de válvula58
Figura 21. Morfología de la superficie del plato de válvula con alto grado de abrasión59
Figura 22. Banco de Pruebas 60
Figura 23. Posiciones en las que se tomaron señales de vibración 62
Figura 24. Posiciones señales de caudal y presión63

Figura 25. Significancia de las características obtenidas a partir de las señales de	
vibración	64
Figura 26. Espectro de la señal de vibración condición 1 (94,9%)	65
Figura 27. Espectro de la señal de vibración condición 2 (90,1%)	. 66
Figura 28. Espectro de la señal de vibración condición 3 (84,6%)	. 66
Figura 29. Espectro de la señal de vibración condición 4 (74,8%)	. 67
Figura 30. Espectro de la señal de vibración condición 5 (69,5%)	67
Figura 31. Espectro de la señal de vibración condición 6 (64,9%)	. 68
Figura 32. Filtro Pasa Baja para la condición 1 (94,9%)	. 68
Figura 33. Filtro Pasa Baja para la condición 6 (64,9%)	. 69
Figura 34. Filtro Pasa Alta para la condición 1 (94,9%)	69
Figura 35. Filtro Pasa Alta para la condición 6 (64,9%)	70
Figura 36. Potencia vs centro de alta frecuencia de las señales de vibración por cada condición y posición	. 74
Figura 37. Espectro de las señales de presión condición 1 (94,9%)	74
Figura 38. Espectro de las señales de presión condición 6 (64,9%)	75
Figura 39. Filtro Pasa Baja para la condición 1 (94,9%)	. 75
Figura 40. Filtro Pasa Baja para la condición 6 (64,9%)	. 76
Figura 41. Filtro Pasa Alta para la condición 1 (94,9%)	. 76
Figura 42. Filtro Pasa Alta para la condición 6 (64, 9%)	. 77
Figura 43. Potencia vs centro de alta frecuencia de las señales de vibración por cada condición y posición	. 79
Figura 44. Selección de características (señal de vibración)	86
Figura 45. Selección de características (señal de presión)	. 86
Figura 46. Características de mayor significancia en 3D (señal de vibración)	. 87
Figura 47.Características de mayor significancia en 3D (señal de presión)	. 87
Figura 48. Arquitectura implementada para las tipologías Adaline y redes no lineales	. 90
Figura 49. Arquitectura implementada para la tipología MLP1 (1 capa oculta)	90
Figura 50. Arquitectura implementada para la tipología MLP2 (2 capas ocultas	90
Figura 51. Desempeño de la red Adaline para señales de vibración (Training)	91

Figura 52. Desempeño de la red MLP1 para señales de vibración (Training)92
Figura 53. Desempeño de la red MLP2 para señales de vibración (Training) 93
Figura 54. Desempeño de la red NL1 para señales de vibración (Training)
Figura 55. Desempeño de la red NL2 para señales de vibración (Training) 95
Figura 56. Desempeño de la red Adaline para señales de presión (Training)96
Figura 57. Desempeño de la red MLP1 para señales de presión (Training) 97
Figura 58. Desempeño de la red MLP2 para señales de presión (Training) 98
Figura 59. Desempeño de la red NL1 para señales de presión (Training)
Figura 60. Desempeño de la red NL2 para señales de presión (Training) 100
Figura 61. Salida de la red Adaline para señales de vibración (Test)102
Figura 62. Salida de la red MLP1 para señales de vibración (Test)103
Figura 63. Salida de la red MLP2 para señales de vibración (Test)104
Figura 64. Salida de la red NL1 para señales de vibración (Test) 105
Figura 65. Salida de la red NL2 para señales de vibración (Test) 106
Figura 66. Matriz de confusión de las redes implementadas para las señales de vibración (Test)
Figura 67. Salida de la red Adaline para señales de presión (Test) 108
Figura 68. Salida de la red MLP1 para señales de vibración (Test) 109
Figura 69. Salida de la red MLP2 para señales de vibración (Test) 110
Figura 70. Salida de la red NL1 para señales de vibración (Test) 111
Figura 71. Salida de la red NL2 para señales de vibración (Test) 112
Figura 72. Matriz de confusión de las redes implementadas para las señales de presión (Test)

# LISTA DE TABLAS

Tabla 1. Comparación del desempeño de los diferentes métodos para procesamiento de
señales
Tabla 2. Vectores característicos
Tabla 3. Comparación de clasificación de varios defectos de la bomba hidráulica usando
diferentes wavelets madre
Tabla 4. Datos tabulados filtro pasa baja para la condición 1 (94,9%) señales de
vibración71
Tabla 5. Datos tabulados filtro pasa baja para la condición 6 (64,9%) señales de
vibración72
Tabla 6 Datos tabulados filtro pasa alta para la condición 1 (94,9%) señales de
vibración73
Tabla 7. Datos tabulados filtro pasa alta para la condición 6 (64,9%) señales de
vibración73
Tabla 8. Datos tabulados filtro pasa baja para la condición 1 (94,9%) señales de
presión
Tabla 9. Datos tabulados filtro pasa baja para la condición 6 (64,9%) señales de
presión
Tabla 10. Datos tabulados filtro pasa alta para la condición 1 (94,9%) señales de
presión
Tabla 11. Datos tabulados filtro pasa alta para la condición 6 (64,9%) señales de
presión
Tabla 12. Familias de Wavelets y sus correspondientes órdenes analizadas
Tabla 13. Índices de desempeño de diferentes wavelets teniendo en cuenta sus valores
promedio (señal de vibración)
Tabla 14. Índices de desempeño de diferentes wavelets teniendo en cuenta la desviación
estándar (señal de vibración) 83
Tabla 15. Índices de desempeño de diferentes wavelets teniendo en cuenta sus valores
promedio (señal de presión)83
Tabla 16. Índices de desempeño de diferentes wavelets teniendo en cuenta la desviación
estándar (señal de presión)83

Tabla 17. Resumen resultados de cada etapa y por cada red para las señales de	
vibración	.114
Tabla 18. Resumen resultados de cada etapa y por cada red para las señales de	
presión	. 114

## TITULO: DIAGNÓSTICO DE FALLAS EN BOMBAS HIDRÁULICAS DE PISTONES AXIALES, APLICANDO REDES NEURONALES ARTIFICIALES (ANNS).

## Autora: JESSICA GISSELLA MARADEY LÁZARO\*\*

**Palabras Claves**: Bomba de Pistones axiales, Análisis Wavelet, Diagnóstico de Fallas, Redes Neuronales, Monitoreo de Condición.

#### RESUMEN

El trabajo descrito en este documento consistió en establecer una metodología para el diagnóstico de la falla de desgaste de plato de válvula en una bomba hidráulica de pistones axiales usando un banco de pruebas de 40HP de potencia, en el cual se indujeron 5 condiciones de falla asociadas con la pérdida de eficiencia volumétrica de la bomba. A partir de las señales de vibración y presión tomadas de la bomba en operación normal y operación de falla, se realizó análisis preliminar de las señales (corrección línea base, eliminación de tendencias, filtrado), las gráficas espectrales (Spectral Density Power, PSD) de cada una de las condiciones, la extracción de características mediante el uso de Wavelet Packet Transform (WPT), y por último el diseño de diferentes arquitecturas de red neuronal (NN) tales como Adaline, multilayer perceptron de una capa y dos capas, y dos redes no lineares, las cuales fueron entrenadas y validadas. Adicionalmente se implementó una técnica para selección de características de acuerdo a su significancia la cual es conocida como "Independent Features", la cual permitió mejorar la respuesta del clasificador.

La metodología propuesta presenta resultados satisfactorios en las tareas de detección, clasificación y diagnóstico de la falla de desgaste de plato de válvula para bombas de pistones axiales logrando una precisión en la etapa de entrenamiento del 100% y en la etapa de prueba del 95.8% tomando las señales de vibración y de 100% en ambas etapas tomando las señales de presión.

\_\_\_\_\_

<sup>\*</sup> Proyecto de Grado

<sup>\*\*</sup> Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería Mecánica, Director: Ph.D. Carlos Borrás Pinilla. Codirector: MSc. Pedro Díaz.

# TITLE: FAULT DIAGNOSIS IN AXIAL PISTON PUMPS, USING ARTIFICIAL NEURAL NETWORKS (ANN'S)

## Author: JESSICA GISSELLA MARADEY LÁZARO\*\*

**Keywords**: axial piston pump, wavelet analysis, fault diagnosis, neural networks, condition monitoring.

### ABSTRACT

The work described in this paper consisted on establishing a methodology for wear fault diagnosis of valve plate in axial piston pump using a 40HP power test bench, where which 5 associated failure conditions were induced related with the loss of volumetric efficiency of the pump. The vibration and pressure signals taken from the pump in normal and fault operation, the preliminary analysis of signals (baseline correction, trend elimination, filtering) and Spectral Density Power (PSD) for each condition was performed. After, Wavelet Packet Transform (WPT) was used for features extraction. Finally, a several neural networks (NN) architectures was designed such as Adaline, multilayer perceptron one layer and two layers, and two no linear networks which was trained and validated. In addition, a technique for selection of characteristics according to their significance was implemented, which is known as "Independent Features", which improved the response of the classifier.

The proposed methodology presents satisfactory results in the tasks of detection, classification and diagnosis of valve plate wear failure for axial piston pumps achieving a precision in the 100% training stage and in the 95.8% test stage by taking the vibration signals and 100% in both stages by taking the pressure signals.

\_\_\_\_\_

\* Proyecto de Grado

<sup>\*\*</sup> Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería Mecánica, Director: Ph.D. Carlos Borrás Pinilla. Codirector: MSc. Pedro Díaz.

## **INTRODUCCIÓN**

En los últimos años, la confiabilidad y seguridad de los procesos industriales, junto con la eficiente gestión de activos, han tomado un papel muy importante para lograr mayor competitividad y productividad de las empresas a nivel local.

Las bombas hidráulicas de pistones axiales de desplazamiento variable (VDAP) son el corazón de todo sistema hidráulico y son comúnmente usadas en el sector industrial por su alta capacidad de carga, eficiencia (volumétrica y total)[1] y buen desempeño en el manejo de altas presiones y velocidades. Debido a su configuración, las fallas más comunes están relacionadas con el desgaste y fuga de componentes internos, los cuales disminuyen el desempeño operacional del sistema hidráulico e incrementa los costos de mantenimiento.

Para garantizar confiabilidad, seguridad y mantenibilidad de los equipos hidráulicos, lo aconsejado habitualmente por el fabricante es la implementación de un sistema de gestión que incluya actividades de tipo preventivo y predictivo [5], lo que da como resultado una reducción considerable de costos de mantenimiento y operativos, aumentando la productividad de los procesos, así como la estabilidad del sistema en general. De otra parte, se han desarrollado metodologías para diagnóstico de fallas on-line y off-line para este propósito, permitiendo tomar acciones que eviten largas paradas no programadas y/o daños permanentes de los mismos y preservar su vida útil.

Mediante la toma de señales de vibración, presión y flujo volumétrico y el procesamiento digital de ellas es posible detectar, clasificar e identificar fallas o síntomas en maquinaria hidráulica. Estas actividades constituyen la base de un programa Mantenimiento Basado en Condición (CBM).

El análisis wavelet ha sido ampliamente estudiado para la extracción de características [21] [37], el cual ha mostrado una ventaja en el procesamiento de señales no lineales y no estacionarias. Este permite el manejo en el dominio del tiempo y la frecuencia y la descomposición de las series en términos de los coeficientes de aproximación (cA) y detalle (cD), separando la información en bajas y altas frecuencias respectivamente. El algoritmo generalizado Wavelet Packet Transform (WPT) también es un método muy efectivo, el cual después de la descomposición de la señal permite extraer y normalizar los vectores característicos de acuerdo a la energía de cada componente [26] [44].

Por su parte las redes neuronales artificiales (ANN's), gracias a su capacidad de entrenamiento - aprendizaje, auto organización y tolerancia a fallos [32], así como su robustez en la solución de sistemas dinámicos complejos y de naturaleza no lineal, han sido especialmente usadas en tareas de reconocimiento de patrones, diagnóstico y clasificación, para manejar información analítica y heurística, data incompleta entre otras.

Con este proyecto se pretende implementar un sistema de gestión off-line robusto, económico y seguro que permita la detección y clasificación de fallas en bombas de pistones axiales, mediante la integración de técnicas de procesamiento digital de señales (como lo es, WPT) y el uso de la inteligencia artificial (como las ANN's) cuya eficiencia será probada con datos experimentales.

Cabe resaltar la pertinencia del proyecto, el cual no sólo busca el fortalecimiento de la investigación en el área de salud estructural sino contribuir al establecimiento de metodologías de diagnóstico en equipo hidráulico de acuerdo con las investigaciones e interés internacional.

17

# 1. DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN

# 1.1 TÍTULO

"DIAGNÓSTICO DE FALLAS EN BOMBAS HIDRÁULICAS DE PISTONES AXIALES, APLICANDO REDES NEURONALES ARTIFICIALES (ANN'S)".

# **1.2 DIRECTOR DEL PROYECTO**

CARLOS BORRÁS PINILLA Ingeniero Mecánico, Ph.D. Ingeniería Mecánica Universidad Industrial de Santander (Colombia) Escuela de Ingeniería Mecánica.

## **1.3 CODIRECTOR DEL PROYECTO**

PEDRO DÍAZ Ingeniero Mecánico, MSc. Ingeniería Mecánica Universidad Industrial de Santander (Colombia) Escuela de Ingeniería Mecánica.

# **1.4 AUTOR DEL PROYECTO**

# JESSICA GISSELLA MARADEY LÁZARO

Ingeniera Mecánica, M.Eng. con especialidad en Sistemas de Calidad y Productividad, candidata a Magister en Ingeniería Mecánica. Universidad Industrial de Santander (Colombia).

# **1.5 ENTIDADES INTERESADAS EN EL PROYECTO**

- Vicerrectoría de Investigación y Extensión (VIE), Universidad Industrial de Santander (Colombia).
- Grupo de Investigación en Dinámica, Control y Robótica DICBOT.
- Empresas locales como Prevesa, Cemex, Argos, Hormigón de Colombia, Ecopetrol, Postobón, Coca Cola Femsa, Dana Transejes Colombia, entre otras.

#### 2. PLANTEAMIENTO DEL PROBLEMA

Con la creciente necesidad de la industria local de lograr competitividad y productividad a través de una eficiente gestión de activos, el mantenimiento preventivo constituye la principal herramienta para mitigar los efectos que tienen las paradas no programadas, el alto costo de los inventarios y mejora de los índices de eficiencia operacional global.

Los equipos hidráulicos suelen presentar fallas asociadas al desgaste y fugas de sus componentes internos, causando una disminución considerable en su desempeño. En algunos casos, las fallas son difíciles de predecir bajo los sistemas convencionales (Análisis de vibración, termografía y análisis de aceite) debido a la complejidad de su geometría y requerimientos de funcionamiento.

En Colombia los problemas de monitoreo de condiciones mecánicas y eléctricas han sido abordados a través del uso del análisis de vibraciones con uso dominante del algoritmo FFT (Fast Fourier Transform), para sistemas y máquinas rotativas. La maquinaria hidráulica nacional ha tenido poco monitoreo incluso en términos de vibraciones, una de las razones principales es la escasa disponibilidad de fuentes de suministro de alta potencia (laboratorios universitarios o centros de investigación con capacidad superior a unidades de pruebas instrumentadas y controladas mayores a 40 HP) para realizar pruebas continuas en sistemas de potencia fluida.

La temática de detección y diagnóstico de fallas en sistemas de Potencia Fluida usando análisis espectrales como backstrum, cepstrum, FFT y Wavelet, han sido ampliamente estudiado a nivel internacional, sin embargo no se evidencian reportes de su uso a nivel local ni aplicado a la industria local q usa dichos equipos.

De acuerdo con lo anterior, se formula la siguiente pregunta: ¿Es posible predecir o detectar la ocurrencia de una falla en una bomba hidráulica de pistones axiales de

tal modo que se puedan tomar acciones para minimizar o eliminar las consecuencias de la falla y lograr de esta manera una mayor competitividad de las empresas de la región que hacen uso de sistemas hidráulicos?

A partir de la metodología implementada dentro del presente proyecto, se pretende dar respuesta a esta pregunta a través del desarrollo de un algoritmo capaz de detectar y clasificar fallas en bombas de pistones axiales de forma autónoma y flexible, empleando la técnica de redes neuronales artificiales, que permita la implantación de una sistema de gestión off-line de diagnóstico de fallas no intrusivo, confiable, económico y objetivo de fácil acceso para las empresas interesadas.

#### 3. JUSTIFICACIÓN

El mantenimiento basado en condición (CBM) constituye una de las herramientas más flexible, eficiente y económica para disminuir sobrecostos y a través de sistemas expertos mantener la confiabilidad del sistema [32].

Dentro de este contexto, el diagnóstico de fallas en bombas hidráulicas de pistones axiales se ha abordado usando diferentes metodologías las cuales han mostrado efectividad en las funciones de detección, clasificación e identificación completa de fallas que se presentan en operación normal, como lo es el desgaste de componentes. Teniendo en cuenta lo anterior, esta propuesta se formulan las siguientes preguntas:

- ¿Porque emplear la técnica de redes neuronales para el monitoreo de bombas de pistones axiales?
- ¿Si se conoce acerca de la efectividad de varias técnicas de inteligencia artificial en la detección de fallas en bombas de pistones axiales, que hace que las redes neuronales sean la técnica escogida para esta investigación?

El uso de redes neuronales está soportado en el buen desempeño que tienen para resolver problemas no lineales complejos, donde las soluciones analíticas no están disponibles, su flexibilidad al no requerir conocimiento a priori del sistema y permitir el aprendizaje off-line, su versatilidad al escoger los datos de "entrenamiento" y el tipo de supervisión, así como también la posibilidad de ser integrada con otras técnicas para el diagnóstico de fallas[10] [12]. Estudios revelan su eficacia para la detección de la falla de desgaste del plato de válvula [6][10][15]. Algunos otros casos de estudio, en el control de la presión de operación en bombas de pistones axiales [18][41] revelan la efectividad de la técnica en la práctica.

Particularmente, se han usado redes no supervisadas como las SOM (Self Organizing Maps) así como de tipo Multilayer Perceptron para el monitoreo de condición de maquinaria hidráulica [39] [44].

Respecto al segundo interrogante, si bien es cierto, existen muchas técnicas de inteligencia artificial usadas en el diagnóstico de fallas tanto en maquinaria rotativa como hidráulica, las cuales han sido ampliamente estudiadas a lo largo de los últimos años, incluyendo algunos casos de éxito usando combinaciones entre ellas permitiendo lograr un alto grado de desempeño en el procesamiento computacional y así mismo en la correcta identificación de diversas fallas. En el presente trabajo, se desea explorar, aprovechar y verificar las ventajas que tienen las redes neuronales en el reconocimiento de patrones, en la eficiente detección y clasificación de fallas y su gran potencial para resolver casos complejos como lo es el desgaste del plato de válvula.

Este proyecto ofrece una metodología viable, de fácil implementación, no intrusiva y validada que permitirá aportar al campo científico avances respecto a los parámetros, condiciones y requisitos necesarios para la detección y clasificación de fallas en bombas de pistones axiales teniendo en cuenta los recursos disponibles (Banco de Pruebas de Alta Potencia y Software Licenciado Matlab).

21

Adicionalmente, esta metodología permitirá disminuir la probabilidad de una incorrecta identificación de las fallas y acciones infructuosas debido a ésta, brindándole un soporte tecnológico seguro para que el analista de mantenimiento pueda tomar decisiones eficaces de tipo preventivo.

## 4. OBJETIVOS DEL TRABAJO DE INVESTIGACIÓN

#### 4.1 OBJETIVO GENERAL

 Continuar con la misión de la Universidad de generar conocimiento, de atender y dar solución a diferentes problemáticas en los procesos industriales, en particular, en ofrecer un clasificador basado en redes neuronales artificiales (ANN's) para la detección, clasificación y diagnóstico de la falla de desgaste del plato de válvula en bombas hidráulicas de pistones axiales. Adicionalmente, este proyecto pretende contribuir al fortalecimiento de la línea de investigación relacionada con el monitoreo de equipos e inteligencia artificial del grupo DicBoT adscrito a la Escuela de Ingeniería Mecánica.

#### **4.2 OBJETIVOS ESPECIFICOS**

- Establecer el estado del arte sobre la aplicación de diversas técnicas en el diagnóstico de fallas en bombas hidráulicas de pistones axiales, profundizando especialmente en el uso de redes neuronales artificiales (ANN's).
- Desarrollar un algoritmo para detección y clasificación de la falla de desgaste de plato de válvula en una bomba hidráulica de pistones axiales basados en redes neuronales artificiales (ANN´s) usando la información aportada por la señal de vibración y lectura de presión proveniente del banco de pruebas diseñado y disponible para uso de este proyecto.

- Analizar la falla de desgaste de plato de válvula teniendo en cuenta el algoritmo desarrollado (entrenamiento) a partir de los datos experimentales tomados del banco disponible mencionado.
- Validar experimentalmente el algoritmo propuesto, teniendo en cuenta (5) condiciones de falla asociadas con la pérdida de eficiencia volumétrica de acuerdo a los siguientes rangos (90%- 95%), (80-85%), (75%-80%), (y valores menores a 75%), respecto a la condición de estado nuevo, que es 94%.
- Proponer una metodología para el diagnóstico de fallas off-line en equipo hidráulico en general, tomando como caso modelo el estudio del desgaste del plato de válvula en una bomba de pistones axiales.

# 5. ALCANCE DEL PROYECTO

La presente investigación tiene como finalidad, definir una metodología y procedimiento con un algoritmo basado en redes neuronales que permita detectar cambios respecto al desgaste de plato de válvula de una bomba hidráulica marca Eaton serie 54, debido a condiciones normales de desgaste, que afecta la eficiencia volumétrica del equipo. Para llevar a cabo este procedimiento se deberá realizar:

- Implementación de los algoritmos de procesamiento y análisis, para entrenamiento.
- Validación mediante uso de los algoritmos adaptados en pruebas experimentales y corroboradas con flujo de pérdidas que afecta la eficiencia volumétrica.

### 6. ESTADO DEL ARTE

Dado el comportamiento no lineal, variante con el tiempo y sujeto a perturbaciones de carga de las bombas de pistones axiales, la implementación de sistemas on-line [5][25] y off-line [6][7] más robustos para la detección, y clasificación de las fallas oportunamente, han permitido ampliar el conocimiento sobre la condición real de las máquinas, la identificación de sus modos de falla [15], la aplicación de diversos algoritmos y modelos, el análisis de los datos recolectados por los sensores instalados (datos de entrada) y la validación experimental, lo que asegura que la metodología usada es confiable y efectiva para el diagnóstico de fallas.

Las metodologías usadas para el diagnóstico de fallas en bombas de pistones axiales son variadas, abarcan desde modelos dinámicos [2][7] hasta modelos combinados [23] [29] o híbridos y algunos clasificadores multifalla [18] [19]. En la figura 1 puede verse un cuadro conceptual sobre dichas técnicas.

En general, todas las metodologías desarrolladas cumplen con las siguientes etapas tal como se detalla a continuación y complementariamente puede verse en la figura 2:

1. Procesamiento de la señal: El análisis de vibración generalmente estaba basado en el análisis espectral que usa la transformada de Fourier (FT), transformada de Fourier de tiempo corto (STFT) y el análisis de la secuencia de tiempo. Como estos métodos han sido designados para procesar señales en el dominio de la frecuencia o del tiempo solamente. Para contrarrestarlo, ha sido ampliamente utilizado el análisis Wavelet (usado en sísmica, monitoreo del estado de estructuras y diagnóstico de equipo médico, entre otras) que permite el análisis en un dominio extendido de tiempo-frecuencia para identificar señales locales características por descomposición de la señal en el dominio de tiempo para esas frecuencias [9], logrando la reducción de ruido y la efectiva extracción de las características de la falla. Existen más métodos para realizar esta etapa, algunas diferencias entre los métodos puede verse en la Tabla 1.





2. Uso de herramientas estadísticas para dimensionar la reducción e independencia de los datos extraídos. El Análisis de Componentes Principales (PCA) es una técnica estadística multivariable que ha sido aplicada exitosamente

en la detección y diagnóstico de fallas, por ser una herramienta lineal de reducción de dimensionalidad, óptima en términos de capturar la variabilidad de la data y aplicada para realizar la etapa de extracción de características. PCA determina un conjunto de vectores ortogonales, que son combinaciones lineales de las variables originales, éstos son ordenados por la cantidad de varianza explicada en las direcciones de dichos componentes [12] [27].

- 3. Extracción de las características de la señal.
- Establecer las reglas de diagnóstico o algoritmo de clasificación a utilizar, teniendo en cuenta la supervisión y el entrenamiento del mismo, en los casos en los que aplique.
- 5. Validación experimental o simulación de fallas para verificar la validez de las reglas y/o algoritmo seleccionado en el paso anterior.

# Figura 2. Principios de diagnóstico y detección de falla en sistemas hidráulicos.



**Fuente:** GAO, Y.,ZHANG, Q., and KONG, X. Wavelet-based pressure analysis for hydraulic pump health diagnosis, ASAE transactions on, 2003, Vol. 46, No.4, p.969

Para abordar el problema de desgaste de plato de válvula estudiado en el presente proyecto, se propone usar para el procesamiento de las señales el análisis wavelet y para la clasificación la técnica de redes neuronales. El análisis wavelet es el recomendado para diagnóstico de fallas [37] sobre todo para el manejo de señales no lineales y no estacionarias [26] [39] teniendo éxito para el filtrado de señales y extraer características de la señal, tal como puede verse en la figura 3 y en la tabla 2. Los coeficientes wavelet proveen información compacta acerca de una señal en

diferentes localizaciones de tiempo y frecuencia, lo que permite reducir la dimensionalidad de la data, y obtener los vectores de características [14]. Las redes neuronales artificiales han sido aplicadas en problemas complejos de ingeniería, tales como diagnóstico de fallas, reconocimiento de patrones, procesamiento de señales, robótica y control, mostrando buenas habilidades para detectar algunos datos sin tendencia (a la deriva) y fallas en procesos hidráulicos [5], y mejor desempeño con respecto a métodos de regresión o de diferencias finitas [31]. También han sido usadas como un controlador para verificar el flujo y la presión en las VDAP, cuyos parámetros son afectados por el cambio del ángulo del plato oscilante [18][41].

Tabla	1.	Comparación	del	desempeño	de	los	diferentes	métodos	para
proces	sam	niento de señalo	es						

Métodos	Resolución	Interferencia	Velocidad
CWT ( Continuos Wavelet Transform)	Buena resolución en frecuencia y baja resolución en tiempo para componentes en bajas frecuencias, baja resolución en frecuencia y buena resolución en tiempo para componentes de alta frecuencia	No	Rápida
STFT( Short Time Fourier Transform)	Depende de la función ventana, buena resolución en tiempo y frecuencia	No	Menor que la CWT
WVD (Wigner-Ville Distribution)	Buena resolución en tiempo y frecuencia	Severa	Menor que la STFT
CWD ( Choi-Williams Distribution)	Buena resolución en tiempo y frecuencia	Menos interferencia que en WVD	Muy baja
CSD ( Cone-Shaped Distribution)	Buena resolución en tiempo y frecuencia	Menos interferencia que CWD	Muy baja

**Fuente:** PENG, Z., and CHU, F.Application of the wavelet transform in machine condition monitoring and fault diagnosis: a review with bibliography. En: Mechanical Systems and Signal Processing, 2004, Vol.18, No.2, p. 199-221.

En 1995, Hongzhi, Y., Guanzheng, T. y Zhuangyun, L. [42], propusieron un algoritmo off-line para diagnosticar falla de cavitación en bombas de pistones axiales usando una red multicapa perceptron (MLP, 3 capas) con algoritmo de entrenamiento back propagation (BP), el cual presentó algunas desventajas como la baja tasa de convergencia y problemas de mínimos locales. Para contrarrestarlas, se desarrolló un nuevo modelo que incluye la selección y búsqueda de patrones en la capa oculta (hidden layer) y encuentra el nodo oculto dominante. Como resultado, se obtuvo una red con 10 nodos de entrada, 5 nodos ocultos y 3 nodos de salida, la cual fue entrenada y cuya validación experimental demostró su efectividad.

# Figura 3. Ejemplo de resultados de Wavelet Packet Transform (WPT) para la señal de una bomba hidráulica



**Fuente:** JIKUN, B., CHEN, L., ZHIPENG, W., and ZILI,W. An approach to performance assessment and fault diagnosis for hydraulic pumps. En: International LTD. Journal of Vibroengineering, May.2014,Vol. 16, No. 3, p. 1444-1454.

En 1998, Ramden, T., Krus, P. y Palmberg, J. [39], desarrollaron una metodología de monitoreo basado en condición off-line de la fallas relacionadas con el desgaste del plato de válvula en un bomba de pistones de eje inclinado de desplazamiento fijo (Fixed-Displacement Bent-Axis Piston Pump) usando un algoritmo de red MLP usando BP como algoritmo de entrenamiento, obteniendo una red de 5 nodos de entrada, 15 nodos ocultos y 4 nodos de salida, la cual fue entrenada y simulada con Matlab Neural Network Toolbox tomando el plato de válvula original y platos con desgaste correspondientes al 3%, 6% y 9% de perdida de eficiencia volumétrica. Como recomendación final, los autores sugieren trabajar con análisis wavelet para el procesamiento de la señal de vibración tomada de la carcasa de la bomba. En la figura 4 puede verse un esquema del diseño de la red.

No.	$E_1$	$E_2$	$E_3$	$E_4$	$E_5$	$E_6$	$E_7$	$E_8$
1	0.3393	2.5319	0.8789	1.6472	1.0084	0.8393	0.8632	1.2736
2	0.3478	2.5081	0.8403	1.6266	0.8638	1.0336	0.8560	1.2394
3	0.3441	2.5544	0.8547	1.6328	1.0271	0.8498	0.8260	1.2399
4	0.2998	2.5475	0.8050	1.6295	0.8677	0.9842	0.8373	1.2632
5	0.2746	2.5443	0.8867	1.6499	0.9887	0.8384	0.8893	1.2999
6	0.3646	2.5096	0.8442	1.5906	0.8659	0.9996	0.8187	1.3576
7	0.3171	2.5314	0.8504	1.5450	0.9480	0.9248	0.8309	1.4178
8	0.3420	2.4554	0.7721	1.5553	0.9031	0.9380	0.7934	1.4749
9	0.3630	2.5726	0.8263	1.5265	0.9263	0.9830	0.7235	1.4745
10	0.3230	2.4265	0.7846	1.5236	0.9257	0.9358	0.8623	1.2754

 Tabla 2. Vectores característicos

**Fuente:** JIKUN, B., CHEN, L., ZHIPENG, W., and ZILI,W. An approach to performance assessment and fault diagnosis for hydraulic pumps. En: International LTD. Journal of Vibroengineering, May.2014,Vol. 16, No. 3, p. 1444-1454.

Figura 4. Vectores de salida deseados para los vectores de entrada para 5 diferentes condiciones



**Fuente:** RAMDÉN, T., KRUS, P., and PALMBERG, J. Reliability and sensitivity analysis of a condition monitoring technique. En: Proceedings of the JFPS International Symposium on Fluid Power, 1996, Vol.1, p.567-572.

En 1999, Karkoub, M., Gad, O. y Rabie, M. [27], probaron experimentalmente un modelo que describe el comportamiento dinámico en estado estable y en estado transitorio a través de la predicción de las presiones tomando varios puntos de medición en una bomba de eje inclinado de desplazamiento variable. Integraron una red MLP con una técnica de optimización de Levenberg- Marquardt para el entrenamiento de la red. Como resultado se obtuvo un error del 2% entre los resultados teóricos y los experimentales por lo que se concluye que las redes neuronales tiene un potencial muy importante en el modelamiento de sistemas complejos como éste.

En 2003, Lurette, C., y Lecoeuche, S. [31], desarrollaron una arquitectura de red neuronal auto-adaptativa y no supervisada para el monitoreo on-line. El estudio se enfoca en las fallas que ocurren en el acumulador, como lo es la repentina rotura de la membrana. Los resultados mostraron que el modelo detecta y clasifica eficientemente la falla y usa un árbol de decisión para establecer el diagnostico final de acuerdo a la tendencia de los datos obtenidos.

En el mismo año, Gao, Y., Zhang, Q., y Kong, X. [20], propusieron una metodología de diagnóstico de falla on- line de bombas hidráulicas usando las señales de presión tomadas y mediante análisis wavelet obtener los coeficientes de detalle y de aproximación para ser comparados con los obtenidos del estado de bomba normal, teniendo diferencias en los patrones y amplitudes en las diferentes bandas haciendo distinguible y de fácil identificación los tipos de defectos analizados (desgaste del plato oscilante y perdida de ajuste en las zapatas del pistón). Adicionalmente se realizaron test de validación on-line, lo que permite obtener un diagnóstico en tiempo real de la bomba sin afectar su normal operación.

En 2004, Canzbulut, F. y Sinanoglu, C. [15], estudiaron una variedad de condiciones (RPM, temperatura del aceite hidráulico y presiones de descarga), y su incidencia en la eficiencia volumétrica de bombas hidrostáticas en general (pistones axiales, engranajes y paletas). Adicionalmente, propusieron el uso de una red neuronal para predecir el caudal de fuga, la cual fue simulada y validada experimentalmente, permitiendo concluir que el máximo caudal de fuga ocurre a bajas RPM's y altas presiones en las bombas axiales y de paletas para una RPM dada, mientras que con una bomba de engranajes este caudal es mínimo. Se sugiere como necesaria una película de aceite de suficiente espesor para prevenir la fuga excesiva de aceite.

En 2011, Bo, C., Guoping, Y., y Dongshi, X. [10], basados en AMESim Software simularon un modelo mecánico (transmisión entre el eje y plato oscilante) e hidráulico (cámara del pistón) de una bomba de pistones axiales. Los resultados (curvas de desplazamiento del pistón y velocidad, curvas de fugas internas y externas del par de pistones, y curvas de la presión actuante en el pistón a diferentes RPM) arrojados por el software coinciden con los calculados analíticamente.

Igualmente, C. Bayer y O. Rosenblatt [7], realizaron un modelamiento en Modelica Software teniendo en cuenta dos defectos: picaduras por cavitación y juego del cojinete del patin de deslizamiento. Un algoritmo de redes neuronales es usado para clasificar las fallas, teniendo en cuenta 12 características de entrada y 3 neuronas de salida, de las cuales se usan solo dos de ellas (bomba en perfecto estado y bomba defectuosa). Se logró un modelo más flexible que relaciona los defectos con las señales detectadas y facilita el desenvolvimiento de las técnicas de procesamiento de la señal, mejorándolas y generando unas mejores características de clasificación.

En 2012, Tao, X., Wang, Z., Ma, J. y Fan, H. [44], desarrollaron una metodología basada en evaluación de desempeño llamada "SOM Neural Network", diseñada como una red neuronal de aprendizaje no supervisado para organizarse ella misma acorde con la naturaleza de los datos de entrada. La detección de la falla es conseguida haciendo el cálculo de cuantificación del mínimo error (MQE), el cual puede ser transformado en un valor confiable normalizado (CV). Para la verificación del método se realizó el experimento para dos fallas: Patín de deslizamiento suelto y desgaste del plato de válvula, cuyos resultados fueron satisfactorios. Como trabajo futuro, se puede profundizar en el estudio de la extracción de características e identificación de modos de falla teniendo en cuenta solamente la información en operación normal disponible. En la figura 5 se muestra el proceso de diagnóstico de falla basado en SOM que propusieron.

En 2014, Plawiak, P. [35], sugiere métodos inteligentes computacionales para estimar el consumo de una bomba de pistones axiales de desplazamiento fijo. Para esto, diseñó y comparó métodos para el procesamiento de la señal (eliminación del componente constante, normalización, estandarización, reducción, FFT), así como también la efectividad de tres modelos de redes neuronales (MLP, regresión generalizada y probabilística), con Matlab. El análisis realizado mostró que en términos de exactitud el mejor resultado en el dominio de la frecuencia se alcanza con multicapa perceptron y en el dominio del tiempo con la regresión generalizada.

Igualmente, Jikun, B., Chen, L., Zhipeng, W., y Zili, W. [26], propusieron un método para evaluar el desempeño y diagnosticar las fallas en bombas hidráulicas, mediante la descomposición de paquete wavelet (WPT), extrayendo las características basado en el concepto de energía y realizando la clasificación usando una red SOM. La metodología propuesta puede verse en la figura 6. Las fallas estudiadas fueron el desgaste del plato oscilante y del rotor. Adicionalmente calcularon el error medio cuadrático (MQE), optimizaron las características usando el método Taguchi y establecieron un valor de confianza (CV). Los resultados fueron validados y muestran que efectivamente clasifica las fallas estudiadas, éstos pueden verse en la figura 7.



Figura 5. Proceso de detección de fallas basado en SOM

**Fuente:** TAO, X., WANG, Z., and FAN, H. Study on fault detection using wavelet packet and SOM neural network. En: Prognostics & System Health Management Conference, IEEE transactions on, 2012, Vol.12, p.1-5.



Figura 6. Diagrama de Flujo del método propuesto WPT+SOM

**Fuente:** JIKUN, B., CHEN, L., ZHIPENG, W., and ZILI,W. An approach to performance assessment and fault diagnosis for hydraulic pumps. En: International LTD. Journal of Vibroengineering, May.2014,Vol. 16, No. 3, p. 1444-1454.

Finalmente, el trabajo más reciente se encuentra en el año 2015, en el que Salimi, E., y Niromandfam, B. [40], muestran como usando parámetros estadísticos del espectro de vibración es un método simple para obtener características y mediante el uso del método de análisis de datos, se pueden seleccionar las mejores características. Además, resaltan la importancia del uso de la transformada wavelet para el tratamiento de señales inestables y en diferentes estado de la bomba, adicionalmente usando una red neuronal con el algoritmo de entrenamiento de Levenberg- Marquart pudo obtenerse un reconocimiento de los defectos de mayor del 95% lo que muestra que la eficiencia de la red seleccionada para reconocer los defectos es buena y aceptable. La estructura de la red y los datos obtenidos después del análisis wavelet puede verse en la figura 8 y en la Tabla 3.

## Figura 7. Estructura tipo de la SOM entrenada



**Fuente:** JIKUN, B., CHEN, L., ZHIPENG, W., and ZILI,W. An approach to performance assessment and fault diagnosis for hydraulic pumps. En: International LTD. Journal of Vibroengineering, May.2014,Vol. 16, No. 3, p. 1444-1454.

# Figura 8. Estructura de la red usada para clasificar diferentes defectos en la bomba hidráulica



**Fuente:** SALIMI, E., and NIROMANDFAM, B. Condition monitoring of hydrolic pump by wavelet transform and artificial neural network. En: Journal of Novel Applied Sciences, JNAS transactions on, 2015, p.1123-1128.

 Tabla 3. Comparación de clasificación de varios defectos de la bomba

 hidráulica usando diferentes wavelets madre

Tipo de Wavelet	Data de Entrenamiento	Data de evaluación	Data de prueba
Haar	100	100	100
Daubechies	100	100	98.30
Symlet	100	100	100
Coiflet	100	100	96.70
Biorthogonal	98.30	98.30	100

**Fuente:** SALIMI, E., and NIROMANDFAM, B. Condition monitoring of hydrolic pump by wavelet transform and artificial neural network. En: Journal of Novel Applied Sciences, JNAS transactions on, 2015, p.1123-1128

## 7. MARCO TEÓRICO

#### 7.1 Diagnóstico de Fallas en Sistemas no Lineales

Desde el punto de vista matemático, el problema del diagnóstico preciso de fallos de sistemas dinámicos no lineales resulta muy ambicioso. Como primer paso se buscaría linealizar el modelo alrededor de un punto de operación, y posteriormente aplicar técnicas robustas (las cuales son las mismas que se usan en modelos lineales) para generar los residuos que sean insensibles a variaciones en los parámetros del modelo dentro de un pequeño intervalo en la vecindad del citado punto de operación. Sin embargo, esta estrategia sólo funciona bien si el modelo linealizado no se comporta muy diferente del propio sistema no lineal y opera cerca del punto de operación mencionado, lo cual correspondería a casos particulares y no aplicables a sistemas con grandes no linealidades y amplios rangos de operación dinámica. Usar varios modelos linealizados que correspondieran a varios puntos de operación, implicaría un gran número de sistemas de diagnóstico, lo cual no es muy práctico para aplicaciones en tiempo real. El problema se hará más difícil de resolver cuando existe incertidumbre en el sistema [6].

Para resolver los problemas mencionados, es deseable encontrar un modelo aproximado universal que pueda usarse para representar cualquier sistema no lineal de forma aproximada. Además, debería haber un mecanismo que pueda identificar automáticamente ese modelo universal. En este sentido, existen varias técnicas como las redes neuronales que pueden responder efectivamente a estos requerimientos. Adicionalmente se han combinado los conceptos de generación y evaluación del residuo con redes neuronales así como sistemas que incluyen lógica Fuzzy, para formar poderosas herramientas de diagnóstico de fallos en sistemas dinámicos no lineales como los observados en una bomba de pistones axiales de desplazamiento variable que fueron discutidos en el capítulo anterior.

#### 7.1.1 Técnicas de Procesamiento de Señales

#### 7.1.1.1 Transformada de Fourier

La transformada de Fourier ha sido el método clásico de procesamiento y análisis de señales obteniendo gran aceptación debido a sus múltiples áreas como la ciencia y la ingeniería. Es una transformación matemática empleada para convertir señales del dominio del tiempo (o espacial) al dominio de la frecuencia, la cual constituye el espectro de frecuencias de una función, donde las componentes de frecuencia son representadas como picos. Entre sus propiedades se encuentran: Es una función integrable, lineal, simétrica, que permite cambio de escala y traslación en ambos dominios, transformada de la derivada, derivada de la trasformada, y convolución.

La transformada de Fourier de una función f(x) está definida por:

$$F(k) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} f(x) e^{-jkx} dx$$
(7.1)

donde k es una variable real continua y F(k) una función compleja.

La potencia de esta técnica nos permite descomponer una señal compleja en un conjunto de componentes de frecuencia única, sin embargo, no nos indica el

instante en que han ocurrido [8]. A partir de la señal en el dominio de la frecuencia, la función puede ser reconstruida a partir de sus componentes de Fourier en el dominio del tiempo, por medio de la transformada inversa de Fourier:

$$f(k) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} F(k) e^{jkx} dk$$
(7.2)

Entre las limitantes de la Transformada de Fourier se encuentran [38]:

- Se obtienen resultados satisfactorios en los casos de señales periódicas y lo suficientemente regulares, pero no ocurre lo mismo para el análisis de señales cuyo espectro varía con el tiempo (señales no estacionarias).
- No brinda información acerca de la evolución en el tiempo de las características espectrales de la señal. Muchos aspectos temporales de la señal, tales como el comienzo y el fin de una señal finita y el instante de aparición de una singularidad en una señal transitoria, no pueden ser analizados adecuadamente por el análisis de Fourier.

Sin embargo, para los casos de señales no estacionarias y transitorias se utiliza generalmente la transformada de Fourier con ventana. Este método de ventana consiste en realizar un análisis espectral dependiente del tiempo. Una señal no estacionaria es dividida en una secuencia de segmentos de tiempo en los cuales la señal puede ser considerada como cuasi–estacionaria y la Transformada de Fourier es aplicada a cada segmento local de la señal [38]. Esta transformada de Fourier con ventana está definida como:

$$S_f(\omega,\tau) = \int f(t)g * (t-\tau)e^{-j\omega t}dt$$
(7.3)

donde *g* es una ventana deslizante, la cual tiene un ancho fijo y cambia a lo largo del eje x por un factor  $\tau$ .
En la figura 9 se presenta la función de ventana definida como

$$g(t) = \frac{1}{s} \exp\left(-\frac{\pi t^2}{s^2}\right) \tag{7.4}$$

Con la Transformada de Fourier con Ventana se logra una mejor localización de la aparición de una singularidad en una señal. Pero solo se conocerá en qué intervalo de tiempo se produce la singularidad, debido a que la localización depende del ancho elegido para la función ventana. Además, los eventos no podrán ser resueltos si aparecen muy cerca unos de otros, ya que no será posible distinguir diferentes comportamientos dentro de una misma amplitud de ventana [38].

Debemos recordar que el hecho de utilizar ventanas hace que se convolucione la transformada de la señal con la transformada de la ventana, por esta razón es necesario seleccionar la ventana que produzca menor distorsión. Existen varios tipos de ventanas que cumplen con este objetivo, algunas de ellas son la ventana Hamming, Hanning y Parzen. De todas éstas la más utilizada es la Hanning [8].

#### Figura 9. Ejemplo función ventana



**Fuente:** PINTO, J. Análisis e interpretación de señales cardiorrespiratorias para determinar el momento óptimo de desconexión de un paciente asistido mediante ventilación. Tesis Universidad Autónoma de Bucaramanga, 2014.

Otros métodos que pueden ser usados para el análisis de señales no estacionarias puede ser la distribución de Wigner-Ville (WVD), la distribución de Choi-Williams (CWD) y la transformada de Fourier de tiempo reducido (STFT). El problema de la STFT es que sólo permite apreciar un intervalo definido del evento transitorio que se desee analizar y no es posible precisar con claridad su ubicación exacta, ya que las ventanas tanto de tiempo como de frecuencia son de ancho constante[39], esto significa que si se desea obtener una buena resolución en frecuencia usando el tamaño de ventana, el cual es deseable para el análisis de componentes en baja frecuencia, no se tiene posibilidad de obtener buena resolución en el tiempo, el cual es deseable en los componentes de alta frecuencia. Por lo tanto la STFT está disponible para análisis de señales cuasi estacionario (estacionario en la escala de la ventana pero no para señales estacionarias reales). Además, existen bases no ortogonales para la STFT, por lo tanto es difícil encontrar un algoritmo rápido y efectivo para calcular la STFT [37].

#### 7.1.1.2 Transformada Wavelet

En los últimos 15 años, la transformada wavelet se ha hecho muy popular en monitoreo de condición, siendo muy atractiva para la operación de dos actividades principales en señales de naturaleza compleja (transientes y /o no estacionarias): eliminación de ruido y extracción de características [24]. La eliminación de ruido se lleva a cabo a fin de reducir la fluctuación y seleccionar información de diagnóstico oculta o débil, este proceso puede realizarlo sin apreciable degradación de la señal original. La extracción de características usualmente proporciona la entrada a un sistema experto para la vigilancia autónoma de la degradación de la salud de las máquinas y los pronósticos basados en datos [30]. En la figura 10 puede verse un esquema de la filosofía Wavelet basada en monitoreo de condición.

La transformada *Wavelet* permite hacer una representación tiempo-frecuencia de una señal. La habilidad del análisis Wavelet radica en que permite enfocar intervalos

cortos de tiempo en componentes de alta frecuencia e intervalos largos para componentes de baja frecuencia, lo cual es muy importante en diagnóstico de falla así como también, mejora el análisis de señales con impulsos y oscilaciones localizadas. Adicionalmente, revela aspectos de la señal que otras técnicas no harían, como por ejemplo puntos de ruptura y discontinuidades de la señal, además de permitir conocer tendencias. Por esta razón, la descomposición Wavelet es ideal para el estudio de señales transitorias obteniéndose una mejor caracterización y una discriminación más precisas de las señales [21]. Además, la transformada Wavelet es una transformada reversible en la cual se hace reconstrucción o evaluación de los componentes seguros posibles de la señal, aunque la transformada inversa puede ser no ortogonal [37].

Existe dos tipos de transformada, las cuales se describen brevemente a continuación [38]:

 Transformada Wavelet continua (CWT): La transformada Wavelet continua permite el análisis de una señal en un segmento localizado de ésta y consiste en expresar una señal continua como una expansión de términos o coeficientes del producto interno entre la señal y una Función Wavelet Madre.

 Transformada Wavelet discreta (DWT): Por la complejidad en el tratamiento numérico de la DWT, debido a la variabilidad en forma continua de los parámetros de escala como de traslación, es indispensable contar con una herramienta que permita la discretización de ésta. Es así que se pasará de un mapeo continuo a un espectro o conjunto finito de valores, a través del cambio de la integral por una aproximación con sumatorias. La discretización permite representar una señal en términos de funciones elementales acompañadas de coeficientes.

De esta manera, una señal s (t) puede ser escrita como [31]:

$$s(t) = \sum_{j=1}^{j} c_j(k) \varphi_{j,k}(t) + \sum_{j=1}^{j} \sum_k d_j(k) \psi_{j,k}(t)$$
(7.5)

donde:  $\varphi y \psi$  son familia de funciones generadas de funciones básicas de escalamiento  $\varphi(t)$  y wavelet madre  $\psi(t)$ , respectivamente. Cuando el índice k cambia de valor, la wavelet se mueve sobre el eje del tiempo permitiendo la localización en tiempo del evento. Cuando el índice j cambia, la forma de la wavelet cambia en escala. Esto permite una representación de los detalles de la señal [31]:

- Coeficientes de Aproximación ( componentes de baja frecuencia de la señal):  $c_j(k) = \sum_m h(m - 2k)c_{j+1}(m)$ (7.6)
- Coeficientes de Detalles( componentes de alta frecuencia de la señal):

$$d_{j}(k) = \sum_{m} hl(m - 2k)c_{j+1}(m)$$
(7.7)

donde *h* (*m*) y *hl* (*m*) son los coeficientes del filtro paso bajo y paso alto asociados a la función de escalamiento y a la función wavelet respectivamente. El efecto multiresolucional o cambio del tamaño de la ventana de observación se obtienen cuando los coeficientes de aproximación, una vez submuestreados, se hacen pasar de nuevo por los mismos filtros paso bajo y paso alto. Al repetir este procedimiento de filtrado N veces, siendo N el número de niveles de descomposición, se obtiene la representación multiresolucional de la señal objeto de análisis [31]. En la figura 11 se muestra el árbol de descomposición Wavelet de una señal en sus respectivos Ca y Cd.

#### 7.1.1.2.1 Wavelet Packet Transform (WPT)

Es una generalización que aplica el proceso de descomposición Wavelet tanto a los coeficientes de aproximación como a los coeficientes de detalle resultantes, es decir, el análisis se realiza de manera independiente tanto en las bandas de baja como alta frecuencia, lo que puede visualizarse como un árbol con dos laterales, uno correspondiente al filtro pasa baja y el otro al filtro pasa alta, y se compone de una familia de funciones wavelet conocidas que están linealmente combinadas como puede verse en la figura 12

Figura 10. Esquema de la filosofía Wavelet basada en monitoreo de condición



**Fuente:** PINTO, J. Análisis e interpretación de señales cardiorrespiratorias para determinar el momento óptimo de desconexión de un paciente asistido mediante ventilación. Tesis Universidad Autónoma de Bucaramanga, 2014.

Figura 11. Árbol de descomposición Wavelet de una señal



**Fuente:** PINTO, J. Análisis e interpretación de señales cardiorrespiratorias para determinar el momento óptimo de desconexión de un paciente asistido mediante ventilación. Tesis Universidad Autónoma de Bucaramanga, 2014.



Figura 12. Árbol de WPD (Wavelet Packet Descomposition) de una señal

**Fuente:** HOU, W., LU, C., LIU, H., and LU, C. Fault Diagnosis based on wavelet package for hydraulic pump. En: Reliability, Maintainability and Safety ICRMS, IEEE transactions on, 2009, p. 831-835

Generalmente una señal es descompuesta en paquetes, donde cada paquete representa una banda de frecuencia sin intersección. Si la señal en algunas frecuencias no es útil, los paquetes correspondientes pueden ajustarse a cero [24]. El árbol de WPD también puede ser considerado como la salida de un filtro que ha sido sintonizado en una función básica particular. En la parte superior del árbol de descomposición, donde el nivel de descomposición es bajo, el dominio del tiempo puede ser efectivamente resuelto, pero la resolución en el dominio de la frecuencia es pobre. En la parte baja del árbol donde el nivel de descomposición es alto, el dominio de la frecuencia puede ser efectivamente resuelto pero la resolución en el dominio de la frecuencia es más importante que en el dominio del tiempo en monitoreo y diagnóstico de salud estructural (Health Monitoring and Prognostics). Así, un alto nivel de WPD es frecuentemente requerido para detectar cambios menores en la señal [26].

Después que la señal ha sido descompuesta en *jth* niveles, la señal original f(t) puede ser reconstruida por la suma de los  $2^{j}$  componentes como [26]:

$$f(t) = \sum_{i=1}^{2^{j}} f_{j}^{i}(t)$$
(7.8)

donde  $f_j^i(t)$  es el componente de la señal del paquete wavelet que puede ser expresado como una combinación lineal de funciones de paquete wavelet como:

$$f_{i}^{i}(t) = \sum_{k=-\infty}^{\infty} c_{i,k}^{i} \psi_{i,k}^{i}(t)$$
(7.9)

donde i, j y k son enteros definidos como modulación, escala y parámetro de traslación respectivamente. Los coeficientes del paquete wavelet son definidos como:

$$\psi_{i,k}^{i}(t) = 2^{J/2} \psi^{i}(2t - k)$$
(7.10)

donde  $\psi^{o}(t) = \psi^{1}(t) = \psi(t)$ . El primer  $\psi^{1}(t)$  es llamado función wavelet madre y existen varias disponibles para selección. En la figura 13 pueden verse algunas wavelets madre comúnmente usadas. Wavelets  $\psi^{i}$  son definidas por relaciones como:

$$\psi^{2i} = \sqrt{2} \sum_{k} h(k) \psi^{i} (2t - k)$$
(7.11)

$$\psi^{2i-1} = \sqrt{2} \sum_{k} g(k) \psi^{i} \left( 2t - k \right)$$
(7.12)

donde h(k) y g(k) son filtros de espejo de cuadratura asociados con la escala y las funciones wavelet madre.

#### 7.1.2 Técnicas de Clasificación

#### 7.1.2.1 Redes Neuronales Artificiales (ANN's)

Las Redes Neuronales Artificiales (ANN's) son herramientas de aprendizaje y procesamiento automático que imitan a las neuronas del cerebro humano, haciendo uso de modelos matemáticos que forman un sistema de procesamiento de información paralelo capaz de obtener soluciones adaptivas luego de sucesivas etapas de aprendizaje. Este conocimiento es captado mediante el ajuste de los

parámetros libres de la red, concretamente de sus pesos, minimizando de forma simultánea el error existente entre la salida de la red neuronal y el objetivo asociado. Algunas características fundamentales de estos sistemas son su capacidad para generalizar la información y su tolerancia al ruido, razones por las cuales en el reconocimiento de patrones son consideradas herramientas efectivas para manejar datos incompletos, ambiguos e imperfectos. En adición, se puede decir que son computacionalmente eficientes y requieren de poca capacidad de memoria [9]. Por tanto, son aprovechadas para el diagnóstico, ya sea a través de la implementación de algoritmos de reconocimiento de patrones correspondientes a situaciones de fallos, o como sistema de evaluación de los residuos sensibles a los diferentes modos de fallo [41][43]. En cualquiera de los dos casos, las etapas de aprendizaje y reconocimiento, se combinan para lograr el diagnóstico deseado.





**Fuente:** URL:https://www.slideshare.net/hichamberkouk/introduction-to-wavelet transform-with-applications-to-dsp

En general, las redes neuronales se pueden clasificar de diversas maneras, según su topología, forma de aprendizaje (supervisado o no supervisado), tipos de funciones de activación, valores de entrada (binarios o continuos), un resumen de esta clasificación se muestra en la figura 14.





**Fuente:** BERNAL, J., PRIETO, A., LLANES, O., and GARCÍA, E. Estudio comparativo de clasificadores empleados en el diagnóstico de fallos de sistemas industriales. En: Ing. Mecánica, 2011, Vol.142, No. 2, p.87-98.

Entre estos, podemos destacar por su importancia y uso en el diagnóstico de fallos, las arquitecturas de Perceptrón Multicapa (MLP) y Mapas Autorganizados (SOM)[43][36].

# 7.1.2.1.1 Adaline

Adaline significa Neurona Linear adaptativa y su respectiva regla de entrenamiento es llamada LMS (Least Mean Square), el cual es un poderoso algoritmo supervisado

el cual minimiza el error medio cuadrático y por lo tanto trata de mover la decisión de la fronteras tan lejos como los patrones de entrenamiento lo permitan. LMS es aplicado con éxito en procesamiento de señales [22].

La red Adaline tiene una limitación y es que sólo trabaja con problemas linealmente separables [13]. En la figura 15 puede verse el esquema de una red ADALINE.



## Figura 15. Red ADALINE

**Fuente:** HAGAN, M., DEMUTH, H., BEALE, M., and DE JESÚS, O. Neural network design 2a Edition. Universidad de Oklahoma, 2014.

LMS requiere un set de entradas y targets propios del comportamiento de la red:

$$p_1, t_1; p_2, t_2; \dots, p_Q, t_Q$$
 (7.13)

La matriz de peso (W), el vector de bias (b) se agrupan en el vector  $\mathbf{x}$ . El vector de entrada  $\mathbf{z}$  es también conformado y agrupado con la entrada "1" de bias.

$$\mathbf{x} = \begin{bmatrix} \mathbf{w} \\ b \end{bmatrix}$$
(7.14)

 $z = \begin{bmatrix} p \\ 1 \end{bmatrix}$  "1" es la entrada de bias (7.15)

Al comenzar el entrenamiento la matriz de peso (W) y el bias (b) son ajustados a valores aleatorios. La salida de la red ahora puede ser expresada como:

$$a = x^T z \tag{7.16}$$

Esta expresión aplicada en la fórmula del error medio cuadrático se expresa [43]:

$$F(x) = E[e^2] = E[(t-2)^2] = E[(t-x^T z)^2]$$
(7.17)

Reescribiendo esta ecuación en una notación conveniente:

$$F(x) = c - 2x^{T}h + x^{T}Rx$$
 (7.18)

donde:

$$c = E[t^2] \tag{7.19}$$

$$h = E[tz] \tag{7.20}$$

$$R = E[zz^T] \tag{7.21}$$

El único mínimo, si existe es:

$$x^* = R^{-1}h \tag{7.22}$$

LMS usa la diferencia entre la salida deseada y la salida de la sumatoria que produce la función erros usada para ajustar los pesos [13]:

$$W(k+1) = W(k) + 2 \propto e(k)p^{T}(k)$$
(7.23)

$$b(k+1) = b(k) + 2 \propto e(k)$$
(7.24)

donde  $0 < \alpha < 1/\lambda_{max}$  es el máximo eigenvalor de R.

De manera resumida también puede expresarse la salida de la red como:

$$a = purelin (Wp + b) = Wp + b$$
(7.25)

Algunas de las aplicaciones más comunes de la redes ADALINE son en reducción de ruido adaptativo, procesamiento digital de señales, filtros adaptativos, reconocimiento de patrones de señales sísmicas, pronóstico de clima, cancelación de eco adaptativo de teléfonos y satélite de larga distancia, cancelación de la

interferencia correlacionada en instrumentos acústicos y electrónicos, y ecualización de la señal en módems de alta velocidad [13].

#### 7.1.2.1.2 Multilayer Perceptron (MLP)

Un perceptrón multicapa es una red con alimentación hacia delante, compuesta de varias capas de neuronas entre la entrada y la salida de la misma, esta red permite establecer regiones de decisión mucho más complejas que las de dos semiplanos, como lo hace el perceptrón de un solo nivel [1]. Usando solamente dos capas, la red multicapa perceptrón puede representar la mayoría de funciones matemáticas. Pero, si la información dada no es linealmente separable, la red no solucionará eficientemente el problema. Por lo tanto, se requiere adicionar capas que permitan realizar un mapeo a partir de la información compleja, no lineal o discontinua. Incrementando el número de capas se obtendrá potencia adicional en la red. Pero, esto también incrementará el tiempo computacional. Esta es una herramienta matemática e ingenieril que puede ser aplicada para aprendizaje y reconocimiento de datos no lineales y realizar la aproximación de la función[12][13].

A partir de este análisis surge el interrogante respecto a los criterios de selección para las neuronas de las capas ocultas de una red multicapa, este número en general debe ser lo suficientemente grande como para que se forme una región compleja que pueda resolver el problema, sin embargo no debe ser muy grande pues la estimación de los pesos puede no ser confiable para el conjunto de los patrones de entrada disponibles [1]. El diseño de la mejor arquitectura de red multicapa perceptron es algo que todavía está siendo investigado. La solución más apropiada depende fuertemente del número de entradas, sin embargo, la mayoría de desarrollos usan ensayo y error para optimizar el desempeño de la red. La experiencia del diseñador es también un factor importante en la determinación del mejor tamaño de la red para cada aplicación[13].

En las figuras 16 y 17 se muestra un esquema de una red neuronal de 3 capas, en el cual cada capa tiene su propia matriz de peso (W), su propio vector bias (b), una

red de vectores de entrada (n) y de vectores de salida (a). Las capas de salida uno y dos son las entradas para las capas dos y tres respectivamente. Así la capa dos puede verse como una red de una sola capa con  $R = S^1$ entradas,  $S^1 = S^2$ neuronas, y  $S^1 \times S^2$  matriz de peso  $W^2$ . La entrada a la capa dos es  $a^1$ , y la salida es  $a^2$ . Una capa cuya salida es la red de salida es llamada capa de salida. Las otras capas son llamadas capas ocultas (Hidden Layers) [12][22].



Figura 16. Red Multilayer Perceptron (MLP)

**Fuente:** HAGAN, M., DEMUTH, H., BEALE, M., and DE JESÚS, O. Neural network design 2a Edition. Universidad de Oklahoma, 2014.

Para una red con m capas la salida será[22]:

$$a^{m+1} = f^m + 1(W^{m+1}a^m + b^{m+1})$$
 para m=0,1..., M-1. (7.26)

Las neuronas en la primera capa reciben entradas externas:

$$a^0 = p \tag{7.27}$$

Las salidas en la última capa son las redes de salida:

$$a = a^M \tag{7.28}$$

La regla de aprendizaje del perceptrón para una red multicapa es [1]:

$$W^{nuevo} = W^{anterior} + ep^T \tag{7.29}$$

$$b^{nueva} = b^{anterior} + e \tag{7.30}$$

Figura 17. Red Multilayer Perceptron (MLP) Abreviada



**Fuente:** HAGAN, M., DEMUTH, H., BEALE, M., and DE JESÚS, O. Neural network design 2a Edition. Universidad de Oklahoma, 2014.

MLP han sufrido dificultades con la generalización y producción de modelos que pueden superponer los datos. Sin embargo, también existe el problema de adquirir datos de entrenamiento de alta calidad de las situaciones típicas de falla que se necesitan para entrenar las redes [32].

#### 7.1.2.1.2.1 Propagación hacia atrás (Backpropagation, BP)

La propagación hacia atrás (Backpropagation) es un tipo de red de aprendizaje supervisado, que emplea un ciclo de propagación-adaptación de dos fases. Una vez que se ha aplicado un patrón a la entrada de la red como estímulo, éste se propaga desde la primera capa a través de las capas superiores de la red, hasta generar una salida. Las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta que contribuyen directamente a la salida. Sin embargo, las neuronas de la capa oculta sólo reciben una fracción de la señal total del error, basándose aproximadamente en la contribución relativa que haya

aportado cada neurona a la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total. Basándose en la señal de error percibida, se actualizan los pesos de conexión de cada neurona, para hacer que la red converja hacia un estado que permita clasificar correctamente todos los patrones de entrenamiento [1].

La importancia de este proceso consiste en que, a medida que se entrena la red, las neuronas de las capas intermedias se organizan a sí mismas de tal modo que las distintas neuronas aprenden a reconocer distintas características del espacio total de entrada. Después del entrenamiento, cuando se les presente un patrón arbitrario de entrada que contenga ruido o que esté incompleto, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas individuales hayan aprendido a reconocer durante su entrenamiento. Y a la inversa, las unidades de las capas ocultas tienen una tendencia a inhibir su salida si el patrón de entrada no contiene la característica para reconocer, para la cual han sido entrenadas. Esta tendencia se puede extrapolar, para llegar a la hipótesis consistente en que todas las unidades de la capa oculta de una backpropagation son asociadas de alguna manera a características específicas del patrón de entrada como consecuencia del entrenamiento[1].

El primer paso es propagar la entrada hacia delante a través de la red usando las siguientes ecuaciones[28]:

$$a = logsig(n) = \frac{1}{(1 + e^{-n})}$$
(7.31)

donde: a es la salida de la red, W representa la matriz de pesos, P es el vector de entrada y b es el bias o compensación.

Por lo tanto, la función de error es usada para ajustar los pesos[28]:

$$W(k+1) = W(k) + 2\alpha \cdot e(k)(1-a)(a)p^{T}(k)$$
(7.32)

$$b(k+1) = b(k) + 2\alpha \cdot e(k)(1-a)(a)$$
(7.33)

Entonces las sensibilidades debe ser propagada hacia atrás a través de la red $S^{M} = -2\dot{F}^{M}(n^{M})(t-a) \tag{7.34}$ 

donde  $S^M$  es la sensibilidad de la capa de salida y  $F^{M}(n^M)$  es una matriz Jacobiana:

$$F^{\cdot M}(n^{M}) = \begin{bmatrix} \dot{f}^{m}(n_{1}^{m}) & 0 & \cdots & 0\\ 0 & \dot{f}^{m}(n_{2}^{m}) & \cdots & 0\\ \vdots & \vdots & \cdots & \vdots\\ 0 & 0 & \cdots & \dot{f}^{m}(n_{sm}^{m}) \end{bmatrix}$$
(7.35)

$$S^M \to S^{M-1} \to \dots \to S^2 \to S^1$$
 (7.36)

Las sensibilidades para las capas ocultas son calculadas por:

$$S^m = \dot{F}^m(n_m)(W_{m+1})^T S_{m+1}$$
 para m= M-1,.....2,1. (7.37)

Por último, los pesos y bias son actualizados usando la regla de aproximación del descenso de gradiente:

$$W^{m}(k+1) = W^{m}(k) - \alpha \, s^{m}(a^{m-1})^{T}$$
(7.38)

$$b^{m}(k+1) = b^{m}(k) - \alpha \, s^{m} \tag{7.39}$$

donde a es la rata de aprendizaje,  $S^m$  son las sensibilidades en la capa m, y  $(a^{m-1})^T$  es la capa previa de salida (traspuesta).

El algoritmo MLP con BP tiene dos limitaciones principales: (1) dificultad para determinar la estructura de la red y el número de nodos; (2) convergencia lenta del proceso de entrenamiento[32].

#### 7.1.2.1.2.2 Algoritmo de Levenberg-Maquart

Se aplica principalmente a redes MLP con un número grande de patrones ya que

tiene la velocidad de convergencia del MSE (error cuadrático medio) más rápida hasta ahora, principalmente en problemas de aproximación de funciones a pesar de que su complejidad en cálculos es mayor. Usa la metodología Backpropagation empleando el concepto de regla de generalización delta o de corrección del error (generalized delta rule), usando el concepto de rata de entrenamiento y aplicando el modo de batches, sólo que el gradiente se calcula mediante la matriz Jacobiana de los errores de las neuronas de salida [49].

La ecuación con la que se actualizan los pesos es la siguiente [49]:

$$w(n+1) = w(n) - \alpha \cdot w(n-1) - \frac{J^{T} \cdot e}{J^{T} \cdot J + \mu \cdot I}$$
(7.40)

donde J es la matriz Jacobiana de los errores de las neuronas de salida, es decir, la matriz de las primeras derivadas de dichos errores con respecto a los pesos y umbrales ( $\theta$ ) de los que son función,  $J^T$  es la traspuesta de la matriz Jacobiana, I es la matriz identidad (unos en la diagonal y ceros en las demás localidades) del mismo tamaño que la matriz Jacobiana, e es el vector de errores de las neuronas de salida,  $\alpha$  es la constante del momento y  $\mu$  es la constante equivalente a la rata de entrenamiento que es disminuida en cada iteración en la que se observa una reducción del MSE, o incrementada y se descartan los pesos actualizados cuando se obtiene un aumento en el MSE.

Este algoritmo, aunque requiere mayor número de cálculos que el Backpropagation, evita más oscilaciones del MSE y la matriz Jacobiana es la que hace que se tenga una convergencia demasiado rápida, incluso hasta más de 100 veces más rápida que la obtenida por el Backpropagation con su descenso de gradiente [49].

#### 7.1.2.1.3 Red Neuronal Adaptativa no Lineal

Esta red es similar a la ADALINE, solo que la función de transferencia es una función de tipo sigmoidal no lineal. En la figura 18 se muestra un ejemplo de la topología de este tipo de red.

La función de transferencia sigmoidal está dada por [42]:

$$a = logsig(n) = \frac{1}{(1 + e^{-n})}$$
 (7.41)

donde: a es la salida de la red, W representa la matriz de pesos, p es el vector de entrada y b es el bias o ajuste.

Esta red puede trabajar muy bien con problemas no lineales y no lineales separables. Usa el algoritmo de mínimos cuadrados LMS (least mean square). Por lo tanto, la función de error usada para ajustar los pesos son [13]:

$$W(k+1) = W(k) + 2\alpha \cdot e(k)(1-a)(a)p^{T}(k)$$
(7.42)

$$b(k+1) = b(k) + 2\alpha \cdot e(k)(1-a)(a)$$
(7.43)

Esta red tiene una capa de neuronas no lineales.

#### Figura 18. Topología de una red neuronal adaptativa no lineal de una sola capa



**Fuente:** BORRAS, C. Pattern recognition in hydraulic backlash using neural network. Master Thesis, University of Oklahoma, 2001

# 7.3 Caso de Investigación: Desgaste Plato de Válvulas en Bombas de Pistones Axiales de Desplazamiento Variable

En el diseño de la bomba de pistones axiales, el cilindro portapistones está hidrostáticamente cargado contra el plato de válvula, como se muestra en la figura 19. El plato de válvula tiene dos puertos: El puerto de succión el cual está relacionado con el tanque de aceite y el puerto de descarga que está relacionado con la carga. Estos dos puertos ejercen diferente presión contra el cilindro

portapistones. La holgura es una holgura inclinada. La distribución de la presión es muy complicada y no es una constante causada por el principio de funcionamiento de la bomba de pistones axiales (depende del ángulo del plato oscilante). Si la presión de operación supera los límites de diseño, se reducirá la holgura entre el plato de la válvula y el cilindro portapistones.

Cuando aparece el desgaste, no sólo aumenta la holgura entre las dos superficies sino que también las superficies se vuelven cada vez más irregulares. El plato de válvula no hace un buen contacto con el cilindro portapistones, y la película de aceite entre las superficies no es estable, lo que conduce a fugas[17]. Una vez que la película de aceite se pierde (ocurre cuando la fricción y el desgaste son lo suficientemente serios), las dos superficies entran en contacto y se produce la abrasión en los puertos de entrada y salida de la superficie deslizante del plato de válvula [46]. En la figura 20 puede verse la estructura del plato de válvula.

De acuerdo con datos estadísticos, el 75% de las fallas en la bomba de pistones axiales se deben a la abrasión entre el par de fricción, en el cual el ítem más relevante es el desgaste entre el plato de válvula y el cilindro portapistones [23]. En la figura 21 puede verse la morfología de la superficie del plato de válvula con alto grado de abrasión. Esta falla se produce debido a que la presión de operación excede los límites y la holgura entre el plato de válvula y el cilindro portapistones disminuye. Una vez que la película de lubricante se pierde, las dos superficies están en contacto produciendo el desgaste en los bordes de entrada y salida de la superficie deslizante del plato de válvula [23][46][47].



Figura 19. Esquema de una bomba de pistones axiales de desplazamiento variable

**Fuente:** LI, Z. Condition monitoring of axial piston pump. Thesis, University of Saskatchewan, 2005.

# Figura 20. Estructura del plato de válvula



**Fuente:** HE,Z.,HU, W.,WANG, S., and ZHAO, S. Prognostic analysis based on updated grey model for axial piston pump.En:5<sup>th</sup> IEEE Conference on Industrial Electronics and Applications ICIEA, IEEE transactions on, 2010, p. 571-575.

Figura 21. Morfología de la superficie del plato de válvula con alto grado de abrasión



**Fuente:** MARADEY, J.,BORRÁS, C., and ROA, S.,A survey of approaches for fault diagnosis in axial piston pump. En:International Mechanical Engineering Congress and Exposition IMECE, ASME transactions on, Nov.2016, Vol.4A, p.5A052-1 - 5A052-13.

# 8. METODOLOGÍA DE DIAGNÓSTICO PROPUESTA

El desarrollo del presente proyecto consistió en 5 etapas en las cuales se programaron actividades específicas en concordancia con la metodología y objetivos propuestos.

## 8.1 Adquisición y Análisis Preliminar de los Datos

Para la adquisición de las señales, se cuenta con un banco de pruebas compuesto de una bomba hidraúlica de pistones axiales de desplazamiento variable marca Eaton serie 54, motor hidráulico modelo M-21 y un motor eléctrico de 40 hp. En la figura 22 puede verse el montaje del banco de pruebas.

Así mismo, se utilizó un sistema DAQ consistente de sensores (un caudalímetro (fabricante: Flow Metrics, modelo FM-8), dos transductores de presión (Para la

succión, fabricante: WIKA, modelo ECO-1, y para la descarga, fabricante: MSI, serie MSP300) y un acelerómetro (fabricante: PCB piezotronics, modelo 352C33)), un módulo de acondicionamiento de la señal y convertidor analógico-digital y software. El hardware y software utilizado son de la empresa National Instruments, tarjeta NI USB-9234, NI-USB6215 y Measurement & Automation Explorer (MAX), NI–DAQmx y NI LabView 2013 respectivamente [16].

Se tomaron tres señales, señal de voltaje correspondiente al caudal (punto A), señal de vibración en 4 puntos o posiciones de interés (1-4), señales de presión en el puerto de salida de la bomba (punto B) y en la bomba de precarga (punto C). Esto puede verse en las figuras 23 y 24.



Figura 22. Banco de Pruebas

**Fuente:** BOLAÑO, Y., and NIÑO, J., Rediseño y construcción de un banco de pruebas para diagnóstico de fallas en una hidrotransmisión bomba variable-motor fijo, Tesis Universidad Industrial de Santander, 2016.

Las señales adquiridas de vibración y presión, se tomaron para las siguientes condiciones a 700psi:

- Condición 1 correspondiente al estado normal (94.9% de Eficiencia Volumétrica).
- Condición 2 correspondiente a condición de falla (90,1% de Eficiencia Volumétrica).
- Condición 3 correspondiente a condición de falla (84,6% de Eficiencia Volumétrica).
- Condición 4 correspondiente a condición de falla (74,8% de Eficiencia Volumétrica).
- Condición 5 correspondiente a condición de falla (69,5% de Eficiencia Volumétrica).
- Condición 6 correspondiente a condición de falla (64,9% de Eficiencia Volumétrica).

Las posiciones 1-4 para las cuales se tomaron las señales de vibración corresponden a los siguientes puntos:

- Posición 1: Sobre el barril de pistones.
- Posición 2: Sobre los platos de desgaste.
- Posición 3: Sobre los platos de desgaste.
- Posición 4: Sobre la bomba de precarga.

Para las señales de presión se tomaron para el análisis los datos de la presión de precarga y en el puerto A, a los cuales llamamos posición 1 y posición 2 para facilitar el procesamiento.



Figura 23. Posiciones en las que se tomaron señales de vibración

**Fuente:** CASTILLO, S., and SERRANO, J. Metodología de mantenimiento predictivo para diagnóstico de fallas en bombas hidráulicas de pistones axiales asociadas con desgaste de los platos rodantes de presión, Tesis Universidad Industrial de Santander, 2016.

La frecuencia de muestreo para las señales de vibración fue de 50KHz/seg y para las señales de presión y caudal es de 100KHz/seg. Para las señales de vibración, se tomaron aproximadamente 16 señales por cada condición y posición. La cantidad de muestras tomadas por señal fue de 50.000 - 200.000. Para las señales de presión, se tomaron 15 señales con 60.000 muestras cada una. Cabe resaltar igualmente que las muestras tomadas son confiables, ya que se verificaron los valores obtenidos con los datos de flujo de pérdida tomados por el caudalímetro.

Para la selección de número de muestras a tomar para el procesamiento, detección y clasificación de la falla, se debe tener en cuenta la resolución en frecuencia deseada (A mayor número de muestras menos espaciamiento en frecuencia), eficiencia computacional y significancia de las características de la señal. En la

figura 25 se puede ver el nivel de significancia de las características de las señales de vibración, tomando 5.000, 50.000 y 100.000 muestras. Se puede observar que la kurtosis de aproximación es la que más tiene significancia al tomar 100.000 muestras, por lo que se decide trabajar con 100.000 muestras buscando el mayor aprovechamiento de las señales y datos tomados.



Figura 24. Posiciones señales de caudal y presión

**Fuente:** CASTILLO, S., and SERRANO, J. Metodología de mantenimiento predictivo para diagnóstico de fallas en bombas hidráulicas de pistones axiales asociadas con desgaste de los platos rodantes de presión, Tesis Universidad Industrial de Santander, 2016

Después se procedió a corregir la línea base de las señales, eliminar las tendencias y al análisis espectral de cada condición (P-Welch).

Analizando el espectro de las señales de vibración, se pudo observar que en la condición 1 (operación normal) se tienen picos tanto en frecuencias bajas como en altas, es decir, en las bandas de 0-4 KHz y de 10-14 Khz, mientras que en la condición 6 (desgaste extremo, eficiencia volumétrica de 64,9%) se observan los picos en la banda de 10-14KHz, en la posición 1 pronunciado y en la posición 4 con

amplitud menor, esto tiene sentido ya que la respuesta dinámica del sistema dado el flujo de pérdida es de tipo amortiguado. Los espectros obtenidos de las señales de vibración se muestran en las figuras 26-31. Igualmente se puede observar que las posiciones que más proveen diferenciación entre las condiciones son las posiciones 1 y 4.





Adicionalmente se implementaron dos filtros, para el caso de las señales de vibración, un filtro pasa baja y otro paso alto para revisar cómo se comportaban las señales, que pueden verse en las figuras 32 -35 para las condiciones 1 y 6. Como puede evidenciarse en el caso del filtro pasa baja se puede ver que el comportamiento es muy similar al mencionado anteriormente. En las tablas 4- 7 se pueden observar los datos de frecuencias, picos y potencia de las señales de la condición 1 posición 1 y posición 4 vs condición 6 posición 1 y 4.

En la figura 36 se grafica la potencia vs el centro de alta frecuencia (el cual corresponde al pico de mayor amplitud), donde se agrupan cada una de las condiciones para cada posición, puede observarse que en la posición 1 es la

condición 6 la que tiene mayor potencia, mientras que en la posición 4 la condición 6 es la de menor potencia.

Los espectros de las señales de presión (condición 1 y condición 6) y los filtros diseñados pueden verse en las figuras 37 y 38. Al analizar estas figuras, no se observan cambios apreciables en los espectros de cada condición, sin embargo es destacable que al filtrar las señales se ven picos en alta frecuencia (del orden de los 25KHz) y al graficar la potencia y centro de alta frecuencia no es posible distinguir fácilmente la condición 1 y la condición 6. Así mismo puede verse en las tablas 8-11 que los valores de frecuencias, picos y potencia de las señales de la condición 1 y posición 2 vs condición 6 posición 1 y 2 son relativamente pequeños.







Figura 27. Espectro de la señal de vibración condición 2 (90,1%)

Figura 28. Espectro de la señal de vibración condición 3 (84,6%)





Figura 29. Espectro de la señal de vibración condición 4 (74,8%)

Figura 30. Espectro de la señal de vibración condición 5 (69,5%)





Figura 31. Espectro de la señal de vibración condición 6 (64,9%)

Figura 32. Filtro pasa baja para la condición 1 (94,9%)





Figura 33. Filtro pasa baja para la condición 6 (64,9%)

Figura 34. Filtro pasa alta para la condición 1 (94,9%)





Figura 35. Filtro pasa alta para la condición 6 (64,9%)

Condición 1, Posición 1 Señal 1 2 3 4 5 8 9 10 11 12 13 Item 6 7 Picos de 1.22 700.68 700.68 700.68 701.90 700.68 700.68 700.68 700.68 700.68 700.68 700.68 700.68 Baja 700.68 876.46 876.46 876.46 876.46 876.46 875.24 876.46 876.46 876.46 876.46 876.46 875.24 Frecuencia 876.46 1051.03 1052.25 1052.25 1052.25 1051.03 1051.03 1051.03 1051.03 1051.03 1051.03 1051.03 1051.03 1051.03 1226.81 1226.81 1226.81 1226.81 1226.81 1225.59 1226.81 1226.81 1226.81 1225.59 1225.59 1226.81 1226.81 1401.37 1402.59 1402.59 1402.59 1401.37 1401.37 1401.37 1401.37 1401.37 1401.37 1401.37 1400.15 1401.37 1751.71 1752.93 1752.93 1752.93 1752.93 1751.71 1751.71 1751.71 1751.71 1751.71 1751.71 1750.49 1751.71 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 Amplitud 0.04 0.03 0.04 0.03 0.03 0.03 0.03 0.03 0.04 0.04 0.04 0.04 0.04 0.04 0.04 0.02 0.02 0.02 0.02 0.02 0.02 0.02 0.02 0.02 0.02 0.02 0.02 0.02 0.02 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.02 0.02 0.01 0.01 0.01 0.01 0.02 0.02 0.01 0.02 0.02 0.02 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 Potencia 0.32 0.29 0.28 0.29 0.28 0.27 0.28 0.28 0.29 0.29 0.29 0.28 0.28 Condición 1, Posición 4 Señal Item 1 2 3 4 5 6 7 9 10 11 12 13 8 19.53 19.53 Picos de 19.53 19.53 19.53 19.53 19.53 19.53 19.53 19.53 19.53 19.53 19.53 117.19 117.19 700.68 117.19 89.11 700.68 700.68 117.19 117.19 117.19 117.19 117.19 117.19 Baja 1051.03 Frecuencia 700.68 700.68 1051.03 700.68 700.68 1051.03 700.68 700.68 700.68 700.68 700.68 700.68 1051.03 1051.03 1051.03 1051.03 1225.59 1051.03 1051.03 1226.81 1225.59 1051.03 1051.03 1051.03 1051.03 1225.59 1226.81 1401.37 1401.37 1225.59 1225.59 1225.59 1401.37 1226.81 1226.81 1225.59 1225.59 1225.59 1401.37 1401.37 1577.15 1401.37 1401.37 1575.93 1575.93 1400.15 1401.37 1401.37 1401.37 1401.37 1401.37 1575.93 1577.15 1577.15 1577.15 1751.71 1751.71 1575.93 1575.93 1575.93 1575.93 1575.93 0.00 1575.93 1751.71 1751.71 0.00 1751.71 1751.71 2102.05 2102.05 1750.49 1751.71 1750.49 1751.71 1750.49 1751.71 2102.05 2100.83 2102.05 2102.05 2102.05 0.00 2102.05 0.00 0.00 2102.05 2100.83 1926.27 2100.83 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 2100.83 0.00 0.00 0.02 0.01 0.01 0.02 0.01 0.02 0.02 0.01 Amplitud 0.01 0.02 0.01 0.02 0.01 0.00 0.00 0.01 0.00 0.00 0.01 0.02 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.01 0.01 0.00 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.00 0.01 0.00 0.00 0.01 0.00 0.00 0.00 0.00 0.00 0.01 0.00 0.00 0.01 0.01 0.03 0.01 0.01 0.02 0.03 0.01 0.01 0.01 0.01 0.01 0.01 0.02 0.02 0.01 0.02 0.02 0.01 0.01 0.02 0.02 0.02 0.02 0.02 0.02 0.01 0.00 0.01 0.01 0.00 0.00 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.01 0.01 0.00 0.15 0.15 0.16 0.21 0.16 0.16 0.16 0.15 0.14 0.18 0.14 0.15 0.14 Potencia

Tabla 4. Datos tabulados filtro pasa baja para la condición 1 (94,9%) señales de vibración

Condición 6, Posición 1 Señal Item 1 2 з 4 5 6 7 8 9 10 11 12 13 Picos de 700.68 700.68 700.68 700.68 701.90 700.68 700.68 701.90 701.90 701.90 701.90 701.90 701.90 1051.03 1052.25 1052.25 1051.03 1052.25 1052.25 1052.25 1052.25 1052.25 Baja 1052.25 1052.25 1052.25 1053.47 Frecuencia 1226.81 1226.81 1226.81 1226.81 1228.03 1226.81 1226.81 1228.03 1228.03 1228.03 1228.03 1228.03 1228.03 1402.59 1402.59 1402.59 1402.59 1402.59 1402.59 1402.59 1402.59 1402.59 1402.59 1402.59 1402.59 1403.81 1577.15 1577.15 1577.15 1578.37 1578.37 1577.15 1577.15 1578.37 1578.37 1578.37 1578.37 1578.37 1579.59 1752.93 1752.93 1752.93 1754.15 1754.15 1754.15 1754.15 1752.93 1752.93 1752.93 1752.93 1752.93 1755.37 1928.71 1889.65 1927.49 1927.49 1927.49 1927.49 1927.49 1889.65 1928.71 1928.71 1928.71 1929.93 1929.93 1947.02 2098.39 1947.02 1947.02 1928.71 1947.02 1947.02 1928.71 1948.24 1948.24 2084.96 2099.61 2027.59 2025.15 2103.27 2098.39 2083.74 1986.08 2025.15 2025.15 1948.24 2025.15 2098.39 2099.61 2104.49 2086.18 2098.39 2122.80 2103.27 2098.39 2098.39 2083.74 2083.74 1986.08 2084.96 2104.49 2104.49 2161.87 2100.83 2103.27 2277.83 2277.83 2103.27 2104.49 2097.17 2098.39 2025.15 2098.39 2279.05 2161.87 2193.60 2105.71 2279.05 2453.61 2370.61 2194.82 2154.54 2103.27 2103.27 2098.39 2104.49 2369.38 2193.60 2280.27 2281.49 2453.61 2279.05 2194.82 2196.04 2160.64 2104.49 2193.60 2454.83 2280.27 2456.05 2368.16 0.00 2370.61 2457.28 2453.61 2369.38 0.00 0.00 2370.61 2279.05 2277.83 2279.05 2153.32 2279.05 0.00 0.00 0.00 0.01 0.01 0.01 Amplitud 0.01 0.01 0.00 0.01 0.01 0.00 0.00 0.00 0.01 0.00 0.00 0.00 0.00 0.01 0.00 0.00 0.01 0.00 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.00 0.01 0.01 0.00 0.01 0.01 0.01 0.01 0.01 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.01 0.00 0.00 0.01 0.00 0.01 0.01 0.00 0.09 0.09 0.09 0.09 0.10 0.09 0.09 0.09 0.09 Potencia 0.09 0.09 0.09 0.09 Condición 6, Posición 4 Señal 10 11 Item 1 2 3 4 5 6 7 8 9 12 13 Picos de 1.22 19.53 19.53 19.53 19.53 19.53 19.53 19.53 19.53 19.53 19.53 19.53 19.53 526.12 Baja 19.53 526.12 526.12 526.12 526.12 526.12 526.12 526.12 526.12 526.12 526.12 526.12 0.00 1402.59 1403.81 1403.81 1403.81 1402.59 1402.59 1403.81 1402.59 1402.59 1403.81 1405.03 1402.59 Frecuencia 1754.15 1754.15 1752.93 1755.37 1931.15 1754.15 0.00 1928.71 1754.15 1755.37 1929.93 1754.15 1928.71 0.00 0.00 1929.93 1929.93 0.00 1928.71 0.00 1929.93 1928.71 1928.71 1931.15 0.00 1929.93 Amplitud 0.09 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.00 0.13 0.04 0.04 0.04 0.04 0.04 0.04 0.04 0.04 0.04 0.04 0.04 Potencia 0.04

Tabla 5. Datos tabulados filtro pasa baja para la condición 6 (64,9%) señales de vibración

Condición 1, Posición 1													
	Señal												
Item	1	2	3	4	5	6	7	8	9	10	11	12	13
Picos de	10240.17	11247.25	11347.96	9449.77	10206.60	9347.53	11169.43	10211.18	11239.62	11222.84	11213.68	11158.75	11116.03
Alta	10336.30	11158.75	11203.00	9329.22	11132.81	11146.55	11091.61	11125.18	11138.92	11297.61	9301.76	11250.31	10157.78
Frecuencia	11222.84	11343.38	11177.06	11120.61	11212.16	11338.81	11163.33	11247.25	11244.20	9304.81	10096.74	9440.61	11244.20
Amplitud	0.04	0.04	0.03	0.03	0.03	0.03	0.05	0.03	0.03	0.04	0.05	0.03	0.03
	0.03	0.03	0.03	0.03	0.03	0.03	0.04	0.03	0.03	0.03	0.04	0.03	0.02
	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.02	0.03	0.04	0.03	0.02
Potencia	12.57	12.66	12.34	11.86	12.34	12.36	12.58	12.13	12.16	12.17	12.00	12.04	11.83
Condición 1, Posición 4													
							Señal						
Item	1	2	3	4	5	6	7	8	9	10	11	12	13
Picos de	10017.4	9977.722	9495.544	9693.909	9695.435	9924.316	9918.213	9651.184	9902.954	9880.066	9962.463	9671.021	9629.822
Alta	9944.153	9896.851	9399.414	9671.021	9671.021	9690.857	9674.072	9884.644	9611.511	9921.265	9687.805	9904.48	9667.969
Frecuencia	9899.902	9886.169	9613.037	9927.368	9928.894	9898.376	9802.246	9667.969	9967.041	9707.642	9611.511	9947.205	9419.25
Amplitud	0.290167	0.142953	0.121554	0.379778	0.219975	0.131034	0.179166	0.20742	0.186757	0.291065	0.209174	0.282152	0.170493
	0.277797	0.101552	0.112023	0.360039	0.192929	0.122665	0.166156	0.181342	0.154614	0.254289	0.179797	0.258885	0.167017
	0.267848	0.091574	0.106199	0.355245	0.192593	0.117717	0.159743	0.164801	0.149274	0.253463	0.173394	0.251101	0.159321
Potencia	49.13944	18.03311	24.58054	61.86046	36.24433	27.68283	26.15469	33.40366	27.29639	44.88358	33.83043	31.36155	32.91347

Tabla 6. Datos tabulados filtro pasa alta para la condición 1 (94,9%) señales de vibración

# Tabla 7. Datos tabulados filtro pasa alta para la condición 6 (64,9%) señales de vibración

Condición 6, Posición 1													
	Señal												
Item	1	2	3	4	5	6	7	8	9	10	11	12	13
Picos de	14739.99	14257.81	14300.54	14178.47	14057.92	14099.12	14280.7	14468.38	14653.02	14160.16	14334.11	13975.52	14088.44
Alta	14511.11	13966.37	14683.53	14468.38	14224.24	14711	14230.35	14401.25	14425.66	14288.33	14204.41	14199.83	14111.33
Frecuencia	13975.52	14228.82	14773.56	14862.06	14494.32	14178.47	14071.66	14697.27	14524.84	14758.3	14268.49	14205.93	14393.62
Amplitud	0.243835	0.170824	0.269124	0.269675	0.224417	0.196479	0.239995	0.236007	0.206423	0.190991	0.164124	0.238803	0.252513
	0.225073	0.155336	0.203242	0.195895	0.21449	0.195767	0.208601	0.177453	0.194824	0.177348	0.162459	0.200869	0.200811
	0.202289	0.150776	0.185583	0.193178	0.201193	0.190898	0.196863	0.176782	0.187626	0.176618	0.157322	0.198549	0.184088
Potencia	74.28799	73.93661	71.58199	73.15958	73.23263	72.67607	73.06883	70.4537	71.58617	71.58574	71.42305	73.07768	72.17764
	Condición 6, Posición 4												
							Señal						
Item	1	2	3	4	5	6	7	8	9	10	11	12	13
Picos de	10070.8	10949.71	11018.37	10723.88	10856.63	9904.48	10621.64	10682.68	10029.6	10672	10086.06	10731.51	10192.87
Alta	10809.33	10862.73	10902.4	11036.68	10893.25	10885.62	11010.74	10331.73	10147.09	10464.48	10800.17	10653.69	9971.619
Frecuencia	10906.98	10885.62	10813.9	10842.9	10989.38	9986.877	10658.26	10972.6	10150.15	10920.72	9877.014	10861.21	10824.58
Amplitud	0.020175	0.021665	0.022057	0.023869	0.019453	0.024188	0.024583	0.026956	0.02558	0.025888	0.029888	0.02324	0.01915
	0.019444	0.019997	0.02175	0.022868	0.017522	0.023368	0.021047	0.02334	0.022363	0.024914	0.023899	0.021829	0.017808
	0.019115	0.017839	0.019903	0.019958	0.017453	0.021955	0.020819	0.022305	0.022233	0.0214	0.020931	0.021776	0.01761
Potencia	5.200533	5.272157	5.172238	5.219202	5.142321	4.758157	4.992708	4.966912	6.091924	5.064521	5.347228	5.251795	5.123115

Figura 36. Potencia vs centro de alta frecuencia de las señales de vibración por cada condición y posición.



Figura 37. Espectro de las señales de presión condición 1 (94,9%)




Figura 38. Espectro de las señales de presión condición 6 (64,9%)

Figura 39. Filtro pasa baja para la condición 1 (94,9%)





Figura 40. Filtro pasa baja para la condición 6 (64,9%)





Figura 42. Filtro pasa alta para la condición 6 (64, 9%)



Tabla 8. Datos tabulados filtro pasa baja para la condición 1 (94,9%) señales de presión

						Cond	lición 1,	Posiciór	1						
							Seña	al							
Item	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Picos de	19.53	19.53	19.53	117.19	19.53	19.53	117.19	19.53	19.53	117.19	19.53	19.53	19.53	19.5313	19.5313
Baja	117.19	117.19	117.19	240.89	117.19	117.19	240.89	117.19	117.19	240.89	117.19	117.19	117.19	117.188	117.188
Frecuencia	240.89	240.89	240.89	540.36	240.89	240.89	481.77	240.89	240.89	540.36	240.89	240.89	240.89	240.885	240.885
	358.07	358.07	358.07	716.15	540.36	481.77	540.36	475.26	481.77	716.15	481.77	475.26	475.26	475.26	481.771
	481.77	540.36	540.36	898.44	716.15	540.36	716.15	540.36	540.36	898.44	540.36	540.36	540.36	540.365	540.365
	540.36	716.15	716.15	1074.22	898.44	716.15	898.44	716.15	716.15	1074.22	716.15	716.15	716.15	716.146	716.146
	716.15	898.44	898.44	0.00	1074.22	898.44	1074.22	898.44	898.44	0.00	898.44	898.44	898.44	898.438	898.438
	898.44	1074.22	1074.22	0.00	0.00	1074.22	0.00	1074.22	1074.22	0.00	1074.22	1074.22	1074.22	1074.22	1074.22
	1074.22	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0	0
Amplitud	1.1E-06	1.2E-06	1.3E-06	9.8E-06	1E-06	8.6E-07	9.7E-06	1.1E-06	8.4E-07	1.1E-05	9.4E-07	1E-06	1.1E-06	1.3E-06	1.2E-06
	8.7E-06	9.9E-06	9.2E-06	4.4E-06	1E-05	8.4E-06	5E-06	9E-06	7.7E-06	5.7E-06	8.8E-06	8.7E-06	8.4E-06	7.9E-06	6.7E-06
	4E-06	3.8E-06	4.4E-06	5.9E-06	4.9E-06	5.2E-06	1.1E-06	5.3E-06	5.4E-06	8.1E-06	6.4E-06	5.7E-06	6E-06	5.8E-06	6.5E-06
	1.2E-06	1E-06	1E-06	3.3E-06	5.1E-06	9.9E-07	7.7E-06	9.5E-07	1.2E-06	3.2E-06	1.1E-06	1.2E-06	1.1E-06	1.3E-06	1.3E-06
	1.3E-06	5.7E-06	6.3E-06	3.1E-06	2.6E-06	6.7E-06	3.6E-06	8.3E-06	7E-06	3E-06	6.6E-06	5.8E-06	5.5E-06	6.2E-06	6.6E-06
	7E-06	2.4E-06	2.7E-06	2.2E-06	2.9E-06	2.9E-06	2.6E-06	2.9E-06	3.4E-06	2E-06	3.8E-06	4.3E-06	3.8E-06	3.9E-06	3.9E-06
	2.8E-06	3.2E-06	2.5E-06	0	2.6E-06	2.8E-06	2.4E-06	2.6E-06	3.1E-06	0	3E-06	3.5E-06	3E-06	2.6E-06	3.6E-06
	2.7E-06	2.6E-06	2.3E-06	0	0	2.5E-06	0	2E-06	1.8E-06	0	2.2E-06	2E-06	2E-06	2.2E-06	2E-06
	2.4E-06	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Potencia	3.6E-05	3.6E-05	3.6E-05	3.8E-05	3.6E-05	3.6E-05	3.5E-05	3.6E-05	3.6E-05						
						Cond	lición 1,	Posiciór	12						
							Seña	al							
Item	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Picos de	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.5313	19.5313
Baja	117.19	39.06	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.188	117.188
Frecuencia	358.07	117.19	358.07	358.07	358.07	358.07	358.07	358.07	358.07	358.07	358.07	358.07	358.07	358.073	358.073
	0.00	358.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0	0
Amplitud	4.3E-05	4.7E-05	4.8E-05	3.7E-05	3.9E-05	3.3E-05	3.3E-05	4.2E-05	3.4E-05	3.8E-05	3.5E-05	3.7E-05	4.2E-05	4.6E-05	4.1E-05
	3E-05	4.9E-06	3E-05	3.2E-05	3.2E-05	2.5E-05	2.8E-05	2.5E-05	2.1E-05	2.7E-05	2.2E-05	2.2E-05	2E-05	1.8E-05	1.5E-05
	1.1E-05	3.3E-05	1E-05	7.7E-06	8.1E-06	7.4E-06	5.9E-06	5.8E-06	5.9E-06	5.6E-06	6E-06	4.7E-06	5.2E-06	5.2E-06	5.2E-06
	0	1E-05	0	0	0	0	0	0	0	0	0	0	0	0	0
Potencia	9.8E-05	9.7E-05	9.6E-05	8.8E-05	8.5E-05	7.6E-05	7.4E-05	8E-05	7.2E-05	7.2E-05	7E-05	7.1E-05	7.3E-05	7E-05	7E-05

		,		,	,	Cond	ición 6,	Posición	1	,					,
							Seña	al							
Item	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Picos de	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.53	19.5313	19.5313
Baja	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.19	117.188	117.188
Frecuencia	182.29	182.29	182.29	182.29	175.78	175.78	182.29	182.29	182.29	182.29	182.29	182.29	182.29	182.292	182.292
	240.89	240.89	221.35	221.35	221.35	240.89	240.89	240.89	240.89	221.35	240.89	240.89	240.89	240.885	240.885
	260.42	260.42	240.89	240.89	240.89	260.42	260.42	260.42	260.42	240.89	260.42	260.42	260.42	260.417	260.417
	0.00	0.00	260.42	260.42	260.42	0.00	0.00	0.00	0.00	260.42	0.00	0.00	0.00	0	0
Amplitud	2.5E-06	2E-06	5.8E-06	3.2E-06	2.3E-06	2.4E-06	2.4E-06	2.3E-06	2E-06	2E-06	2.4E-06	2.4E-06	2.1E-06	1.8E-06	1.9E-06
	3.6E-06	2.6E-06	5.6E-06	3.5E-06	3.3E-06	3E-06	2.6E-06	2.4E-06	2.7E-06	3.2E-06	2.6E-06	2.6E-06	3.2E-06	2.8E-06	2.8E-06
	3.7E-06	2.6E-06	4.4E-06	3.6E-06	2.6E-06	2.2E-06	2.4E-06	2.1E-06	2.1E-06	2.1E-06	2.4E-06	2.3E-06	2.2E-06	2.3E-06	2.3E-06
	8.3E-06	8.8E-06	1.4E-06	9.3E-07	9E-07	8.5E-06	7.9E-06	8.6E-06	9.9E-06	8E-07	8.2E-06	9.6E-06	9.3E-06	1E-05	9.9E-06
	2.1E-06	1.2E-06	9.4E-06	8.6E-06	7.7E-06	1.5E-06	1.2E-06	1.9E-06	1.4E-06	7.4E-06	1.5E-06	1.7E-06	1.2E-06	1.2E-06	1.2E-06
	0	0	2E-06	1.4E-06	1.7E-06	0	0	0	0	1.8E-06	0	0	0	0	0
Potencia	2.2E-05	1.9E-05	3E-05	2.2E-05	2E-05	1.9E-05	1.9E-05	1.9E-05	1.9E-05	1.9E-05	1.9E-05	1.9E-05	1.8E-05	1.9E-05	1.9E-05
						Cond	ición 6,	Posición	2						
							Seña	al							
Item	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Picos de	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313	19.5313
Amplitud	9.5E-05	7.9E-05	0.00016	0.00011	8.4E-05	8.8E-05	9.2E-05	9E-05	8.5E-05	7.8E-05	9.6E-05	9.2E-05	8.3E-05	7.3E-05	8E-05
Potencia	0.0001	8.6E-05	0.00015	0.00011	1E-04	9.6E-05	9.6E-05	9.3E-05	9.4E-05	9.2E-05	9.2E-05	8.9E-05	8.8E-05	8.8E-05	8.9E-05

Tabla 9. Datos tabulados filtro pasa baja para la condición 6 (64,9%) señales de presión

Tabla 10. D	Datos tabulados filtro	pasa alta para la	a condición 1	(94,9%) señales
de presión				

	Condición 1, Posición 1														
							1	Señal							
Item	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Picos de	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.89648	49993.89648
Baja	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	20007.32	20007.32	20007.32	20007.32	19989.01	20007.32	19989.01	20007.32422	20007.32422
Frecuencia	20007.32	20007.32	20007.32	20007.32	20007.32	20007.32	19982.91	19989.01	19989.01	19989.01	20007.32	19989.01	20007.32	19989.01367	19989.01367
Amplitud	1.3E-07	1.25E-07	1.12E-07	1.06E-07	1.06E-07	1.24E-07	1E-07	8.74E-08	1.09E-07	9.62E-08	1.08E-07	9.23E-08	9.38E-08	9.08266E-08	1.00965E-07
	4.7E-08	3.16E-08	3.67E-08	3.38E-08	3.03E-08	3.11E-08	2.47E-08	2.93E-08	2.26E-08	2.09E-08	2.3E-08	2.81E-08	2.06E-08	2.27334E-08	2.2568E-08
	2.64E-08	2.6E-08	2.7E-08	2.87E-08	2.29E-08	2.29E-08	1.88E-08	2.39E-08	1.94E-08	1.72E-08	2.15E-08	1.88E-08	1.95E-08	1.72571E-08	2.0008E-08
Potencia	7.16E-07	6.77E-07	6.45E-07	6.74E-07	6.73E-07	7.01E-07	6.19E-07	6.48E-07	6.36E-07	6.07E-07	6.4E-07	6.29E-07	6.57E-07	6.23898E-07	6.47238E-07
						(	Condició	n 1, Posic	ión 2						
							1	Señal							
Item	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Picos de	26013.18	26477.05	26489.26	26464.84	26440.43	25689.70	26477.05	24951.17	26544.19	26489.26	26422.12	25726.32	26477.05	26293.94531	26483.1543
Baja	24841.31	26452.64	24896.24	26519.78	26470.95	26501.46	26373.29	25823.97	26525.88	26556.40	26403.81	25616.46	26525.88	26342.77344	26416.01563
Frecuencia	26525.88	26190.19	26184.08	26501.46	26416.02	25701.90	26422.12	26123.05	24761.96	25958.25	25634.77	25585.94	26385.50	26263.42773	26434.32617
Amplitud	1.15E-08	1.04E-08	8.82E-09	1.77E-08	2.43E-08	9.2E-09	1.67E-08	8.87E-09	1.22E-08	9.58E-09	1.16E-08	1.11E-08	9.9E-09	1.10336E-08	1.33799E-08
	9.33E-09	8.61E-09	7.65E-09	1.51E-08	2.12E-08	8.79E-09	1.32E-08	7.96E-09	5.89E-09	8.4E-09	9.97E-09	9.36E-09	9.72E-09	9.67125E-09	9.08031E-09
	9.13E-09	7.58E-09	7.41E-09	1.32E-08	1.16E-08	7.36E-09	9.41E-09	7.81E-09	5.77E-09	6.27E-09	8.32E-09	8.84E-09	9.22E-09	8.53639E-09	7.84772E-09
Potencia	1.06E-06	9.89E-07	9.8E-07	9.74E-07	9.97E-07	1.05E-06	1.01E-06	9.61E-07	9.52E-07	9.38E-07	9.65E-07	9.37E-07	9.44E-07	9.28873E-07	9.70073E-07

Tabla 11. Datos tabulados filtro pasa alta para la condición 6 (64,9%) señales de presión

	Condición 6, Posición 1														
								Señal							
Item	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Picos de	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.89648	49993.89648
Baja	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01367	19989.01367
Frecuencia	39990.23	39990.23	39996.34	39990.23	39990.23	20007.32	39990.23	20007.32	39990.23	39996.34	39990.23	20007.32	39996.34	39990.23438	20007.32422
Amplitud	1.27E-07	1.27E-07	1.19E-07	1.05E-07	1.29E-07	1.18E-07	1.18E-07	1.29E-07	1.21E-07	1.05E-07	1.05E-07	1.18E-07	1.18E-07	1.05E-07	1.26E-07
	4.26E-08	4.47E-08	3.93E-08	3.29E-08	3.33E-08	3.42E-08	3.71E-08	3.10E-08	3.74E-08	3.57E-08	4.40E-08	3.96E-08	3.90E-08	3.80E-08	3.67E-08
	2.33E-08	2.42E-08	1.99E-08	2.19E-08	2.17E-08	2.11E-08	2.32E-08	2.30E-08	2.05E-08	1.85E-08	2.16E-08	2.37E-08	1.93E-08	2.01E-08	2.59E-08
Potencia	5.97E-07	6.21E-07	6.01E-07	6.03E-07	5.93E-07	6.03E-07	5.95E-07	6.15E-07	5.99E-07	6.04E-07	6.02E-07	5.97E-07	5.91E-07	5.92E-07	6.10E-07
						(	Condició	n 6, Posic	ión 2						
								Señal							
Item	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Picos de	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.90	49993.89648	49993.89648
Baja	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01	19989.01367	19989.01367
Frecuencia	39990.23	39990.23	39996.34	39990.23	39990.23	20007.32	39990.23	20007.32	39990.23	39996.34	39990.23	20007.32	39996.34	39990.23438	20007.32422
Amplitud	8.81E-09	1.04E-08	1.54E-08	1.69E-08	1.35E-08	1.74E-08	9.86E-09	9.07E-09	7.59E-09	1.15E-08	1.20E-08	7.26E-09	1.87E-08	1.09E-08	8.02E-09
	5.51E-09	6.97E-09	1.19E-08	1.31E-08	1.11E-08	1.38E-08	8.22E-09	7.56E-09	5.27E-09	5.11E-09	9.21E-09	7.25E-09	1.46E-08	7.71E-09	7.28E-09
	5.29E-09	6.36E-09	9.71E-09	1.21E-08	1.11E-08	1.20E-08	7.40E-09	6.76E-09	4.90E-09	4.98E-09	8.68E-09	5.14E-09	8.19E-09	6.78E-09	6.14E-09
Potencia	8.12E-07	7.59E-07	8.54E-07	8.93E-07	8.73E-07	9.18E-07	8.33E-07	7.50E-07	8.15E-07	8.62E-07	7.93E-07	7.71E-07	8.42E-07	8.16E-07	7.93E-07

Figura 43. Potencia vs centro de alta frecuencia de las señales de vibración por cada condición y posición.



### 8.2 Análisis Wavelet

## 8.2.1 Selección de la Wavelet Madre

Una de las decisiones más importante es decidir sobre la familia específica de wavelet madre a seleccionar para realizar el análisis wavelet, para lo cual no existen ninguna directriz cerrada y dado el tipo de señales a analizar no necesariamente se sabe la decisión a tomar. Más que un método de selección, el procedimiento usualmente consiste en evaluaciones comparativas del desempeño de las diferentes familias de wavelet, sin asumir que esta es una decisión óptima universal[4].

Por lo anterior, se analizó un número de diferentes posibilidades con la limitación que las wavelets deben ser reales y deben estar definidas en el dominio discreto[4]. Matlab® Toolbox tiene diferentes familias de wavelets que pueden ser consideradas dentro del análisis, algunas de ellas son: Daubechies (Db), Symlets (Sym), Coiflets (Coif) y Biortogonal (Bior). En la tabla 12 se muestran las diferentes familias que se usaron para análisis en el presente proyecto y el orden de la wavelet implementadas.

Familia de Wavelets	Orden de la Wavelet
Daubechies	1:43
Coiflets	1:5
Symlets	1:25
Biortogonal	1.1,1.3,1.5,2.2,2.4,2.6,2.8,3.3,3.5,3.7,3.9,4.4,5.5,6.8

|--|

**Fuente:** ARIZMENDI, C. Signal processing techniques for brain tumour diagnosis from magnetic resonance spectroscopy data, Tesis Doctoral Universidad Politécnica de Catalunya, 2011.

El análisis de wavelet discreta se aplica a las señales originales, realizando primeramente la descomposición usando el algoritmo generalizado de Wavelet de Paquete (WPT), para el cual tuvimos en cuenta que la descomposición óptima se encuentra teniendo en cuenta árboles con 2<sup>*D*</sup>, donde D es la intensidad de la entropía (*Depth* en inglés) y para seleccionar el mejor nivel de descomposición toma los árboles con mejor intensidad de la entropía (*Depth* en inglés). Esto quiere decir que si el máximo nivel de descomposición es 16, no todos los niveles son mejores para tener información característica de la señal, donde normalmente los primeros son los mejores. De esta manera, se podrían seleccionar solo 5 o 6 de los 16 disponibles, por regla heurística podríamos decir la mitad del posible, mejorando el tiempo computacional. Con respecto al criterio de Entropía se seleccionó *"logenergy"*, el cual no necesita parámetro y es comúnmente usado entre las diferentes opciones que tiene Maltab® (*shannon, threshold, norm, sure*).

Para cada wavelet madre, los valores absolutos de los coeficientes de descomposición se ordenan de manera descendente y los espectros de cada señal son reconstruidos por sumatoria de los coeficientes consecutivos [4]. Para la descomposición y reconstrucción se usaron las funciones de Matlab®: *wavedec, wmaxlev, waverec, wrcoef, wprcoef.* 

El promedio del error medio cuadrático (MSE) y la relación señal/ruido (SNR) pueden ser calculados para un conjunto completo de señales para cada orden de wavelet así:

$$MSE = \frac{1}{N} \sum_{i=1}^{N} [x(i) - \hat{x}(i)]^2$$
(8.1)

$$SNR(db) = 10\log\left[\frac{\sum_{i=1}^{N} [x(i)]^{2}}{\sum_{i=1}^{N} [x(i) - \hat{x}(i)]^{2}}\right]$$
(8.2)

donde  $\hat{x}$  es la señal reconstruida. Finalmente el índice Q1 para la orden (r) se computa de acuerdo a la estadística mencionada anteriormente así:

$$Q1(r) = \frac{SNR(r)}{MSE(r)}$$
(8.3)

Los valores máximos de Q1 indican las órdenes con el mejor error de reconstrucción. Este procedimiento es la fase inicial para la selección de la wavelet madre [4].

Con el propósito de determinar la wavelet definitiva, el valor promedio de varios valores estadísticos pueden ser combinados (SNR, Energía Preservada (EP), Porcentaje de Distorsión (PRD) y Relación de compresión (CR)) como se detallan a continuación [4]:

$$E_p = \frac{\sum_{i=1}^{N} [\hat{x}(i)]^2}{\sum_{i=1}^{N} [x(i)]^2} * 100\%$$
(8.4)

$$PRD = \sqrt{\frac{\sum_{i=1}^{N} [x(i) - \hat{x}(i)]^2}{\sum_{i=1}^{N} [x(i)]^2}} * 100\%$$
(8.5)

$$CR = \frac{L_o}{L_c} \tag{8.6}$$

donde  $L_o$  es la cardinalidad de los coeficientes de descomposición de la señal original y  $L_c$  es la cardinalidad de los coeficientes de descomposición diferentes de cero.

Estas medidas de desempeño nos sirven para determinar la mejor wavelet para la reconstrucción de la señal. Entonces un criterio objetivo para seleccionar la función wavelet óptima es a través del Q2 como se muestra:

$$Q2 = \left[\frac{SNR + E_p + CR}{MSE + PRD}\right]$$
(8.7)

El máximo valor que se obtuvo para el índice Q2 para las señales de vibración fue con *sym21* para los valores promedio y *sym11* para los valores teniendo en cuenta la desviación estándar. *En nuestro caso, seleccionamos sym21*. En la tabla 13 y 14 se pueden observar algunos valores obtenidos teniendo en cuenta los valores promedio y la desviación estándar para las señales de vibración.

En el caso de las señales de presión el resultado se observa en las tablas 15 y 16.

	Max									
Wavelet	Nivel	Entropía	Depth	MSE	SNR	Q1	PRD	CR	EP	Q2
'db35'	10	258248.09	5	0.28	15.71	63.26	17.19	70.72	96.79	11.68
'coif5'	11	242462.96	5	0.28	15.74	63.83	17.14	69.40	96.81	11.64
'sym19'	11	242671.88	5	0.28	15.76	64.06	17.12	70.53	96.82	11.75
'sym21'	11	242568.53	5	0.28	15.78	64.76	17.05	70.47	96.85	11.7667053
'sym25'	10	242743.69	5	0.28	15.76	64.20	17.10	70.95	96.83	11.7656707
'bior6.8'	12	241421.40	6	0.30	15.41	57.82	17.77	69.89	96.99	11.17

Tabla 13. Índices de desempeño de diferentes wavelets teniendo en cuenta sus valores promedio (señal de vibración).

Tabla 14. Índices de desempeño de diferentes wavelets teniendo en cuenta la desviación estándar (señal de vibración).

Wavelet	Entropía	Depth	MSE	SNR	Q1	PRD	CR	EP	Q2
'coif5'	-106970.25	0	0.11	2.83	21.39	17.14	5.20	1.70	4.48
'sym11'	-107003.49	1	0.11	2.89	19.87	17.31	5.72	1.72	4.55
'sym12'	-107009.70	1	0.11	2.88	19.91	17.31	5.74	1.73	4.54
'bior6.8'	-105928.68	1	0.12	2.78	19.12	17.77	5.52	1.60	4.18

Tabla 15	. Índices	de de	sempeño	de	diferentes	wavelets	teniendo	en	cuenta
sus valor	es prom	edio (s	señal de p	resi	ón)				

Wavelet	Maxlev	Entropía	Depth	MSE	SNR	Q1	PRD	CR	EP	Q2
' db2'	14	537621.586	7	0.00	40.10	571730187.35	1.02	48.98	99.99	196.81
'coif1'	13	535626.648	6	0.00	40.09	570255188.82	1.02	48.88	99.99	196.49
' sym3'	13	535657.528	6	0.00	39.96	551998187.45	1.04	50.53	99.99	195.16
'bior1.1'	15	520286.37	3	0.00	40.58	645577392.70	0.96	38.12	99.99	196.00

Tabla 16. Índices de desempeño de diferentes wavelets teniendo en cuenta ladesviación estándar (señal de presión)

Wavelet	Entropía	Depth	MSE	SNR	Q1	PRD	CR	EP	Q2
' db3'	-539027.344	0	0.00	2.20	69133203.58	1.04	3.73	0.01	47.80
'db31'	-539027.344	0	0.00	2.20	68703532.57	1.03	3.59	0.01	47.71
'db34'	-539027.344	0	0.00	2.20	68373996.09	1.03	3.55	0.01	47.70
'db36'	-539027.344	0	0.00	2.20	68332645.89	1.03	3.60	0.01	47.66
' sym3'	-539027.344	0	0.00	2.20	69133203.58	1.04	3.73	0.01	47.80

# 8.2.2 Extracción de Características

Una vez se realiza la descomposición y reconstrucción de acuerdo al algoritmo WPT cuyo árbol puede verse en la figura 13, se procede a determinar los valores promedio de los coeficientes de aproximación (**Ca**), que corresponden a las bandas de baja frecuencia y los de detalle (**Cd**) que corresponden a las bandas de alta frecuencia. Las características de la señal que se extrajeron son: *Media, Valor RMS, Desviación Estándar, Varianza, Skewness, Kurtosis y Rango Intercuartil (IRS).* Con estos valores se consigue un vector aumentado de características, el cual puede representarse así:

# [avgA, avgD, rmsA, rmsD, stdA, stdD, varA, varD, skeA, skeD, kurA, kurD, iqrA, iqrD]

Para las señales de vibración se tomaron vectores de 12x14 y para las señales de presión de 15x14.

# 8.2.3 Selección de Características

Es un proceso que permite identificar las características más relevantes que deben ser extraídas para lograr que el clasificador tenga mejor desempeño. Así mismo, busca evitar sobredimensionar el sistema permitiendo encontrar los datos más relevantes para este, y filtrar aquellos que no aportan o alteran en los resultados de la clasificación. La selección de características no solo implica la reducción de carnalidad, es decir, la imposición de un límite arbitrario o predefinido en el número de atributos que se pueden considerar al crear un modelo, sino también la elección de atributos, lo que significa que el modelado debe seleccionar o descartar activamente los atributos en función de su utilidad para el análisis [38].

Aunque existen varios métodos como Bidirectional Search, Algoritmos Geneticos, Forward Selection y Backward selection, se eligió una técnica denominada "Independent Features", código desarrollado por Will Dwinnell (<u>predictr@bellatlantic.net</u>) por su facilidad de implementación y sencillez, cuyo método consiste en calcular el nivel de significación 'Sig' de las variables reales ( en columnas) de la matriz X, basado en su capacidad para distinguir 2 categorías de la columna del vector Y (típicamente, las variables se mantienen cuando la significación es >=2.0). Para una variable de salida continua, se sugiere que los valores se dividan en el 50% inferior y superior. Utilizando Weiss/Indurkhya 'Independent Features' (método de pruebas de significancia), tenga en cuenta que esto no pretende ser la selección final de las variables, sino sólo un medio de eliminar las características que no son de interés.

El código implementado para nuestro caso se detalla a continuación:

```
function Sig = IndFeat(X,Y)
% find the two (more to come) class "names"
UniqueClass = unique(Y);
% find indexes for both classes
ClassA = (Y == UniqueClass(1));
ClassB = (Y == UniqueClass(2));
nA = sum(double(ClassA));
nB = sum(double(ClassB));
% calculate significances
Sig = ...
    abs(mean(X(ClassA,:)) - mean(X(ClassB,:))) ./ ...
    sqrt(var(X(ClassA,:)) ./ nA + var(X(ClassB,:)) ./ nB);
```

En las figuras 44 y 45 puede verse la gráfica de las características de mayor significancia aplicando el algoritmo Independent features para las señales de vibración y de presión respectivamente. En el caso de las señales de vibración se obtienen 18 features disponibles y para las de presión 19 disponibles, seguramente debido a que éstas tienen mayor cantidad de señales.

En las figuras 46 y 47 se pueden ver las 3 características de mayor significancia en plano 3D para las señales de vibración y presión respectivamente.

Por motivos de convergencia del clasificador y tiempo computacional se eligen 12 características de las disponibles.

Figura 44. Selección de características (señal de vibración)



Figura 45. Selección de características (señal de presión)



Figura 46. Características de mayor significancia en 3D (señal de vibración)



Figura 47. Características de mayor significancia en 3D (señal de presión)



### 8.3 Diseño de la Arquitectura de Red Neuronal

Las redes neuronales son una técnica muy sofisticada capaz de modelar funciones complejas de diversa índole. Uno de los principales problemas al usar las redes neuronales es la selección correcta de la arquitectura y de los parámetros de la red. Para lograr superar el problema es necesario contar con una base de datos lo suficientemente amplia para el entrenamiento y para la validación de la red [3].

Los algoritmos de entrenamiento de las redes neuronales buscan encontrar la mejor solución al problema, razón por la cual en la implementación de ellos se debe prevenir el llegar a caer en un mínimo local, el cual el error queda oscilando manteniendo el entrenamiento sin satisfacer el porcentaje de error que se desea, generando un mayor gasto computacional sin mejorar la respuesta que presenta el sistema, razón por la cual se debe seleccionar los criterios de parada adecuados, estos los podemos encontrar en la *Neural Network Toolbox* de Matlab® para determinar cuáles son posibles a implementar [33].

El número de capas y el número de neuronas por capa son decisiones importantes en una red unidireccional, estas decisiones son realizadas usando la experiencia. No existe una regla fija que nos indique sus valores sino que se establecen por la intuición del diseñador de la red, sin embargo, existe un conjunto de reglas que se pueden usar en la solución de problemas [3]:

- Regla 1: Cuando más aumenta la complejidad en las relaciones entre los datos de entrada y los datos de salida, entonces el número de neuronas en las capas ocultas también debe aumentarse.
- Regla 2: Si el proceso que se está modelando es separable en dos etapas, entonces nuevas capas pueden ser adicionadas. Si el proceso no es separable en varias etapas, entonces las capas adicionales simplemente permiten memorizar y se perderá generalización.
- Regla 3: El número de patrones de entrenamiento disponibles establecen una cota superior en el número de neuronas en la capa oculta.

Como dato de entrada a la red se define el número de features que desea seleccionar de un número posible que está calculado con el código de Independent Features, en el cual se definió como umbral s>=2. En la figura 44 se muestra el proceso de selección de características de la señal de vibración y en la figura 45 se muestra la gráfica 3D de las características de mayor significancia en este caso se mostrarían 3, varianza de detalle, varianza de aproximación y kurtosis. Posteriormente los datos fueron normalizados y se selecciona la tipología de red que se quiere entrenar y probar, en este caso, se implementaron: Una red Adaline (función de transferencia: purelin), una Red Multilayer Perceptron (función de transferencia: softmax) y 2 redes adaptativas no lineales (función de transferencia: tansig y logsig). Se usó el comando 'kfold' el cual genera una partición estratificada 3-fold para el set de entrenamiento, garantizando que el 70% de los datos serán usados para entrenamiento y el 30% para test. La arquitectura de red diseñada para la tipología Adaline y las redes adaptativas no lineales constan de una capa de entrada, una capa oculta y una capa de salida con 6 neuronas. La regla de entrenamiento utilizada es Levenverg-Marquart y de desempeño Mean Squared Error. En la figura 48 se muestra la arquitectura de red implementada para la tipología Adaline y las redes no lineales (NL1 y NL2). Para la tipología MLP se trabajaron dos arquitecturas: una con una capa oculta y otra con dos capas ocultas. La regla de entrenamiento y desempeño fueron las mismas que en el caso de la Adaline y las demás. En las figuras 49 y 50 se muestran las arquitecturas MLP implementadas. Para el entrenamiento de las redes se tomaron 8 sets de los 12 disponibles. En las figuras 51-55 puede verse los resultados del entrenamiento para cada una de las redes implementadas tomando las señales de vibración. En las figuras 56-60 pueden verse los resultados del entrenamiento para las señales de presión.

Figura 48. Arquitectura implementada para las tipologías Adaline y redes no lineales.



Figura 49. Arquitectura implementada para la tipología MLP1 (1 capa oculta).



Figura 50. Arquitectura implementada para la tipología MLP2 (2 capas ocultas).



# Figura 51. Desempeño de la red Adaline para las señales de vibración(Training)



	Train Confusion Matrix										
1	<b>2</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
	4.2%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%				
2	<b>6</b>	<b>8</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	57.1%				
	12.5%	16.7%	0.0%	0.0%	0.0%	0.0%	42.9%				
3	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
SS	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%				
Itput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	100%				
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%				
<b>o</b> ี	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	100%				
5	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%				
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	100%				
	0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%				
	25.0%	100%	100%	100%	100%	100%	87.5%				
	75.0%	0.0%	0.0%	0.0%	0.0%	0.0%	12.5%				
	1	2	3 Та	4 Irget Cla	5 SS	6					





Figura 52. Desempeño de la red MLP1 para las señales de vibración(Training)

	Train Confusion Matrix										
1	<b>8</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100 <i>%</i>				
	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%				
2	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100 <i>%</i>				
	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%				
3	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	<b>0</b>	100 <i>%</i>				
SS	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%				
Itput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	100%				
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%				
o	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	100%				
₅	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%				
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	100%				
	0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%				
	100%	100%	100%	100%	100%	100%	100%				
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%				
	1	2	з Та	4 Irget Cla	5 SS	6					
				_							





Figura 53. Desempeño de la red MLP2 para las señales de vibración(Training)





Figura 54. Desempeño de la red NL1 para las señales de vibración (Training)



Train Confusion Matrix										
<b>8</b>	<b>8</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	50.0%				
16.7%	16.7%	0.0%	0.0%	0.0%	0.0%	50.0%				
<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	NaN%				
0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	NaN%				
<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%				
<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	100%				
0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%				
<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	100%				
0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%				
<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	100%				
0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%				
100%	0.0%	100%	100%	100%	100%	83.3%				
0.0%	100%	0.0%	0.0%	0.0%	0.0%	16.7%				
1	2	3 <b>T</b> a	4 arget Cla	5 SS	6					
	8 16.7% 0 0.0% 0 0.0% 0 0.0% 0 0.0% 100% 0.0%	8         8           16.7%         0           0         0.0%           0.0%         0.0%           0.0%         0.0%           0.0%         0.0%           0.0%         0.0%           100%         0.0%           100%         0.0%           1         2	Nome       Nom       Nome       Nome	Train Confusion         8       8       0       <	Train Confusion Matrix         8       8       0	Train Confusion Matrix         8       8       0				





Figura 55. Desempeño de la red NL2 para las señales de vibración (Training)

	Train Confusion Matrix										
1	<b>8</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	88.9%				
	16.7%	2.1%	0.0%	0.0%	0.0%	0.0%	11.1%				
2	<b>0</b>	<b>7</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
	0.0%	14.6%	0.0%	0.0%	0.0%	0.0%	0.0%				
3	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
SS	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%				
itput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	100%				
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%				
õ	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	100%				
₅	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%				
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	100%				
	0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%				
	100%	87.5%	100%	100%	100%	100%	97.9%				
	0.0%	12.5%	0.0%	0.0%	0.0%	0.0%	2.1%				
	1	2	3 Ta	4 Irget Cla	5 SS	6					



Figura 56. Desempeño de la red Adaline para las señales de presión (Training)



	Train Confusion Matrix									
1	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100 <i>%</i>			
	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%			
2	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	NaN%			
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	NaN%			
3	<b>0</b>	<b>10</b>	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	50.0%			
SS	0.0%	16.7%	16.7%	0.0%	0.0%	0.0%	50.0%			
itput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>	<b>0</b>	<b>0</b>	100 <i>%</i>			
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%			
õ	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>	<b>0</b>	100%			
₅	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%			
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>	100%			
	0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%			
	100%	0.0%	100%	100%	100%	100%	83.3%			
	0.0%	100%	0.0%	0.0%	0.0%	0.0%	16.7%			
	1	2	3 Ta	4 arget Clas	5 55	6				





Figura 57. Desempeño de la red MLP1 para las señales de presión (Training)

	Train Confusion Matrix										
1	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%				
2	<b>0</b>	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%				
3	<b>0</b>	<b>0</b>	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
SSE	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%				
tput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>	<b>0</b>	<b>0</b>	100%				
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%				
<b>no</b> 5	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>	<b>0</b>	100%				
	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%				
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>	100%				
	0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%				
	100%	100%	100%	100%	100%	100%	100%				
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%				
	1	2	3 <b>Ta</b>	4 rget Cla	5 I <b>SS</b>	6					





Figura 58. Desempeño de la red MLP2 para las señales de presión (Training)

	1	<b>10</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	100% 0.0%
	2	<b>0</b> 0.0%	<b>10</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	100% 0.0%
SSE	3	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>10</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	100% 0.0%
tput Cla	4	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>10</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	100% 0.0%
no	5	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>10</b> 16.7%	<b>0</b> 0.0%	100% 0.0%
	6	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>10</b> 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100 <i>%</i> 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
		1	2	3	4	5	6	
				Та	rget Cla	ISS		



### Train Confusion Matrix





	Train Confusion Matrix											
1	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%					
	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%					
2	<b>0</b>	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%					
	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%					
3	<b>0</b>	<b>0</b>	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%					
SSB	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%					
tput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>	<b>0</b>	<b>0</b>	100%					
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%					
<b>no</b> 5	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>9</b>	<b>2</b>	81.8%					
	0.0%	0.0%	0.0%	0.0%	15.0%	3.3%	18.2%					
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>8</b>	88.9%					
	0.0%	0.0%	0.0%	0.0%	1.7%	13.3%	11.1%					
	100%	100%	100%	100%	90.0%	80.0%	95.0%					
	0.0%	0.0%	0.0%	0.0%	10.0%	20.0%	5.0%					
	1	2	3 <b>Ta</b> i	4 rget Cla	5 ISS	6						



Figura 60. Desempeño de la red NL2 para las señales de presión (Training)



					masio	maanz	•	
	1	<b>10</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	100% 0.0%
	2	<b>0</b> 0.0%	<b>10</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	100% 0.0%
ass	3	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>10</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	100% 0.0%
tput Cla	4	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>10</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	100% 0.0%
ō	5	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>10</b> 16.7%	<b>0</b> 0.0%	100% 0.0%
	6	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>10</b> 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
		1	2	3 <b>Ta</b>	4 rget Cla	5 I <b>SS</b>	6	



	Train	Confusion	Matrix
--	-------	-----------	--------

De lo anterior se puede observar que la red que mejor identifico las condiciones en el caso de las señales de vibración fue la MLP1, la cual tuvo un 100% en la clasificación. Por su parte la que presentó el peor desempeño fue la red la NL1 con un 83.3% de clasificación.

Respecto a las señales de presión, las redes que mejor identificaron las condiciones fueron las NL2, MLP1 y MLP2 logrando un 100% en la clasificación. La red que presentó el peor desempeño fue la tipo Adaline.

### 9. RESULTADOS Y ANÁLISIS

Los datos de prueba están compuestos por el 30% de las señales tomadas en la extracción de características de acuerdo a la distribución k-fold. Estos nunca se usaron para entrenamiento, por lo que se desea observar que tan bien identifica la red neuronal cada condición. A continuación, en las figuras 61-66 se muestra el detalle de los resultados obtenidos en el test para cada tipo de red implementada para las señales de vibración. En ellas puede observarse que la que mejor se desempeña en cuanto a las salidas es la red MLP1, ya que las demás presentan problemas en la identificación de la condición 1 y 2. En las figuras 67-72 se muestra el detalle de los resultados obtenidos en el test para los tipos de redes implementados para la señal de presión. Como puede verse, la red MLP2 es la que alcanza mejor porcentaje de clasificación y obtiene el menor error medio cuadrático. En las tablas 16 y 17 puede verse un resumen de los resultados obtenidos para cada red implementada y para las señales de vibración y presión respectivamente.



Figura 61. Salida de la red Adaline para las señales de vibración (Test)



Figura 62. Salida de la red MLP1 para las señales de vibración (Test)



Figura 63. Salida de la red MLP2 para las señales de vibración(Test)



Figura 64. Salida de la red NL1 para las señales de vibración(Test)



Figura 65. Salida de la red NL2 para las señales de vibración (Test)



# Figura 66. Matriz de confusión de las redes implementadas para las señales de vibración (Test)



#### MLP2

Test Confusion Matrix											
1	<b>3</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
	12.5%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%				
2	1	<b>4</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	80.0%				
	4.2%	16.7%	0.0%	0.0%	0.0%	0.0%	20.0%				
3	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
55	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%				
tput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	<b>0</b>	100%				
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%				
ð	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	100%				
₅	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%				
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	100%				
	0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%				
	75.0%	100%	100%	100%	100%	100%	95.8%				
	25.0%	0.0%	0.0%	0.0%	0.0%	0.0%	4.2%				
	1	2	3 Ta	4 Irget Cla	5	6					

NL1

	Test Confusion Matrix										
1	<b>4</b>	<b>4</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	50.0%				
	16.7%	16.7%	0.0%	0.0%	0.0%	0.0%	50.0%				
2	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	NaN%				
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	NaN%				
3	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%				
SS	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%				
tput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	<b>0</b>	100%				
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%				
o	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	100%				
₅	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%				
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	100%				
	0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%				
	100%	0.0%	<b>100%</b>	100 <i>%</i>	100%	100 <i>%</i>	83.3%				
	0.0%	100%	0.0%	0.0%	0.0%	0.0%	16.7%				
	1	2	3	4	5	6					
			Та	arget Cla	SS						

NL2 Test Confusion Matrix 100% 0.0% **3** 12.5% **0** 0.0% **0** 0.0% **0** 0.0% **0** 0.0% 1 0.0% **4** 16.7% **0** 0.0% **0** 0.0% **0** 0.0% **0** 0.0% 80.0% 20.0% 1 4.2% 2 **0** 0.0% **0** 0.0% **4** 16.7% **0** 0.0% **0** 0.0% **0** 0.0% 3 Output Class **0** 0.0% 100% 0.0% **0** 0.0% **0** 0.0% **3** 12.5% **0** 0.0% **0** 0.0% 80.0% 20.0% **0** 0.0% **0** 0.0% **0** 0.0% 1 4.2% **4** 16.7% **0** 0.0% 5 **0** 0.0% **0** 0.0% **0** 0.0% **0** 0.0% **4** 16.7% 100% 0.0% **0** 0.0% 6 100% 0.0% 100% 0.0% 91.7% 8.3% 75.0% 25.0% 1 2 6 3 5 Target Class



Figura 67. Salida de la red Adaline para las señales de presión (Test)



Figura 68. Salida de la red MLP1 para las señales de presión (Test)



Figura 69. Salida de la red MLP2 para las señales de presión (Test)


Figura 70. Salida de la red NL1 para las señales de presión (Test)



Figura 71. Salida de la red NL2 para las señales de presión (Test)



# Figura 72. Matriz de confusión de las redes implementadas para las señales de presión (Test)

М	L	Р	1

Test Confusion Matrix							
1	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%
	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
2	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%
	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%
sse 3	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%
	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%
tput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	100%
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%
<b>0</b> 5	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	100%
	0.0%	0.0%	0.0%	0.0%	13.3%	0.0%	0.0%
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	1	<b>5</b>	83.3%
	0.0%	0.0%	0.0%	0.0%	3.3%	16.7%	16.7%
	100%	100%	100 <i>%</i>	100%	80.0%	100%	96.7%
	0.0%	0.0%	0.0%	0.0%	20.0%	0.0%	3.3%
	1	2	3	4	5	6	
	Target Class						

MLP2

Test Confusion Matrix							
1	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%
	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
2	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%
	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%
338	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%
	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%
tput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	100%
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%
no 5	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	100%
	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	100%
	0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%
	100%	100%	100%	100%	100%	100%	100%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
	1	2	3 Та	4 root Cla	5	6	
larget class							



Test Confusion Matrix							
1	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%
	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
2	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%
	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%
sse 3	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	100%
	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%	0.0%
tput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	100%
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%
ð₅	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	1	83.3%
	0.0%	0.0%	0.0%	0.0%	16.7%	3.3%	16.7%
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	100%
	0.0%	0.0%	0.0%	0.0%	0.0%	13.3%	0.0%
	100%	100 <i>%</i>	100 <i>%</i>	100 <i>%</i>	100%	80.0%	96.7%
	0.0%	0.0%	0.0%	0.0%	0.0%	20.0%	3.3%
1 2 3 4 5 6 Target Class							

N	L	2
LИ		~

	Test Confusion Matrix						
1	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	100 <i>%</i>
	16.7%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
2 ss <sup>3</sup>	<b>0</b> 0.0%	<b>5</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	100 <i>%</i> 0.0%
	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>5</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	100 <i>%</i> 0.0%
tput Cla	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	100 <i>%</i>
	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%	0.0%
<b>no</b> 5	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	100 <i>%</i>
	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%	0.0%
6	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	100 <i>%</i>
	0.0%	0.0%	0.0%	0.0%	0.0%	16.7%	0.0%
	100%	100 <i>%</i>	100 <i>%</i>	100%	100%	100%	100%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
	1	2	3	4	5	6	
Target Class							

Tabla 17. Resumen resultados de cada etapa y por cada red para las señalesde vibración

Red Neuronal	Mean squared error performance MSE	% de Clasificación Train	% de Clasificación Test
Adaline	0,03024	87,5%	83,3%
NL1	0,030568	83,3%	83,3%
NL2	0,027626	97,9%	91,7%
MLP1	0,0075705	100%	95,8%
MLP2	0,020601	97,9%	95,8%

Tabla 18. Resumen resultados de cada etapa y por cada red para las señalesde presión

Red Neuronal	Mean squared error performance MSE	% de Clasificación Train	% de Clasificación Test
Adaline	0,028225	83,3%	83,3%
NL1	0,052012	95%	96,7%
NL2	0,000020206	100%	100%
MLP1	0,010574	100%	96,7%
MLP2	0,0000218	100%	100%

#### **10. CONCLUSIONES**

- Se desarrolló un algoritmo para la detección, clasificación y análisis de fallas off-line de una bomba hidráulica de pistones axiales correspondientes a diferentes condiciones de desgaste de plato de válvula usando las señales de vibración y presión adquiridas alcanzando una precisión en la etapa de entrenamiento del 100% y en la etapa de prueba del 95.8% tomando las señales de vibración y de 100% en ambas etapas tomando las señales de presión.
- Para la selección del número de muestras se debe revisar cual es el criterio más adecuado para cada caso de estudio, siempre teniendo en cuenta la eficiencia en cuanto a tiempo y costo computacional se refiere, la resolución en frecuencia deseada y su influencia en otras etapas del análisis.
- El análisis espectral permite observar diferencias en el dominio de la frecuencia permitiendo comparar e identificar las características de cada condición solo con simple observación. Adicionalmente la densidad espectral de potencia (PSD) permite observar las zonas de alta potencia y las diferencias entre las posiciones consideradas, destacando que las posiciones 1 y 4 en el caso de las señales de vibración es donde se evidencia el mayor cambio.
- La implementación de filtros pasa baja y pasa alta son de vital importancia para verificar las frecuencias, amplitudes y potencia de los picos de mayor relevancia tanto para las señales de vibración y presión. Al pasar el filtro pasa alta a las señales de presión pueden verse picos en frecuencias del orden de 20Hz, por lo que se sospecha pueda ser ruido, sin embargo al no tener las curvas de frecuencia del sensor de presión no es posible verificar si efectivamente lo es.
- Dado que se analizaron las señales de vibración y presión por separado es difícil observar cuál de ellas tiene más influencia sobre la identificación de la falla. Teniendo en cuenta la información espectral las que proveen mayor

información son las señales de vibración, sin embargo, al obtener altos porcentajes de clasificación para las señales de presión, se puede afirmar que dichas señales también pueden ser utilizadas con éxito, a pesar de poseer baja potencia y amplitudes.

- El criterio para seleccionar la wavelet madre debe ser establecido como paso inicial para el análisis wavelet, de esto depende que la extracción de características sea óptima.
- A medida que se aumenta el orden de la wavelet se puede requerir mayor tiempo computacional.
- Es importante tener en cuenta que al tener el vector aumentado de características se debe asegurar que todas las condiciones tengan el mismo número de señales.
- El método de selección de características es de gran ayuda en el ahorro de costo computacional y además mejora el desempeño del clasificador. Así mismo al aumentar el número de características se puede identificar mejor la falla.
- Las características más significativas son la varianza de aproximación, la varianza de detalle y la kurtosis, en el caso de la señales de vibración. Para las señales de presión, la kurtosis de aproximación, el skewness de aproximación y de detalle.
- La red ADALINE es la que presenta resultados más pobres tanto en la etapa de entrenamiento y prueba tanto para las señales de vibración como para las de presión.
- En la etapa de prueba para las señales de vibración se pudo constatar que las redes MLP1 y MLP2 son las que mejor se desempeñan con un porcentaje de clasificación de 95,8%.
- En la etapa de prueba para las señales de presión se pudo constatar que las redes NL2 y MLP2 son las que mejor se desempeñan con un porcentaje de clasificación de 100%.

### 11. APORTES

- Metodología de diagnóstico validada experimentalmente para la detección, y clasificación de fallas en bombas hidráulicas de pistones axiales.
- Ponencia titulada: "Diagnóstico de Fallas en Bombas Hidráulicas de Pistones Axiales aplicando Redes Neuronales Artificiales "ANN's". En: Proceedings of International Congress of Mechanical Engineering and Agricultural Science, Oct. 2015, Bucaramanga, STD, COL.
- Capítulo de libro tipo B según clasificación Colciencias, titulado" A Survey of Approaches for Fault Diagnosis in Axial Piston Pumps", En: ASME International Mechanical Engineering Congress and Exposition IMECE 2016, Nov. 2016, Phoenix, AZ, USA.
- Un artículo en revista indexada tipo A según clasificación Colciencias, el cual se encuentra en proceso de elaboración y revisión. En: International Journal on Interactive Design and Manufacturing (IJIDeM).

# **12. RECOMENDACIONES Y TRABAJOS FUTUROS**

- Probar otras metodologías como coeficientes de Fourier y redes SOM.
- Probar la metodología propuesta en este proyecto en el diagnóstico de otras fallas en bombas hidráulicas de pistones axiales.
- Probar el algoritmo teniendo en cuenta sets desconocidos.

# 13. BIBLIOGRAFÍA

[1] ACOSTA M., and ZULUAGA, C. Tutorial sobre Redes Neuronales Aplicadas en Ingeniería Electrica y su Implementación en un Sitio Web, Universidad Tecnológica de Pereira, 2000.

[2] ANCIC,I.,SESTA,A.,and VIRAG, Z. Determination of Actual Discharge of High-Pressure Low-Discharge Axial Piston Pumps, Transactions of FAMENA, Vol.38, No. 2, p.1-10.

[3] ARANGO, G. Clasificación de fallas en motores eléctricos utilizando señales de vibración, Tesis Maestría Universidad Tecnológica de Pereira, 2007

[4] ARIZMENDI, C. Signal processing techniques for brain tumour diagnosis from magnetic resonance spectroscopy data, Tesis Doctoral Universidad Politécnica de Catalunya, 2011

[5] AYMAN, A., An artificial neural network flow control of variable displacement piston pump with pressure compensation. En:International Journal of Control, Automation and Systems, Ene. 2015, vol.4, No.1, p. 1-7.

[6] BLÁZQUEZ, L., and DE MIGUEL, L.J. Diagnóstico automático de fallos para sistemas dinámicos no lineales. Reporte de investigación, Dpto. Ingeniería de Sistemas y Automática, Universidad de Valladolid, España,1999, p.1-30.

[7] BAYER, C., and Enge-Rosenblatt, O. Modeling of hydraulic axial piston pumps including specific signs of wear and tear. En: Proceedings 8<sup>th</sup> International Modelica Conference, Jun.2011, No. 63, p.461-466.

[8] BERNAL, J., GÓMEZ, P., and BOBADILLA, J. Una visión práctica en el uso de la transformada de Fourier como herramienta para el análisis espectral de la voz. En: Estudios de Fonética Experimental, 1999, Vol.10, p.75-105.

[9] BERNAL, J., PRIETO, A., LLANES, O., and GARCÍA, E. Estudio comparativo de clasificadores empleados en el diagnóstico de fallos de sistemas industriales. En: Ing. Mecánica, 2011, Vol.142, No. 2, p.87-98.

[10] BO,C.,GUOPING, Y.,DONGSHI, X., and JUNHAO, G. Modeling and simulation of axial piston hydraulic pump. En: Measuring Technology and Mechatronics Automation (ICMTMA), IEEE transactions on, Ene. 2011, Vol.2, p.609-612.

[11] BOLAÑO, Y., and NIÑO, J., Rediseño y construcción de un banco de pruebas para diagnóstico de fallas en una hidrotransmisión bomba variable-motor fijo, Tesis Universidad Industrial de Santander, 2016

[12] BORRÁS, C., and STALFORD, H. Pattern recognition of backlash in hydraulic actuators using neural network. En: The American Control Conference, 2002, Vol.1, fasc. WA12-5, p.400-405.

[13] BORRAS, C.Pattern recognition in hydraulic backlash using neural network. Master Thesis, University of Oklahoma, 2001.

[14] CAMACHO, O., PADILLA, D., and GOUVEIA, J. Diagnóstico de fallas utilizando técnicas estadísticas multivariables. En: Revista Técnica de la Facultad de Ingeniería Universidad del Zulia, 2007, Vol.30, No.3, p.253-262.

[15] CANBULUT, F.,and SINANOGLU, C. An investigation on the performance of hydrostatic pumps using artificial neural network. En: JSME International Journal Series C Mechanical Systems, Machine Elements and Manufacturing, 2004, Vol.47, No.3, p.864-872.

[16] CASTILLO, S., and SERRANO, J. Metodología de mantenimiento predictivo para diagnóstico de fallas en bombas hidráulicas de pistones axiales asociadas con desgaste de los platos rodantes de presión, Tesis Universidad Industrial de Santander, 2016.

[17] CHANG, Y., LIU, M., CHU, H., KANG, Y., and CHANG, W. Model –following controller based on neural network for variable displacement pump. En: JSME International Journal Series C Mechanical Systems, 2003, Vol.46, No.1, p.176-187.

[18] DU, J. and WANG, S. Hiberarchy clustering fault diagnosis of hydraulic pump. En: Prognostics and Health Management Conference, 2010, No.10, p.1-7.

[19] DU, J., WANG, S., and ZHANG, H. Layered clustering multi-fault diagnosis for hydraulic piston pump. En: Mechanical Systems and Signal Processing, 2013, Vol.36, No. 2, p. 487-504.

[20] GAO, Y., ZHANG, Q., and KONG, X. Wavelet-based pressure analysis for hydraulic pump health diagnosis, ASAE transactions on, 2003, Vol. 46, No.4, p.969.

[21]GUILLÉN, M., PAREDES, J., and CAMACHO O. Detección y diagnóstico de fallas utilizando la transformada wavelet. En: Revista Ciencia e Ingeniería, 2004, Vol.25, No.1, p. 35-41.

[22] HAGAN, M., DEMUTH, H., BEALE, M., and DE JESÚS, O. Neural network design 2a Edition. Universidad de Oklahoma, 2014

[23] HE,Z.,HU, W.,WANG, S., and ZHAO, S. Prognostic analysis based on updated grey model for axial piston pump.En:5<sup>th</sup> IEEE Conference on Industrial Electronics and Applications ICIEA, IEEE transactions on, 2010, p. 571-575.

[24] HOU, W., LU, C., LIU, H., and LU, C. Fault Diagnosis based on wavelet package for hydraulic pump. En: Reliability, Maintainability and Safety ICRMS, IEEE transactions on, 2009, p. 831-835.

[25] HUA-PING, G., and CHENG, T. Rearch and practice in the parameters measurement method used in faults diagnostic of hydraulic system. En: Fluid Power and Mechatronics (FPM), IEEE transactions on, 2011, p. 779-782.

[26] JIKUN, B., CHEN, L., ZHIPENG, W., and ZILI,W. An approach to performance assessment and fault diagnosis for hydraulic pumps. En: International LTD. Journal of Vibroengineering, May.2014, Vol. 16, No. 3, p. 1444-1454.

[27] KARKOUB, M., GAD, O., AND RABIE, M. Predicting axial piston pump performance using neural networks. En: Mechanism and Machine Theory, 1999, Vol. 34, No.8, p.1211-1226.

[28] LI, Z. Condition monitoring of axial piston pump. Thesis, University of Saskatchewan, 2005.

[29]LINLIN, D.,SIYUAN,L., and WANLU, J. Study on application of principal component analysis to fault detection in hydraulic pump. En: International Conference on Fluid Power and Mechatronics, 2011, No. 4, p.173-178.

[30] LOUTAS, T., and, KOSTOPOULOS, V. Utilising the wavelet transform in condition-based maintenance: a review with applications. En: Advances in Wavelet Theory and Their Applications in Engineering, Physics and Technology, In Tech, 2012.

[31] LURETTE, C., and LECOEUCHE, S. Unsupervised and auto-adaptive neural architecture for on-line monitoring application to a hydraulic process. En: Eng. Appl. Artif. Intell., 2003, Vol.16, No. 5-6, p.441-451.

[32] MARADEY, J.,BORRÁS, C., and ROA, S.,A survey of approaches for fault diagnosis in axial piston pump. En:International Mechanical Engineering Congress and Exposition IMECE, ASME transactions on, Nov.2016, Vol.4A, p.5A052-1 - 5A052-13.

[33] ORTIZ, J. Análisis de la interacción entre el patrón respiratorio y la frecuencia cardíaca, en pacientes asistidos mediante ventilación mecánica, para la estimación del momento óptimo en la extubación, Tesis Universidad Autónoma de Bucaramanga, 2014.

[34] PALAZZOLO, J., SCHEUNEMANN, L., and HARTIN, J. Leakage fault detection method for axial-piston variable displacement pumps. En: Aerospace Conference, IEEE transactions on, 2008, p. 1-8.

[35] PLAWIAK, P. An estimation of the state of consumption of a positive displacement pump based on dynamic pressure or vibrations using neural networks. En: Neurocomputing, 2014, Vol.144, p.471-483.

[36] PATAN, K. Artificial neural networks for the modeling and fault diagnosis of technical processes. En: Springer, 2008.

[37] PENG, Z. K. and CHU, F.L. Application of the wavelet transform in machine condition monitoring and fault diagnosis:a review with bibliography. En: Mechanical Systems and Signal Processing, Science Direct, Abr. 2003, vol.18, p.199-221.

[38] PINTO, J. Análisis e interpretación de señales cardiorrespiratorias para determinar el momento óptimo de desconexión de un paciente asistido mediante ventilación. Tesis Universidad Autónoma de Bucaramanga, 2014.

[39] RAMDÉN, T., KRUS, P., and PALMBERG, J. Reliability and sensitivity analysis of a condition monitoring technique. En: Proceedings of the JFPS International Symposium on Fluid Power, 1996, Vol.1, p.567-572.

[40] SALIMI, E., and NIROMANDFAM, B. Condition monitoring of hydrolic pump by wavelet transform and artificial neural network. En: Journal of Novel Applied Sciences, JNAS transactions on, 2015, p.1123-1128.

[41] SORSA, T., and KOIVO, H. Application of artificial neural network in process fault diagnosis. En: Automatica, 1993, Vol.29, No.4, p.843-849.

[42] TAN, L., and YANG, Z. Fault diagnosis of hydraulic pumps using improved neural network. En:J.Cent.South Univ. Technol., 1995, Vol.2, No. 1, p.65-68.

[43] TANSEL, I., DEMETGUL, M., and TASKIN, S. Fault diagnosis of pneumatic systems with artificial neural network algorithms. En: Expert Syst. Appl.,2009, Vol.36, No.7, p.10512-10519

[44] TAO, X., WANG, Z., MA, J., and FAN, H. Study on fault detection using Wavelet Packet and SOM Neural Network. En: Prognostics & System Health Management Conference, IEEE transactions on, 2012, Vol.12, p.1-5.

[45] VEGA, V. Aplicación de la transformada wavelet discreta (DWT) en la detección e identificación de eventos de la calidad de la energía eléctrica. Tesis Universidad Industrial de Santander, 2004.

[46] WANG, K., WANG, S., and LI, K. Prognostic analysis based on hybrid prediction method for axial piston pump. En: 10<sup>th</sup> Conference Ind. Informatics, IEEE transactions on, 2012, p.688-692.

[47] WANG, S., ZHAO, W, and DOU, H. Fault simulation analysis of axial piston pump based on the components failure. En: 10<sup>th</sup> Int. Conf. Ind. Informatics, IEEE transactions on, 2012, p.631-634.

[48]URL:https://www.slideshare.net/hichamberkouk/introduction-to-wavelet transform-with-applications-to-dsp

[49]URL:http://catarina.udlap.mx/u\_dl\_a/tales/documentos/lis/navarrete\_g\_j/capitul o2.pdf

## ANEXO A. Código de metodología WPT+NN desarrollada para las señales de vibración.

```
88
% Auxiliar function used to process Vibration data
% General Signal Parameters
Fs = 50e3; % sample frequency
positions = [1 2 3 4]; % must be the respective positions for pressure or
vibration data
22
%read excel files
raw data = ReadrawData;
88
%remove means, trends and cut signals
parameters.Ls = 100e3; % minimum length signal
parameters.method = 'initial'; % can be 'center' or 'initial'
fData = preProcess(raw data, parameters);
응응
%plot PSD (Power Spectral Densities)
PSDplot (fData, Fs, positions) % for original frequencies until Fs/2
22
%plot Low Frequency Signal Contens
% Basic User Parameters (Should be specified)
fPar.Factor = 10; % downsampled factor (must be 1 to processing original
signal)
fPar.Fp = 3e3; % Passband frequency in Hz
% Advanced Parameters (optional to change)
fPar.Fst = fPar.Fp + 0.4e3; % Stopband frequency in Hz
fPar.MinPeakHeight = 0.1; % percentage value of frequency peaks to
mantain
fPar.Ap = 1;
                  % Passband ripple in dB
fPar.Ast = 95; % Stopband attenuation in dB
[PeaksL, FreqsL, powerL] = PSDplotLower (fData,Fs,fPar,positions); %plot
PSD for lower frequencies below Fp kHz
88
%plot High Frequency Signal Contens
% Basic User Parameters (Should be specified)
fPar.NPeaks = 3; % percentage value
fPar.Fp = 3.4e3; % Passband frequency in Hz
% Advanced Parameters (optional to change)
fPar.Fst = fPar.Fp - 0.4e3; % Stopband frequency in Hz
fPar.Ap = 1; % Passband ripple in dB
fPar.Ast = 95; % Stopband attenuation in dB
```

```
% Plot function
[PeaksH, FreqsH, powerH] = PSDplotHigh (fData, Fs, fPar, positions);
22
%scatter plots for Frequency data (for pressure data it does not make
sense)
PlotGroups(powerL, powerH, FreqsH, FreqsL, PeaksH, PeaksL, positions)
88
%Function to select mother and level for wavelet analysis
% entropy criterion
CRI = 'log energy'; %'shannon', 'threshold', 'norm', 'log energy' (or
'logenergy'), 'sure'
[wpM,wpS,Res] = waveletAnalysis(fData,positions,CRI);
88
%function to compute wavelet features
% mean, rms, std, var, skewness, kurtosis, iqr (aprox y detalle x cada
posición)
% wavelet family filter
wname='sym21'; %'db1', ...,'db43' or 'coif1',...,'coif5' or 'sym1',
..., 'sym25'
                       %'bior1.1'; 'bior1.3'; 'bior1.5'; 'bior2.2';
'bior2.4'; 'bior2.6'; 'bior2.8';
                       %'bior3.3'; 'bior3.5'; 'bior3.7'; 'bior3.9';
'bior4.4'; 'bior5.5'; 'bior6.8'
Position = [1 4];% can be [1 2 3 4] or [1 3 4] or [1 4] (Positions with
useful information)
wFeat = waveletFeat(fData,wpM,CRI,Position,wname);
88
%optional wavelet features
% Energy and kurtosis of sub-band wavelet packets (aprox y detalle x cada
posición)
wFeatS = waveletFeats(fData,wpM,CRI,Position,wname);
22
%This function is used to hold the same number of signals per
condition...
num = 12; % It is only necessary if the positions in each condition have
different number of signals
wFeatR = cutWfeat(wFeat,num); % wFeat can be replaced with wFeatS if
optional features are used
88
%Feature Selection using independent features method with significance
threshold
S=2;
                  typically, variables are kept when significance S >= 2
[DataF,Targets] = FeatSel(wFeat,S); % wFeat can be replaced with wFeatS
if optional features are used
88
%Results for different types of ANN (Neaural Network Outputs)
```

```
Normalizar = true; % or false
[Outputs,performance,errors]= Ann(DataF,Targets,Normalizar);
```

#### 99 99

```
%Compare performance of different types of ANN
[confmat,All_performance]=AnnCompare(DataF,Targets,Normalizar);
```

#### ANEXO B. Código de metodología WPT+NN desarrollada para las señales de

presión

```
88
%Auxiliar function used to process Pressure data
% General Signal Parameters
Fs = 100e3; % sample frequency
positions = [1 2]; % must be the respective positions for pressure or
vibration data
22
%read excel files
raw data = ReadrawData;
88
%remove means, trends and cut signals
parameters.Ls = 60e3; % minimum length signal
parameters.method = 'initial'; % can be 'center' or 'initial'
fData = preProcess(raw data, parameters);
응응
%plot PSD (Power Spectral Densities)
PSDplot (fData, Fs, positions) % for original frequencies until Fs/2
22
%plot Low Frequency Signal Contens
% Basic User Parameters (Should be specified)
fPar.Factor = 30; % downsampled factor (must be 1 to processing original
signal)
fPar.Fp = 10e3; % Passband frequency in Hz
% Advanced Parameters (optional to change)
fPar.Fst = fPar.Fp + 1e3; % Stopband frequency in Hz
fPar.MinPeakHeight = 0.1; % percentage value of frequency peaks to
mantain
fPar.Ap = 1;
                  % Passband ripple in dB
fPar.Ast = 95; % Stopband attenuation in dB
[PeaksL, FreqsL, powerL] = PSDplotLower (fData,Fs,fPar,positions); %plot
PSD for lower frequencies below Fp kHz
88
%plot High Frequency Signal Contens
% Basic User Parameters (Should be specified)
fPar.NPeaks = 3; % percentage value
fPar.Fp = 10e3; % Passband frequency in Hz
% Advanced Parameters (optional to change)
fPar.Fst = fPar.Fp - 1e3; % Stopband frequency in Hz
fPar.Ap = 1; % Passband ripple in dB
fPar.Ast = 95; % Stopband attenuation in dB
```

```
% Plot function
[PeaksH, FreqsH, powerH] = PSDplotHigh (fData, Fs, fPar, positions);
22
%scatter plots for Frequency data (for pressure data it does not make
sense)
PlotGroups(powerL, powerH, FreqsH, FreqsL, PeaksH, PeaksL, positions)
88
%Function to select mother and level for wavelet analysis
% entropy criterion
CRI = 'log energy'; %'shannon', 'threshold', 'norm', 'log energy' (or
'logenergy'), 'sure'
[wpM,wpS,Res] = waveletAnalysis(fData,positions,CRI);
88
%function to compute wavelet features
% mean, rms, std, var, skewness, kurtosis, iqr (aprox y detalle x cada
posición)
% wavelet family filter
wname='db2'; %'db1', ...,'db43' or 'coif1',...,'coif5' or 'sym1', ...,
'sym25'
                       %'bior1.1'; 'bior1.3'; 'bior1.5'; 'bior2.2';
'bior2.4'; 'bior2.6'; 'bior2.8';
                       %'bior3.3'; 'bior3.5'; 'bior3.7'; 'bior3.9';
'bior4.4'; 'bior5.5'; 'bior6.8'
Position = [1 2];% can be [1 2 3 4] or [1 3 4] or [1 4] (Positions with
useful information)
wFeat = waveletFeat(fData,wpM,CRI,Position,wname);
88
%optional wavelet features
% Energy and kurtosis of sub-band wavelet packets (aprox y detalle x cada
posición)
wFeatS = waveletFeats(fData,wpM,CRI,Position,wname);
22
%This function is used to hold the same number of signals per
condition...
num = 15; % It is only necessary if the positions in each condition have
different number of signals
wFeatR = cutWfeat(wFeat,num); % wFeat can be replaced with wFeatS if
optional features are used
88
%Feature Selection using independent features method with significance
threshold
S=2;
                  typically, variables are kept when significance S >= 2
[DataF,Targets] = FeatSel(wFeat,S); % wFeat can be replaced with wFeatS
if optional features are used
88
%Results for different types of ANN (Neaural Network Outputs)
```

```
Normalizar = true; % or false
[Outputs,performance,errors]= Ann(DataF,Targets,Normalizar);
```

#### 99 99

```
%Compare performance of different types of ANN
[confmat,All_performance]=AnnCompare(DataF,Targets,Normalizar);
```