



UNIVERSIDAD
NACIONAL
DE COLOMBIA

Identificación de diferentes modos de operación en bombas hidráulicas de caudal fijo con pistones axiales mediante técnicas de aprendizaje automático

César Augusto Alzate Rincón

Universidad Nacional de Colombia
Facultad de Minas
Medellín, Colombia
2022

Identificación de diferentes modos de operación en bombas hidráulicas de caudal fijo con pistones axiales mediante técnicas de aprendizaje automático

César Augusto Alzate Rincón

Tesis presentada como requisito parcial para optar al título de:

Magíster en Ingeniería Mecánica

Director:

Alejandro Restrepo Martínez

Profesor Titular

Línea de Profundización:

Profundización en Ingeniería Mecánica

Universidad Nacional de Colombia

Facultad de Minas

Medellín, Colombia

2022

DECLARACIÓN DE OBRA ORIGINAL

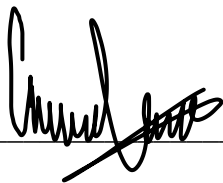
Yo declaro lo siguiente:

He leído el Acuerdo 035 de 2003 del Consejo Académico de la Universidad Nacional. «Reglamento sobre propiedad intelectual» y la Normatividad Nacional relacionada al respeto de los derechos de autor. Esta disertación representa mi trabajo original, excepto donde he reconocido las ideas, las palabras, o materiales de otros autores.

Cuando se han presentado ideas o palabras de otros autores en esta disertación, he realizado su respectivo reconocimiento aplicando correctamente los esquemas de citas y referencias bibliográficas en el estilo requerido.

He obtenido el permiso del autor o editor para incluir cualquier material con derechos de autor (por ejemplo, tablas, figuras, instrumentos de encuesta o grandes porciones de texto).

Por último, he sometido esta disertación a la herramienta de integridad académica, definida por la universidad.



César Augusto Alzate Rincón

Fecha DD/MM/AAAA

Fecha

RESUMEN

Identificación de diferentes modos de operación en bombas hidráulicas de caudal fijo con pistones axiales mediante técnicas de aprendizaje automático

Este trabajo busca identificar diferentes condiciones de operación en las bombas de pistones axiales de eje desviado mediante técnicas de análisis predictivo; la tesis expone la identificación de diversas situaciones de operación del equipo, que permitan extraer sus principales características de operación y establecer criterios claros de decisión ante posibles fallos en el equipo.

La bomba de pistones axiales de eje desviado objeto de este estudio, hace parte de una máquina inyectora de una importante compañía de inyección de poliuretano ubicada en la ciudad de Medellín, donde las mediciones fueron tomadas durante el proceso productivo de inyección de espumas y las diferentes referencias de productos representan sus distintos modos de operación.

La toma de datos de operación se dio a través de la medición de señales temporales como vibraciones, emisiones acústicas, ultrasónicas y campos magnéticos, discriminando diferentes niveles de exigencia del equipo. Esta información medida tendrá una etapa de análisis y descripción en el dominio del tiempo y la frecuencia mediante diferentes técnicas, así se facilitará un proceso de clasificación con estrategias de agrupamiento y redes

Identificación de diferentes modos de operación en bombas hidráulicas de caudal fijo con pistones axiales mediante técnicas de aprendizaje automático

neuronales; y finalmente se examinará el rendimiento de la clasificación con herramientas gráficas de evaluación.

El resultado del desarrollo de la tesis hará posible comparar los diferentes métodos utilizados determinando la mejor sugerencia para un plan de diagnóstico de las bombas de pistones, que será el principal insumo de un programa de mantenimiento basado en la condición del equipo que garantice un prolongado ciclo de vida con eficiencia y eficacia en su operación.

Palabras clave: Mantenimiento predictivo, bomba hidráulica de pistones, junta magnética, vibraciones mecánicas, campos magnéticos, emisiones acústicas, aprendizaje automático.

ABSTRACT

Identification of different conditions in fixed displacement axial piston hydraulic pumps through machine learning

This work searches identify different operation conditions of bent axis piston pumps through predictive analysis techniques; the thesis shows various situations of equipment operation, it enables to take its main operating features and establish decision criteria before of equipment fail.

The bent axis piston pumps factual of this investigation is part of an injection machine of a major company of polyurethane injection located at Medellin city, where the measures were

Identificación de diferentes modos de operación en bombas hidráulicas de caudal fijo con pistones axiales mediante técnicas de aprendizaje automático

taken during productive process of foams injection and the different products references represent its modes of operation.

The operation data acquisition was given through the measurement of variables like vibrations, acoustic emissions, ultrasonic emissions and magnetic fields, discriminating the exigence levels of equipment. This information will have an analysis and description phase in time and frequency domain through different techniques; so, it will facilitate a classification process with clustering strategies and neural networks; finally, it will review the classification performance whit evaluation graphic tools.

The development result will make possible to compare the used methods determining the better suggestion for a piston pumps diagnostic plan, it will be the main input of a maintenance plan based on equipment condition for warranting a long life cycle with efficiency and efficacy in its operation.

Keywords: predictive maintenance, hydraulic piston pump, magnetic joint, mechanic vibrations, magnetic fields, acoustic emissions, machine learning.

CONTENIDO

	Pág.
DECLARACIÓN DE OBRA ORIGINAL	III
RESUMEN	V
ABSTRACT	VII
CONTENIDO.....	XI
LISTA DE FIGURAS.....	XIII
LISTA DE TABLAS	XV
1. INTRODUCCIÓN	1
1.1 ESTADO DEL ARTE.....	3
1.2 JUSTIFICACIÓN.....	10
1.3 PREGUNTA DE INVESTIGACIÓN.....	11
1.4 HIPÓTESIS	11
1.5 OBJETIVOS.....	12
1.5.1 OBJETIVO GENERAL.....	12
1.5.2 OBJETIVOS ESPECÍFICOS	12
2. ADQUISICIÓN DE DATOS	14
2.1 INYECCIÓN DE POLIURETANO	14
2.2 MEDICIONES.....	17
2.2.1 VIBRACIONES.....	18
2.2.2 CAMPOS MAGNÉTICOS	22
2.2.3 EMISIONES ACÚSTICAS	24
2.2.4 EMISIONES ULTRASÓNICAS	27
3 DESCRIPCIÓN DE LAS SEÑALES.....	30
3.1 DESCRIPTORES TEMPORALES.....	30
3.2 TRANSFORMADA RÁPIDA DE FOURIER.....	31

3.3 ESPECTROGRAMAS	32
3.4 ESCALOGRAMAS	35
4 ENTRENAMIENTO NO SUPERVISADO	39
4.1 TÉCNICAS DE REDUCCIÓN DIMENSIONAL	39
4.1.1 PCA.....	40
4.1.2 TSN-E	41
4.1.3 UMAP.....	42
4.2 AGRUPAMIENTO DE LOS DATOS	42
4.2.1 K MEANS	43
4.3 CLASIFICADORES	49
4.3.1 REDES NEURONALES DE CLASIFICACIÓN.....	50
5 ENTRENAMIENTO SUPERVISADO	53
5.1 VALIDACIÓN CRUZADA	54
5.2 RED NEURONAL NN USANDO DESCRIPTORES TEMPORALES	54
5.3 ARBOLES DE DECISIÓN	56
5.4 REDES PROFUNDAS	58
5.4.1 ENTRENAMIENTO SUPERVISADO CON ESPECTROGRAMAS.....	58
5.4.2 ENTRENAMIENTO SUPERVISADO CON ESCALOGRAMAS.....	60
5.4.3 OTRAS COMBINACIONES.....	62
6. EVALUACIÓN DE METODOS SELECCIONADOS	64
6.1 MATRIZ DE CONFUSIÓN	65
6.2 CURVA ROC	69
7. CONCLUSIONES	73
8. BIBLIOGRAFÍA	75

LISTA DE FIGURAS

	Pág.
Figura 2-1: Bomba de pistones axiales de caudal fijo	16
Figura 2-2: Toma de señales de vibraciones en campo	20
Figura 2-3: Señales temporales de vibraciones	21
Figura 2-4: Toma de señales de campos magnéticos	23
Figura 2-5: Señales temporales de campos magnéticos	24
Figura 2-6: Toma de señales de emisiones acústicas en campo	26
Figura 2-7: Señales temporales de emisiones acústicas	26
Figura 2-8: Toma de señales de emisiones ultrasónicas en campo	27
Figura 2-9: Señales temporales de emisiones ultrasónicas	28
Figura 3-1: Transformada de Fourier para señal de vibraciones	32
Figura 3-2: Espectrograma creado a partir de señal de vibraciones	33
Figura 3-3: Señal temporal de campos magnéticos	34
Figura 3-4: Espectrograma creado a partir de señal de campos	34
Figura 3-5: Señal temporal de vibraciones	36
Figura 3-6: Escalograma continuo creado a partir de señal de vibraciones	36
Figura 3-7: Señal temporal de ultrasonidos	37
Figura 3-8: Escalograma discreto creado a partir de señal de ultrasonidos	38
Figura 4-1: Comparativo de imágenes PCA, K-Means de vibraciones	44
Figura 4-2: Comparativo de imágenes PCA, K-Means de ultrasonidos	45
Figura 4-3: Comparativo de imágenes t-SNE, K-Means de vibraciones	46
Figura 4-4: Comparativo de imágenes t-SNE, K-Means de ultrasonidos	47
Figura 4-5: Comparativo de imágenes UMAP, K-Means de vibraciones	48
Figura 4-6: Comparativo de imágenes UMAP, K-Means de ultrasonidos	48
Figura 5-1: Comparativo de espectrogramas de vibraciones	58
Figura 5-2: Comparativo de escalogramas de vibraciones	61
Figura 6-1: Matrices de confusión redes profundas con vibraciones	66
Figura 6-2: Matrices de confusión red NN y árbol de decisión para ultrasonidos ...	67
Figura 6-3: Matriz de confusión red NN con entrenamiento no supervisado para vibraciones	68
Figura 6-4: Curvas ROC para redes profundas con vibraciones	70
Figura 6-5: Curvas ROC de red NN y árbol de decisión para ultrasonidos	71

Figura 6-6: Curva ROC de red NN con entrenamiento no supervisado para vibraciones 72

LISTA DE TABLAS

	Pág.
Tabla 1-1: Cuadro resumen del estado del arte	9
Tabla 4-1: Comparativo de resultados en exactitud de clasificación para entrenamiento no supervisado	52
Tabla 5-1: Comparativo de resultados en exactitud de clasificación para entrenamiento no supervisado con red NN.....	55
Tabla 5-2: Comparativo de resultados en exactitud de clasificación para entrenamiento no supervisado con árbol de decisión	57
Tabla 5-3: Comparativo de resultados en exactitud de clasificación para entrenamiento supervisado con redes profundas	62

1. INTRODUCCIÓN

Las bombas hidráulicas de pistones axiales de caudal fijo constituyen uno de los principales equipos para generación de altas presiones y caudales en el campo de la hidráulica, ya que sus condiciones extremas de trabajo constituyen un desafío al momento de medir, analizar y tomar acciones predictivas o preventivas que permitan optimizar y extender su ciclo de vida.

Actualmente en bombas hidráulicas de pistones de caudal fijo con acoplamiento magnético se presenta la ausencia de una estrategia de análisis predictivo en vibraciones, campos magnéticos y emisiones acústicas con sistema de clasificación automático de fallos. Es así como se genera la necesidad de crear una metodología de diagnóstico y análisis de funcionamiento que permita detectar en producción los diferentes modos de operación y sus variaciones. Debido a las velocidades variables de operación, a la complejidad del equipo y la irregularidad en el comportamiento de las bombas ante diferentes productos generados, se explorarán cuatro señales temporales diferentes en la adquisición de la información requerida para el análisis.

Considerando lo anterior, el desarrollo de esta tesis buscará describir el comportamiento de este tipo de bombas tomando cuatro señales temporales en vibraciones, campos magnéticos, emisiones acústicas y ultrasonido. Se realizará un procesamiento con descriptores temporales, transformada de Fourier, espectrogramas y ondículas para llevar a una clasificación con algoritmos supervisados y no supervisados, y finalmente cerrar con un proceso de evaluación de los resultados en la identificación de los casos.

Para dar cumplimiento a los objetivos planteados y desarrollar un análisis objetivo del equipo, se tomarán como datos de entrada diferentes condiciones de operación de la bomba, las cuales serán asociadas a la producción de algunas referencias manufacturadas en el proceso industrial de operación de la bomba. Esto se definió ya que, a diferencia de otros estudios similares, no se cuenta con casos buenos y malos de la bomba que puedan

dar estados de referencia definidos. Al ser una máquina ubicada en el ambiente industrial, obtener muestreos de equipos en fallo sólo es posible con presencia de averías en el equipo, esta condición no podrá ser inducida debido a los altos costos y afectaciones en el proceso productivo que esto conduciría, y esto es algo que no se encuentra en el alcance del desarrollo de este estudio.

Finalmente, la estrategia desarrollada permitirá explorar el análisis de diferentes condiciones de operación, lo que permitirá crear una metodología útil para la detección futura de fallos en las bombas. Esto será posible complementando la información acá enunciada y los métodos evaluados para el desarrollo futuro de una metodología que establezca estrategias de predicción para la construcción del mantenimiento por condición en el equipo.

1.1 ESTADO DEL ARTE

El estado del arte incluirá una contextualización histórica sobre análisis similares que han buscado atender una necesidad similar a la de este estudio. Se verán diferentes combinaciones de análisis y técnicas que entregarán una importante base para el inicio de esta tesis y una ruta clara de trabajo para el cumplimiento de los objetivos.

Se citarán diferentes estudios previos que se han desarrollado para la detección de fallos en elementos de máquinas, investigaciones guiadas por etapas de adquisición caracterización, entrenamiento y diagnóstico identificando un flujo de trabajo similar al propuesto. Inicialmente trabajos realizados con análisis aplicados a señales en el dominio de la frecuencia, luego en el dominio del tiempo y finalmente la combinación de ambos. Posteriormente se complementará con estudios realizados comparando diferentes redes neuronales de clasificación que indicarán las diferencias de los resultados al modificar las técnicas aplicadas para el análisis, para cerrar con un comparativo de las técnicas aplicadas por los autores.

Previamente han demostrado que es posible realizar una completa metodología para el diagnóstico de fallo en rodamientos siguiendo cuatro etapas principales: adquisición de los datos de varios fallos en rodamientos, caracterización de las señales mediante descriptores temporales, entrenamiento de una red neuronal y diagnóstico final de fallo. De esta forma *Tao* pudo desarrollar un estudio experimental de análisis de fallo mediante una adquisición multisensorial de tres entradas diferentes, 14 descriptores estadísticos en el dominio del tiempo y 42 nodos de salida para entrenar una red neuronal profunda que entregó un 10% más de precisión que los sistemas con un solo sensor [8]. Esto definió que una red neuronal DBN bien entrenada permite mucha más precisión en los resultados que las redes SVM,

KNN y BPNN, bajo la restricción de contar con más de tres sensores de entrada que miden sincrónicamente el comportamiento del motor.

También para *Lessmeier* fue posible presentar un flujo de trabajo que permitió clasificar diferentes tipos de daños en rodamientos de bolas. El algoritmo de inteligencia artificial aprendió a partir de un mapa de características de entrada con un conjunto de datos adquiridos en campo. La red se evaluó por medio de matrices de confusión que determinaron la efectividad de la técnica bajo diferentes condiciones [9]. Esto constituye un flujograma para mediciones y clasificación en tiempo real, que se podrá aplicar en la presente tesis en el mismo orden y actividades propuesta, esperando clasificar diferentes comportamientos en la bomba.

En el año 2019, *Huang* aportó una guía para modelar las frecuencias naturales de un motor hidráulico de pistones axiales de eje desviado mediante herramientas de simulación, que posteriormente fueron verificadas de manera experimental tomando señales acústicas y de vibración mecánica. Mediante análisis a los espectros obtenidos gracias a la FFT de las señales, se obtuvieron picos en señales de vibración entre 80 y 416 Hz y en emisiones acústicas entre 128 y 832Hz. De allí se realizó un análisis del comportamiento del motor identificando los mayores puntos de vibración o emisión acústica bajo diferentes condiciones de operación, esto se obtuvo modificando las presiones y las velocidades de trabajo [10]. El análisis no continuó hacia el diagnóstico automático de fallos u otro sistema de análisis para el aprovechamiento de la información obtenida, pero define algunos puntos de medición para la toma de datos requeridos en este estudio.

Dependiendo del comportamiento de las señales tomadas, se debe definir el dominio en el cual se procederá a describir la señal, lo cual se puede desarrollar mediante las ondículas de segunda generación que utilizan las señales de rango en el dominio de la frecuencia a partir de las señales de rango en el dominio del tiempo tal como fue propuesto por *Gharezzi* [11].

Cabañas demostró que es posible realizar el análisis de las señales tomadas dentro del dominio del rango de la frecuencia mediante un proyecto experimental que permita simular diferentes defectos en los rodamientos a partir de la medición de vibraciones. La información tomada por un acelerómetro es posteriormente transformada mediante Matlab y el paquete Wavemenu para realizar su análisis dentro del dominio de la frecuencia. Sus

patrones característicos posteriormente entrenan tres sistemas de red neuronal: Red de base radial, red perceptrón multicapa, red SOM; lo que permite comparar el mejor método de procesamiento según el defecto puntual en los componentes [13]. Para un análisis de este tipo será necesario contar con un banco de pruebas y elementos en fallo para el entrenamiento de la red, además de enfocarse en fallos de rodamientos de motores, no puntualmente de bombas hidráulicas de pistones como es el caso de esta tesis.

Dentro del análisis de las frecuencias, *Gong* calculó teóricamente la relación entre el flujo y la presión en el funcionamiento de un motor hidráulico. Este experimento se simuló mediante la herramienta AMESim y se obtuvieron modelos teóricos del funcionamiento, posteriormente se realizó un ensayo en un banco de pruebas midiendo las emisiones acústicas mediante un micrófono y se procesaron las señales mediante el software LabShop. Al final se analizó la medida mediante *Danisk BK acustic system* para verificar su estabilidad y los picos presentes en la señal de frecuencia bajo diferentes condiciones de operación. De esta manera se estableció un método de análisis y control del funcionamiento de un motor hidráulico con posibles ahorros energéticos y control de emisiones de ruido [14]. A pesar de tener la información ya recolectada y procesada no se continuó con un entrenamiento automatizado para establecer un sistema de control de fallos de los motores, además de no contar con condiciones de fallo como dato de referencia.

Pasando al análisis de las señales dentro del rango del dominio del tiempo, *Sreejith* utilizó un banco de pruebas para un sistema de transmisión de un motor eléctrico del que tomó las señales de vibración de varios rodamientos en condición de fallo, se realizó la descripción de las señales en el rango del dominio del tiempo mediante el valor de pico (Pv), valor RMS, desviación estándar (SD), kurtosis (K), factor de cresta (Crf), factor de holgura (Clf), factor de impulso (Imf), factor de cresta (Shf), distribución Weibull (Wnl), y el valor de probabilidad logarítmico negativo normal (Nnl). Posteriormente se determinó que los mejores descriptores para fallos en la pista interna, la pista externa y los elementos rodantes de los rodamientos fueron el Kv y el Nnl, esto debido a que se requiere un menor número de neuronas y capas para entrenar la red neuronal artificial de clasificación. La misma comparación se realizó con las redes neuronales de propagación resiliente (RP), gradiente conjugada escalada (SCG), gradiente conjugada Powell-Beale (PBCG) y LM, siendo la última las más eficiente debido a la menor cantidad de etapas de entrenamiento requeridas. Con los descriptores y la red neuronal seleccionada se pudo construir un modelo con una alta probabilidad de diagnóstico correcto [15]. Esta estrategia podrá

aplicarse en el desarrollo de esta tesis para analizar las señales e identificar sus diferentes comportamientos, teniendo en cuenta que se requerirá de un entrenamiento supervisado para su completo desempeño.

Es posible también realizar un análisis donde se incluya el tratamiento de la señal en los rangos de dominio del tiempo y la frecuencia combinados para la detección de fallo, tal como lo realizó *Zarour*, quien a partir de un banco de pruebas para el análisis de los rodamientos en un sistema de transmisión de un motor eléctrico, tomó los datos de las vibraciones de rodamientos en condiciones de fallo. Mediante un sensor piezoeléctrico conectado a un módulo de adquisición se tomaron los datos de aceleración de las vibraciones, en el rango del dominio de tiempo de las señales se tomaron como descriptores estadísticos el valor RMS, kurtosis, factor de cresta, y oblicuidad, mientras que en el rango del dominio de la frecuencia se utilizó el BFPO (frecuencia de paso de las bolas por la pista externa). Se realizó la comparación entre los datos obtenidos por cada indicador, dando como resultado que sólo la kurtosis y la oblicuidad mostraron diferencias fácilmente perceptibles entre los datos tomados bajo varias condiciones diferentes de operación [16]. Con esto se realizó un análisis para validar la efectividad de los descriptores de fallo, pero se descartaron otros datos posibles que se pueden analizar dentro del dominio de la frecuencia, así como también queda abierta la posibilidad de aplicar una red neural para automatizar el análisis de fallo ya iniciado.

Una clara metodología para la creación de un algoritmo de diagnóstico en vibraciones fue construida por *Gharesí* quien realizó una reducción dimensional mediante un análisis discriminante dimensional (LDA) y generó una etapa de procesamiento para obtener mayor separación entre las clases de los datos. Posteriormente estos datos fueron analizados mediante un mapa autoorganizado (SOM) que facilitó su comprensión visual, para proceder a entrenar un algoritmo SVM que entregó los resultados finales del diagnóstico de los rodamientos en fallo utilizados para la toma de datos [11]. Al final del estudio se entregó un promedio de precisión en el diagnóstico de un 97.78%, dato mayor frente a otros estudios previos similares. A pesar de ser una metodología muy completa, será necesario profundizar la investigación en rodamientos de otros tamaños y referencias, así como evaluar casos de componentes en buen estado bajo condiciones de operación diferentes, haciendo muy importante poder evaluar este comportamiento en motores de mayor potencia como lo son los del montaje de bombas hidráulicas de pistones axiales.

Diferentes tipos de red neuronal podrán ser utilizados para la clasificación de los datos y toma de decisión predictiva de acuerdo con el entrenamiento recibido. *Karkouba* tomó como datos de entrada diferentes señales de presión y caudal en una bomba hidráulica de pistones axiales similar a la de este estudio, estas entradas se dividieron entre estado estable y las respuestas transitorias a diferentes cargas solicitadas al sistema hidráulico. La red neuronal se diseñó seleccionando el número de capas, el número de neuronas, función de transferencia y los datos de entrenamiento. En este análisis se buscó disminuir las pérdidas de potencia en el sistema cuando opera a altas presiones, logrando una precisión en el diagnóstico de 98% y generando un modelo de análisis para bombas de pistones axiales que se podrá utilizar en otras aplicaciones futuras en estos equipos [17]. Esta información se puede evaluar con otros modelos de red neuronal más avanzados a la fecha, en búsqueda de aumentar la precisión de la lectura para implementar una posible metodología de diagnóstico.

Un análisis similar con redes neuronales fue el realizado por Lara, donde a partir de señales de vibraciones en rodamientos en un banco de pruebas para análisis de vibraciones, obtuvo un análisis en el dominio de la frecuencia mediante ondículas para proceder con los sistemas clasificadores mediante tres diferentes redes neuronales: MLP y RBF y PNN. Del análisis se concluye que los sistemas de clasificación híbridos (con dos o más tipos de red) entregan los mejores resultados de clasificación bajo lo diferentes condiciones de fallo de los rodamientos [18]. A pesar de entregar un buen análisis en redes neuronales, se basa el estudio en rodamientos con fallo, lo cual es una condición que no se tiene presente en el modelo de esta tesis.

Casoli tomó datos de vibraciones en bombas hidráulicas de pistones axiales de plato basculante mediante tres tipos de sensores diferentes: dos acelerómetros piezoeléctricos, un encóder relativo y un tacómetro. Con estas señales se tomaron datos de bombas en buen estado y en fallo bajo diferentes condiciones: desgaste en los puertos de la placa, erosión por cavitación, desgaste en las zapatas y desgaste en los cilindros. Con esta información construyó un promedio sincrónico (SA) mediante ecuaciones que facilitó el poder extraer la parte predictiva de la señal y el ruido restante, a estas señales se les realizó una identificación de características mediante la FFT y una posterior clasificación mediante el PCA. Finalmente se entrenaron 7 diferentes clasificadores: árbol grueso, discriminante lineal, árboles conglomerados, KNN pesada, KNN media, SVM gaussiana fina y SM lineal. Al comparar los clasificadores mediante una matriz de confusión se concluyó que el

conglomerado de árboles presentó los mejores resultados respecto a la precisión del diagnóstico [19]. El método se realizó en un banco de pruebas y tuvo comparación con casos de fallo existentes, será necesario evaluar su desempeño en condiciones típicas de operación.

Finalmente, se citará un adecuado método para el análisis de diferentes estados de operación de las bombas, con la técnica de transformada de ondículas continuas convertidas a imágenes de dos dimensiones. Posteriormente se construye un modelo de autocodificación convolucional enseñándole los diferentes estados de operación del equipo tal como lo realizó *Kaji*. La transformada ondícula se utiliza para identificar señales no estacionarias de diferentes frecuencias, lo que la hace una técnica que puede revelar aspectos ocultos en la señal a diferencia de otras técnicas; esto facilita la identificación de rupturas instantáneas o fallos evolutivos a lo largo del tiempo. De allí se entrenó una red neuronal convolucional logrando obtener al final un modelo de identificación de la evolución de fallo de un rodamiento [20]. La técnica se comparó con análisis realizados mediante descriptores temporales, deduciendo que este método entrega mejores resultados a la hora de evaluar el desarrollo en el tiempo de evolución de un fallo. Esta ventaja podrá apoyar este proyecto de tesis al poder realizar seguimiento a las bombas hidráulicas a lo largo del tiempo e identificar condiciones de alerta al momento de detectar variaciones críticas en sus condiciones de operación.

En la Tabla 1-1 se podrá apreciar un resumen de los análisis experimentales realizados discriminando las variables físicas utilizadas para el análisis, el dominio utilizado, cantidad de descriptores, clasificador, el componente del sistema y el fallo puntual analizado. De la síntesis se puede concluir que los métodos utilizan principalmente señales de vibraciones con análisis de descriptores temporales, de frecuencia y de escalas, con esto se aplican diferentes sistemas de clasificación dando un mayor énfasis a la detección de fallos en rodamientos.

Tabla 1-1: Cuadro resumen del estado del arte (Fuente Propia)

Ref	Variable	Análisis en dominio	Descriptor	Clasificador	Elemento en fallo	Fallo
8	Vibración	Tiempo	14 diferentes	DBN	Rodamientos	Pista interna, pista externa y bolas
9	Vibración, emisión acústica	Frecuencia	No incluido	No incluido	No incluido	No incluido
11	Vibración	Temporales	Orbitales	CNN	Rodamientos	Desbalanceo, desalineación
12	Vibración	Frecuencia	Ondícula	Red de base radial, red perceptron multicapa, red SOM	Rodamientos	Pista interna, pista externa y bolas
13	Emisión acústica	Frecuencia	No incluido	No incluido	Rodamientos	No incluido
14	Vibración	Tiempo	9 diferentes	LM, RP, SCG, PBCG	Rodamientos	Pista interna, pista externa y bolas
15	Vibración	Tiempo y frecuencia	6 diferentes	No incluido	Rodamientos	Pista externa
10	Vibración	Frecuencia	Ondícula	SOM, SVM	Rodamientos	Pista interna, pista externa
16	Caudal	No incluido	No incluido	Método de gradiente descendiente	No incluido	No incluido

De acuerdo con esto, se visualiza la necesidad de profundizar en el análisis predictivo utilizado para bombas hidráulicas con acoplamiento por junta magnética, explorar en casos donde no se cuente con eventos de fallo para el entrenamiento y donde se cuente con los campos magnéticos como como variable de entrada.

1.2 JUSTIFICACIÓN

Es común que al momento de presentarse averías mecánicas en las bombas de pistones axiales se incurra en elevados costos de mantenimiento, gracias al creciente valor comercial que tienen su fabricación, importación y compra de refacciones para el mantenimiento correctivo de sus elementos constitutivos; así como el lucro cesante generado por las paradas en los equipos y sus afectaciones directas al proceso productivo.

En las industrias fabricantes de motopartes y autopartes, una avería generada por el fallo de una de estas bombas representa paradas en las líneas de producción y riesgo de abastecimiento a la línea de manufactura final de las principales ensambladoras del país. Adicional a esto, se genera la necesidad de realizar la compra inmediata de bombas hidráulicas nuevas las cuales son importadas directamente desde Europa, dado que este tipo de bombas no se producen en el país.

En los históricos de la empresa, estas operaciones correctivas pueden promediar un costo aproximado de 200.000.000 COP y el contrato de penalización por lucro cesante con una ensambladora maneja indemnizaciones aproximadas de 900.000 COP por minuto, generando entonces paros con costos superiores a 400.000.000 COP en los últimos cinco años. Esto sumado a que la incertidumbre generada por el riesgo de no conocer el estado del equipo en operación o no poder generar un pronóstico de su ciclo de vida útil, afecta directamente las proyecciones presupuestales de la compañía.

Entre los modos de falla generados en las bombas se encuentran algunos tales como rupturas en las zapatas de los pistones, socavaciones internas por cavitación, pistones rayados y fracturas en los componentes internos.

1.3 PREGUNTA DE INVESTIGACIÓN

¿Es posible describir el comportamiento de este tipo de bombas mediante descriptores estadísticos, clasificar los datos recopilados en su funcionamiento, entrenar con ellos un sistema de inteligencia artificial y evaluar su efectividad en la detección de diferentes condiciones de operación?

1.4 HIPÓTESIS

La principal hipótesis que se maneja es que la operación de diferentes referencias de productos en la máquina genera cambios en las vibraciones, emisiones acústicas y ultrasónicas y en el campo magnético con respecto a su condición normal de operación, por lo que estas variaciones podrán entregar información que sea clasificada por una red neuronal que realice una correcta identificación de estas condiciones en la bomba.

1.5 OBJETIVOS

1.5.1 OBJETIVO GENERAL

Desarrollar técnicas para la identificación de casos de operación de bombas hidráulicas de pistones axiales utilizando una señal temporal y algoritmos de inteligencia artificial para obtener un análisis de su comportamiento.

1.5.2 OBJETIVOS ESPECÍFICOS

- Elaborar una estrategia para adquisición y selección de una señal de operación de la bomba.
- Evaluar y seleccionar descriptores temporales, de frecuencia y escalograma de wavelets, para transformar la señal adquirida.
- Desarrollar el entrenamiento de los clasificadores permitiendo diferenciar las condiciones de operación de la bomba.
- Evaluar el desempeño de los clasificadores en la identificación de los modos de operación.

Para exponer la tesis planteada, este documento enseñará a través de diferentes capítulos las etapas de construcción del estudio iniciando una etapa experimental de adquisición de las señales temporales por cuatro métodos diferentes, las señales adquiridas se describirán también con estrategias diferentes para ser llevadas posteriormente a un proceso de clasificación con técnicas supervisadas y no supervisadas. Se conocerán los resultados del proceso y se evaluarán los mejores resultados por medio de herramientas para la evaluación del desempeño de algoritmos.

Se espera que al finalizar todo el desarrollo se dé cumplimiento a los objetivos planteados y poder contar con una metodología clara para la identificación de casos de operación y análisis de operación de las bombas de pistones.

En la etapa final se conocerán las conclusiones del estudio con base a los objetivos inicialmente planteados, identificando cuáles son las técnicas más adecuadas para obtener su cumplimiento.

2.ADQUISICIÓN DE DATOS

En búsqueda de dar cumplimiento a los objetivos planteados, se inició con la toma de los datos para el análisis de las diferentes señales temporales medidas con la idea de monitorear el comportamiento de la máquina. Inicialmente con una contextualización del objeto de estudio y su medio de trabajo, se conocerán las condiciones de la medición y retos a superar para un correcto proceso de adquisición, luego se identificarán las señales temporales a medir y la metodología utilizada para llevar a cabo el proceso.

2.1 INYECCIÓN DE POLIURETANO

Los sistemas hidrostáticos son de gran aplicación en el campo industrial gracias a los amplios rangos de velocidad y torque que desempeñan, así como su fácil monitoreo [1]; por ello las bombas hidráulicas de pistones axiales tipo eje desviado constituyen uno de los principales componentes de los sistemas hidráulicos actuales. En los últimos años se han desarrollado diferentes técnicas de análisis para evaluar el comportamiento de los elementos existentes en este tipo de bombas, buscando facilitar y optimizar las labores de mantenimiento predictivo en estos sistemas mecánicos.

La industria actual de ensamble de motocicletas y automóviles maneja como premisa principal el bajo consumo energético y el máximo desempeño, por ello la tendencia a utilizar componentes de baja densidad que reduzcan el peso del vehículo. Las sillas de los ocupantes deberán entonces cumplir con el máximo confort y seguridad posible,

adaptándose a la anatomía humana, absorbiendo las vibraciones generadas en el desplazamiento y aportando a la reducción en el peso del vehículo. Las espumas de poliuretano son el material más utilizado para cumplir con estas características, aprovechando sus características físicas, así como la velocidad y precisión que permite su proceso de manufactura [2].

El poliuretano se obtiene al darse la mezcla de dos componentes químicamente reactivos como lo son el polioliol y el isocianato [2][3], estos se inyectan mediante un sistema de alta presión y la mezcla ingresa a un molde bajo condiciones de presión y caudal estables y controladas. Ya en el molde se genera internamente un aumento en la temperatura y liberación de CO₂, lo que crea una dilatación isométrica de la mezcla que se expande rápidamente hasta llenar completamente la cavidad del molde [3]. En este proceso se forma la espuma de poliuretano, la cual posee características viscoelásticas que combinan las propiedades físicas de los líquidos y los sólidos al mismo tiempo [2].

En el proceso de inyección se utiliza un dispositivo para el mezclado llamado cabezal de mezclado el cual posee dos cámaras y dos boquillas de dimensiones milimétricas, con el fin de que en el proceso de inyección se dé un aumento en la energía cinética, por lo tanto, grandes turbulencias y una mezcla perfecta. Estas condiciones sólo pueden obtenerse si se tiene un sistema de bombas de alta precisión manejadas directamente por un exigente sistema de control [3].

El polioliol es considerado un componente muy abrasivo, mientras que el isocianato tiene la tendencia a formar cristales al tener contacto con el oxígeno [4], de acuerdo con esto la elección de la bomba adecuada para esta función dependerá de la viscosidad y lo abrasivo del producto y también lo serán los rangos de precisión y flujo considerados para el proceso. La experiencia práctica enseña que las bombas de pistones de caudal fijo dan los mejores resultados en términos de ciclo de vida, exactitud y precisión, por lo que son las más utilizadas para esta aplicación [5].

Una bomba de pistones axiales tipo eje doblado (Figura 2-1) se divide en dos partes: un bloque de cilindros y una placa de torque. El eje de la placa base (en la misma dirección al eje del motor) se conecta con el bloque de cilindros sin una interferencia mecánica y es soportado por rodamientos. Las placas se conectan mediante un mecanismo que asegura una perfecta sincronización de rotación a través de una junta universal [6]. El torque

generado desde el motor se conduce a la bomba a través una transferencia magnética de torque; esta transferencia trabaja bajo el principio de inducción magnética: dos componentes separados que no mantienen contacto físico al tener una brecha de aire entre ellos. El motor se encuentra completamente aislado de la carga lo cual permite eliminar la transmisión de vibraciones entre las unidades, aumentar su tiempo de vida, reducir el mantenimiento y no requerir de tiempos prolongados para la alineación del sistema [7].




Figura 2-1: Bomba de pistones axiales de caudal fijo (Fuente Propia)

Bajo estas condiciones especiales de operación, y los pocos tiempos disponibles para mantenimiento que el proceso requiere, se construirá el proceso de adquisición de datos sin requerir de ningún método invasivo que genere inconvenientes al proceso.

2.2 MEDICIONES

En la compañía en cuestión, se seleccionó una de las máquinas inyectora de poliuretano pertenecientes al proceso productivo, la cual procesa diferentes referencias de productos como sillas de motocicletas. Esta máquina posee dos bombas de pistones axiales como las descritas previamente, de la cual se seleccionó la bomba inyectora del isocianato como nuestro objeto de estudio.

Cada unidad inyectada tiene una duración promedio de diez segundos por pieza, siendo este el ciclo de medición que se tomó como base del muestreo recolectado. Las diferentes mediciones tomadas se clasificaron bajo la referencia del producto manufacturado, en estos casos fueron referencias de motocicletas que denominaremos producto 1, producto 2, producto 3; tal como lo veremos en la descripción de los datos.

Las señales seleccionadas para la observación de la bomba de pistones fueron las vibraciones, emisiones acústicas, de ultrasonido, y los campos magnéticos generados en el acople de la bomba y el motor eléctrico. La selección de estas señales se dio en búsqueda de obtener la mayor cantidad posible de información de operación, complementando cada técnica entre sí para obtener al final un análisis integral de las condiciones de operación del equipo.

Con la técnica de vibraciones es posible obtener el comportamiento de la máquina en frecuencias menores a 50 Hz, y se complementa con las emisiones acústicas que facilitarán la identificación de las frecuencias hasta 20 KHz y sus variaciones en el comportamiento. A través del ultrasonido el sistema nos proporcionará la posibilidad de identificar fugas

internas o condiciones de fallo tempranas que son posibles de identificar con frecuencias superiores a 20 KHz. Por último, la medición de las variaciones en los campos magnéticos proporcionará información de posible desalineación o desbalanceo en el acople, como principal modo de falla perceptible por esta técnica.

Para la recolección de la información se utilizaron sensores de aceleración, micrófonos y de campos magnéticos; los cuales convierten las señales mecánicas del equipo en señales temporales que se podrán procesar mediante herramientas computacionales.

Los datos con las muestras tomadas del equipo se enviaron a un computador, donde se realizó un proceso de estandarización de las muestras para facilitar su análisis mediante Matlab, para un posterior procesamiento y clasificación de la información.

De las cuatro señales tomadas: las vibraciones, los campos magnéticos y las emisiones acústicas, fueron medidas a través de un teléfono celular Iphone X. Este teléfono celular posee acelerómetro, micrófono y magnetómetro que permitieron tomar estas variables físicas mediante la aplicación gratuita. La otra variable referenciada, emisiones ultrasónicas, fue tomada a través del medidor *all-sun* EM2246. Este medidor permitió convertir las emisiones ultrasónicas en audibles, para ser almacenadas en el teléfono celular y de allí ser analizadas como archivo con extensión M4a.

2.2.1 VIBRACIONES

La vibración mecánica es el movimiento generado por una máquina o sus componentes al desplazarse de un punto a otro de su posición de equilibrio; el ejemplo más claro es el de una masa atada a un resorte, cuando esta se aleja o se acerca manualmente de su punto de anclaje y posteriormente se libera, continuará moviéndose indefinidamente hasta volver a su punto de partida.

El movimiento de vibración se compone de un periodo, una frecuencia, amplitud, desplazamiento, velocidad y aceleración [21]. Será necesario conocer cada una de estas magnitudes para determinar la condición a evaluar y medir en el análisis de vibraciones a desarrollar.

Las máquinas y equipos con operaciones mecánicas generan siempre señales de vibración debido a sus dinámicas de operación, por lo que su intensidad dependerá directamente de la carga aplicada al sistema, su modo de operación y velocidad de trabajo, entre otras múltiples variables. Es por este motivo que actualmente las técnicas de análisis de vibraciones son las prácticas no invasivas más utilizadas en el diagnóstico de equipos rotativos [22].

Evaluar la anormalidad en estas vibraciones permitirá detectar rodamientos defectuosos, pérdidas de eficiencia, acoples gastados o rotos, desalineación, desbalanceo, inestabilidad en flujos de operación o elevada condición de desgaste en componentes de bombas [21].

Como sensor de medición se utilizó el acelerómetro del teléfono celular, el cual deberá ubicarse sobre la carcasa del equipo, lo más cerca que se pueda a la ubicación de los rodamientos o al área de contacto de los pistones para obtener las lecturas que mejor describan de la operación [22].

El teléfono celular Iphone X posee dentro de sus características un sensor de movimiento acelerómetro LIS331DL, el cual puede detectar la aceleración en el dispositivo con un rango de medición de 100 Hz, que nos permitirá identificar frecuencias de hasta 50Hz generadas por la bomba. Esta característica permitió detectar las señales de vibración en baja frecuencia de la bomba de pistones axiales, lectura similar a la que se podría obtener por medio de un acelerómetro industrial.

Utilizando la aplicación Phyphox instalada en el teléfono, en el modo aceleración sin g se inició con cada una de las mediciones a evaluar. Se apoyó el teléfono directamente sobre la bomba de pistones buscando medir el impacto de estos al momento de realizar al proceso de inyección (Figura 2-2), allí se sostuvo rígidamente durante cada medición y mediante la aplicación se almacenaron cada una de las tomas realizadas.

Se tomaron un total de 90 mediciones diferentes en tres referencias distintas, cada muestra se estandarizó con una duración de 5,12 segundos para establecer de esa forma un tamaño de muestra de 512 datos. Las señales pregrabadas fueron verificadas en el computador revisando el comportamiento de cada una de las señales, buscando eliminar muestras con errores de medición o captura de los datos que generasen errores al momento de realizar el análisis de los datos.



Figura 2-2: Toma de señales de vibraciones en campo (Fuente Propia)

El principal patrón característico detectado en las gráficas es que en el producto 1 se detectan picos con menores amplitudes y una mayor separación en el eje del tiempo, a diferencia de los productos 2 y 3 donde se tienen tres picos con una distribución similar y con mayores amplitudes de la señal (Figura 2-3). Estas variaciones son provocadas por la secuencia de apertura y cierre de las válvulas del producto inyectado, lo cual genera un impacto directo en los cambios de dirección bruscos del fluido y por consiguiente los mayores picos de vibración en la bomba. En la etapa de clasificación se evaluará la capacidad de los algoritmos para diferenciar estos patrones de comportamiento reflejados en las señales temporales.

Con las muestras ya revisadas se construyó una matriz de 90 por 512 en formato xlsx que constituirá el archivo con las señales de vibración temporales, insumo de entrada para el resto del proceso.




Figura 2-3: Señales temporales de vibraciones (Fuente Propia)

2.2.2 CAMPOS MAGNÉTICOS

Actualmente en los sistemas de transmisión de movimiento utilizados en la industria, es común encontrar que con mayor frecuencia se utilicen los sistemas de acople magnético coaxial [25]. Un magneto conductor y un magneto conducido generan una interacción entre sus campos magnéticos al darse el giro en el primero, de esta manera el torque se transmite de uno a otro dando como resultado un efectivo mecanismo de acoplamiento.

Este sistema de transmisión de movimiento es utilizado por ventajas como estas:

- Se utilizan en sistemas de bombeo de productos químicos considerados peligrosos, ya que el sistema permite la hermeticidad en la bomba con muy bajas probabilidades de fuga de componentes.
- Este sistema se considera de bajo mantenimiento porque los desgastes por fricción entre piezas son muy bajos y alargan el ciclo de vida en operación de las bombas y motores sin ser necesaria la lubricación.
- Se consideran sistemas de alta eficiencia en transmisión y bajo consumo de energía debido a que no se tiene fricción directa entre componentes y la transmisión es completamente magnética.

El Iphone X posee un sensor magnetómetro AKM8975, el cual permite detectar los cambios en el campo magnético generado por el acople de la bomba en el dispositivo con un rango de medición de 100 HZ, para identificar comportamientos de la señal en frecuencias por debajo de 50 HZ. Esta característica ayudará a detectar las variaciones del campo en las bajas frecuencias.

La aplicación Phyphox permitirá también utilizar el modo magnetómetro para la medición del campo magnético, así se configuró el dispositivo para realizar la medición. Se apoyó el teléfono directamente sobre el acople magnético entre la bomba y el motor, siendo este el punto más cercano para medir la variación en el campo (Figura 2-4).




Figura 2-4: Toma de señales de campos magnéticos (Fuente Propia)

Se tomaron un total de 70 mediciones diferentes en tres referencias distintas, estas muestras también se estandarizaron con una duración de 5,12 segundos para establecer de esa forma un tamaño de muestra de 512 datos. Los tres productos presentan un comportamiento similar en cuanto a que las señales son periódicas y siguen una misma forma de onda en el tiempo, reflejando normalidad en el estado del acople magnético y la lectura de sus campos (Figura 2-5). No es fácil diferenciar las referencias de los productos debido a que la oscilación es similar y los cambios en el tiempo siguen el mismo modelo.

Con las muestras ya revisadas se armó también una matriz de 70 por 512 en formato xlsx, por medio de la cual se creó la base de datos de las señales magnéticas temporales con la lectura del comportamiento del acople entre bomba y motor.




Figura 2-5: Señales temporales de campos magnéticos (Fuente Propia)

2.2.3 EMISIONES ACÚSTICAS

La emisión acústica es la técnica de análisis de fallo basada en detección de las ondas no estacionarias creadas por la deformación elástica en los materiales [23]. Es muy adecuada para detectar los cambios pequeños y tempranos que se dan en esta liberación de energía, así como también facilita el manejo de altas frecuencias en las señales; por lo que sus grandes ventajas en el monitoreo de las estructuras críticas y sus componentes no podrían dejarse de lado en el desarrollo de esta tesis.

Esta técnica se empezó a utilizar analizando la deformación y los defectos presentes en los materiales de las máquinas, posteriormente se impulsaron nuevos análisis debido al intercambio de técnicas y modelos desarrollados a nivel mundial en el análisis de

mantenimiento predictivo, y finalmente se profundizó en las formas de onda, la caracterización y ubicación de las fuentes generadoras de la emisión [24].

Para el desarrollo de la técnica se deberá recopilar la información, donde un sensor (generalmente un micrófono) tomará las señales emitidas y las llevará a una tarjeta de adquisición que convertirá las señales análogas en digitales, será tratada por una interfaz, generalmente un software, que se utilizará para el desarrollo de la técnica y la aplicación de los diferentes métodos de análisis [23].

Para las mediciones de las emisiones acústicas de la bomba se utilizó el micrófono convencional del teléfono celular como sensor de conversión de la variable física en señal temporal. De esta forma será posible evaluar el comportamiento de la bomba con una frecuencia de muestreo de 44.100 Hz, lo que permitirá analizar frecuencias de hasta 22.000 Hz. Esta característica ayudará a identificar eventos y comportamientos no perceptibles en los métodos anteriores, ya que algunos fenómenos de fallo temprano en las máquinas generan emisiones a mayor frecuencia, la cual disminuye a medida que empeora la condición del equipo.

Mediante la aplicación de grabador de voz del teléfono celular, se tomaron las muestras de audio de las referencias especificadas para la medición. El teléfono fue apoyado directamente sobre la bomba, en la ubicación de impacto superior de los pistones (Figura 2-6). El micrófono principal, el cual se encuentra ubicado en la cara inferior del teléfono, se ubicó en contacto directo y rígido sobre la bomba con el fin de evitar interferencias o pérdidas en la señal entre el teléfono y la bomba.

Finalmente, se construyó una matriz en Matlab con un tamaño de 400.000 columnas por 148 filas, donde cada fila indica el caso de operación medido o muestra de las tres referencias evaluadas. Esta será el archivo de entrada para el análisis de las emisiones acústicas de la bomba.

Es posible identificar diferentes picos y amplitudes en las señales por cada referencia medida, lo que se supone que se da debido a los procesos de cierre y apertura de válvulas que son independientes por cada referencia inyectada (Figura 2-7). Cada producto es muy diferente a los demás y no se perciben picos anormales que lleven a suponer que se tiene alguna condición de fallo en la bomba.



Figura 2-6: Toma de señales de emisiones acústicas en campo (Fuente Propia)




Figura 2-7: Señales temporales de emisiones acústicas (Fuente Propia)

2.2.4 EMISIONES ULTRASÓNICAS

Para medir las emisiones ultrasónicas se utilizó el detector ultrasónico de fugas *all-sun* EM2268, el cual convierte las emisiones generadas por la bomba a una señal audible para el ser humano. La muestra se almacenó en el teléfono celular utilizando su tarjeta de digitalización de audios. Este método permitió identificar y almacenar emisiones ultrasónicas en la bomba con valores entre 36 y 44 KHz que fueron analizadas en el audible. Esta estrategia facilitó el poder identificar eventos no perceptibles mediante las tres estrategias previamente relacionadas, ya que en las altas frecuencias será más fácil ver pequeñas fugas internas o fricciones tempranas con riesgo en los componentes.

Para el desarrollo de la medición, se tomó la sonda ultrasónica del detector, y se ubicó directamente sobre la parte superior de la bomba, la que se ha descrito como zona de impacto superior de los pistones; sosteniéndola para que tenga contacto directo y rígido al momento de la inyección (Figura 2-8). El detector posee una salida de audio por audífonos, la cual permite escuchar la señal ultrasónica convertida a señal audible. Esta señal se llevó al teléfono celular como entrada de audio, para guardarla como señal de audio y poder disponer de las misma en los análisis subsecuentes.



Figura 2-8: Toma de señales de emisiones ultrasónicas en campo (Fuente Propia)

Para emisiones ultrasónicas, se grabaron un total de 125 muestras de tres referencias de productos diferentes. Buscando disminuir la necesidad en procesamiento y optimizar la capacidad computacional disponible, las señales se estandarizaron con una longitud final de 295.000 datos por muestra. Se revisaron todas las señales en su totalidad para identificar posibles ruidos o señales incorrectas, para finalmente depurar las muestras a evaluar en los pasos posteriores.

Las señales temporales muestran variación en picos positivos y negativos sin un patrón característico ni amplitudes de onda que faciliten el diferenciar las clases tomadas. Esto lleva a suponer que no se tienen condiciones tempranas de fallo que sean detectadas por el método (Figura 2-9).




Figura 2-9: Señales temporales de emisiones ultrasónicas (Fuente Propia)

La matriz final con los datos de emisiones de ultrasonido fue construida con un tamaño de 295.000 columnas por 125 filas, que representan las muestras tomadas de cada clase o referencia medida y que serán la base de datos del análisis posterior.

Las cuatro señales temporales adquiridas permitieron analizar diferentes métodos y elementos de medición, que facilitaron de una forma integral la identificación de las señales en sus diferentes condiciones de operación, llevando a distinguir sus comportamientos y tendencias vistas desde diferentes puntos de evaluación.

Después del desarrollo en la etapa de adquisición de los datos vista en este capítulo, se puede concluir que, en el comportamiento de las señales en el rango del dominio del tiempo fue posible identificar los picos principales generados en el proceso de inyección, como patrón principal de diferenciación de clases a tener en cuenta en el estudio que viene a continuación. También fue notorio el hecho de que, sin un análisis posterior, las técnicas de vibración y emisiones acústicas y ultrasónicas permiten visualizar diferencias entre las clases; mientras que con la medición de los campos magnéticos la diferencia entre referencias no es perceptible a simple vista.

Al ser este proceso el inicio del desarrollo de la tesis es de vital importancia que los datos tomados y el procedimiento realizado para la recolección de los datos se realice con todo el detalle explicado y cumpliendo estrictamente cada paso descrito, ya que, si alguna de estas actividades no se da correctamente, se tiene un gran riesgo de obtener información errada para el desarrollo y posiblemente esto genere que el proyecto realizado no finalice según lo esperado.

Reconocer las diferencias y las dificultades presentes entre cada método de medición, permitió mejorar la calidad del análisis de los datos, y la calidad del trabajo realizado posteriormente.

3 DESCRIPCIÓN DE LAS SEÑALES

Posterior a la etapa de adquisición de las señales se continuó con la etapa de descripción, allí a cada una de las muestras tomadas se les aplicaron técnicas de descripción para facilitar el proceso de clasificación y tener representaciones generalizadas de las bases de datos adquiridas mediante la extracción de las características de su comportamiento.

Se utilizaron los descriptores temporales buscando facilitar el análisis y resumir la información tomada en el dominio del tiempo, permitiendo que los datos sean más comprensibles y fáciles de interpretar para un análisis posterior; las señales también fueron analizadas mediante la transformada rápida de Fourier (FFT), la cual permite visualizar la composición de las señales tomadas a través de la descomposición de sus componentes espectrales, se implementaron también los espectrogramas para facilitar la identificación del comportamiento de la frecuencia de las señales y su intensidad en el tiempo, finalmente aplicando la transformada de ondículas para descomponer las señales e identificar discontinuidades o zonas de gran variación.

3.1 DESCRIPTORES TEMPORALES

Cada una de las señales tomadas fueron sometidas a la extracción de sus descriptores temporales en búsqueda de poder hallar sus tendencias, dispersión y distribución;

expresadas en vectores de una menor longitud que describan perfectamente nuestras señales y permitan un análisis con una baja necesidad computacional de procesamiento.

Las matrices obtenidas en la adquisición de las señales temporales de vibración, emisiones acústicas, campos magnéticos y emisiones ultrasónicas fueron producto de la extracción de los siguientes descriptores estadísticos: media, máximos, mínimos, pico a pico, varianza, desviación estándar, curtosis, raíz cuadrática media y asimetría. De esta forma se obtuvieron vectores de 9 datos por cada muestra tomada, así la matriz final tendrá 9 filas y la cantidad de columnas que representa las mediciones realizadas de los tres productos evaluados.

3.2 TRANSFORMADA RÁPIDA DE FOURIER

La transformada rápida de Fourier computa la transformada discreta de Fourier y su inversa, se utiliza para convertir una señal digital en el dominio del tiempo a una señal en el dominio de la frecuencia.

La ventaja de utilizar este tipo de análisis sobre los análisis en el dominio del tiempo será la facilidad en identificar y aislar las frecuencias específicas a estudiar, esto será posible ya que la señal temporal se descompone en frecuencias que representan las funciones armónicas de cada señal medida. Aplicar esta herramienta podrá apoyar el presente estudio en la identificación de condiciones y picos de operación que caractericen el funcionamiento de las bombas.

La Figura 3-1 muestra la transformada de Fourier de una de las señales de vibraciones tomadas a través de la aplicación Phyphox en el teléfono celular, allí se puede visualizar un pico en 21,6 Hz mostrando donde más se concentra la energía de la señal, de esta forma es posible ver información de la señal que en la temporal no se puede percibir

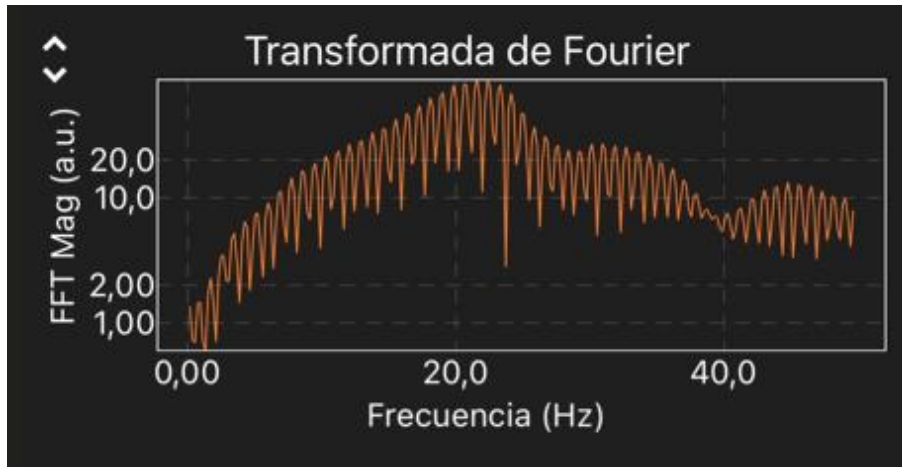


Figura 3-1: Transformada de Fourier para señal de vibraciones (Fuente Propia)

Mediante la aplicación Phypbox en el modo espectro de audio, fue posible generar la transformada rápida de Fourier a las señales de vibración medidas. Gracias a esta herramienta fue posible identificar las bajas frecuencias presentes en las señales y seguir construyendo la ruta de datos requeridos para la adecuada caracterización de los modos de operación de la bomba y su comportamiento ante las diferentes referencias analizadas.

3.3 ESPECTROGRAMAS

Posteriormente se realizó la transformación por espectrograma buscando obtener mejores descripciones de la señal en su aspecto temporal, frecuencial y de amplitud de la variable medida.

El espectrograma es una herramienta que permite visualizar la estructura de las señales en ventanas de tiempo expresándolas a través de espectros de frecuencia. Permite desplegar las características de las señales como inicios agudos, pulsos de campo, trayectorias y contenido de energía con una visibilidad muy clara

Para su construcción será necesario descomponer la amplitud de la señal en segmentos discretos de tiempo que serán llamados las ventanas. Estas columnas contienen la cantidad en densidad espectral que posee la señal en un intervalo de frecuencia.

Cuando estas ventanas se combinan en el espectrograma será necesario atenuar sus proximidades con técnicas como el traslape, el cual entre mayor sea mayor será la facilidad de visualización del espectro. Esto se representará en una mayor cantidad de transformadas de Fourier a realizar y por consiguiente una mayor demanda computacional [28].

La Figura 3-2 se obtuvo a partir de la misma señal de la Figura 3-1, allí se puede apreciar la mayor concentración de energía en los 21 Hz de frecuencia, viendo allí las variaciones de frecuencia presentes en la señal y su intensidad en el tiempo medido.

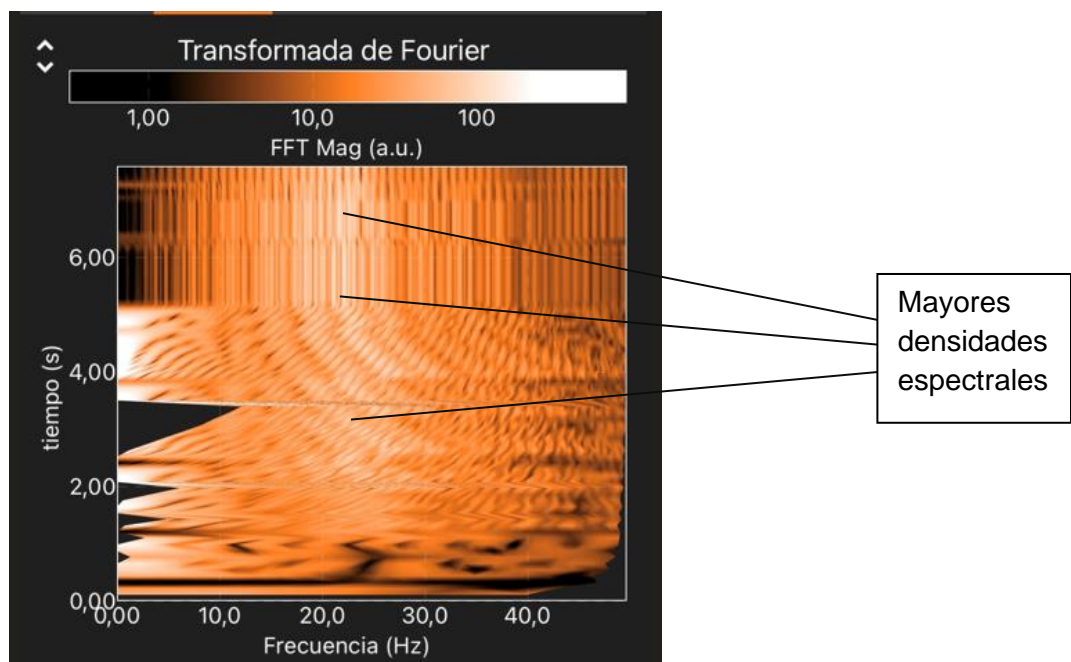


Figura 3-2: Espectrograma creado a partir de señal de vibraciones (Fuente Propia)

Fuente: propia

Cada una de las matrices con los datos almacenados de las mediciones, fue transformada mediante la función espectrograma de Matlab. A partir de esta función, se construyeron imágenes con un tamaño de 224 por 224 por cada una de las mediciones tomadas en vibraciones, campos magnéticos, emisiones acústicas y emisiones ultrasónicas.

En las imágenes puede apreciarse el espectrograma generado a partir de la señal temporal de la medición en el campo magnético de la bomba (Figura 3-3), es notorio el gran contenido espectral debido a las altas energías frecuenciales presentes en las señales obtenidas por esta técnica (Figura 3-4).




Figura 3-3: Señal temporal de campos magnéticos (Fuente Propia)




Figura 3-4: Espectrograma creado a partir de señal de campos (Fuente Propia)

3.4 ESCALOGRAMAS

Otra técnica de descripción utilizada es la transformada de ondículas, la cual permite graficar cada una de las señales tomadas en una expresión de tiempo y frecuencia obteniendo una expresión visual de cada muestra tomada. Las ondículas facilitan la identificación de los instantes que presentan mayores frecuencias en la señal gracias a la comparación a diferentes escalas realizada entre la ondícula madre y la señal evaluada. De esta forma se grafican las diferentes intensidades por escalas entre mayor o menor sea la similitud de las ondas.

La aplicación de esta técnica presenta mejores resultados para el análisis de señales transitorias que la transformada de Fourier, ya que facilita el análisis de la señal en los dominios de tiempo y frecuencia a la vez y además se enfoca en las principales frecuencias para una mejor identificación.

Tomando las matrices de vibración y campos magnéticos con los datos temporales medidos, se aplicó la técnica de filtro continuo cwt del programa Matlab. Las características del filtro fueron las siguientes:

- Función madre: Morse. (por defecto en Matlab)
- Largo señal: 512
- Voces por octava: 12
- Frecuencia de muestreo: 100 Hz
- Ancho de banda: 60 (por defecto en Matlab)

En las imágenes se puede ver una señal temporal de vibraciones (Figura 3-5) y posteriormente su transformación mediante el escalograma de ondículas (Figura 3-6). Se pueden identificar las mayores frecuencias de la señal gracias a la destacada descripción realizada por esta técnica.

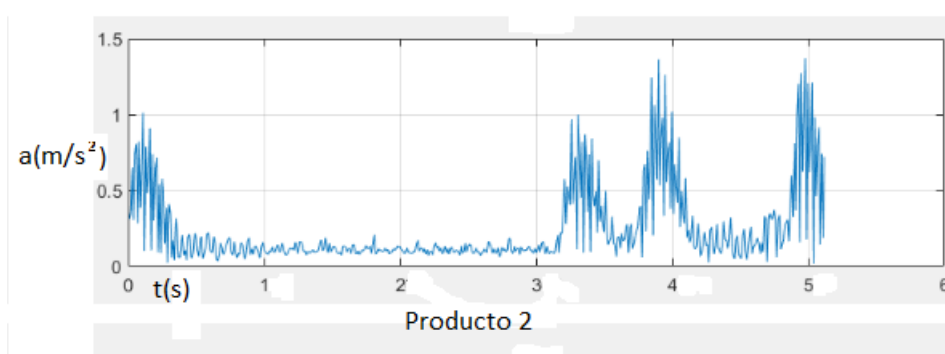


Figura 3-5: Señal temporal de vibraciones (Fuente Propia)




Figura 3-6: Escalograma continuo creado a partir de señal de vibraciones (Fuente Propia)

Esta técnica permitió la transformación de las señales de vibración y campos magnéticos entregando 90 y 70 imágenes respectivamente, que gracias a la longitud en la temporal de 512 permitió desarrollar la técnica en un computador convencional sin ningún inconveniente

de procesamiento, algo diferente al utilizar las técnicas de emisiones acústicas y ultrasónicas, las cuales respectivamente poseen una longitud de 400.000 y 295.000 datos.

Lo anterior generó la necesidad de aplicar el filtro discreto dwt, el cual entrega información menos detallada de las muestras en las bajas frecuencias pero que facilita la rapidez computacional en la transformación de las señales debido al gran tamaño de estas.

Así, se llevó a cabo la transformación discreta de wavelet en multiniveles mediante el programa Matlab, para señales de grandes longitudes sin requerir de una cantidad de procesamiento adicional. Los argumentos de entrada para la descomposición fueron:

- Nivel de descomposición: 5
- Onduleta ortogonal: Daubechies db1

Las imágenes muestran una de las señales temporales de ultrasonidos (Figura 3-7), y su posterior transformación por un escalograma discreto (Figura 3-8), es posible notar la diferencia al graficar un escalograma continuo y su nivel de detalles contra el discreto que generaliza más la señal para representarla en los cinco niveles predeterminados.





Figura 3-7: Señal temporal de ultrasonidos (Fuente Propia)



**Figura 3-8: Escalograma discreto creado a partir de señal de ultrasonidos
(Fuente Propia)**

Gracias a el comportamiento impulsivo de los picos generados en las diferentes señales al realizar el proceso de inyección, se puede concluir que el método que mejor describe las señales es el escalograma, que gráficamente permitió identificar las referencias comparadas, y sus variaciones de frecuencia en el tiempo de la inyección. Esto nos llevará a un proceso de clasificación más preparado y analizado previamente, gracias a las técnicas de descripción desarrolladas.

4 ENTRENAMIENTO NO SUPERVISADO

A partir de las matrices construidas de las con los descriptores temporales de vibraciones y los ultrasonidos, se realizará una reducción dimensional de las señales con diferentes herramientas para simplificar las muestras tomadas, posteriormente se le aplicará una etapa de agrupamiento a la información obtenida de acuerdo con sus características, y finalmente se desarrollará un algoritmo de entrenamiento para una red neuronal de identificación de patrones que clasificará la información obtenida. De esta forma se desarrollará toda una estrategia de entrenamiento no supervisado que permitirá continuar con el análisis y clasificación de los diferentes modos de operación de las bombas de pistones.

4.1 TÉCNICAS DE REDUCCIÓN DIMENSIONAL

En búsqueda de realizar una disminución en las características de las señales tomadas y de singularizar las muestras para un mejor análisis y preparación para la etapa de clasificación sin pérdida en la información tomada, se aplicaron técnicas de visualización y clasificación no supervisada como el PCA, TSNE-E y UMAP.

Los vectores construidos a partir de los descriptores temporales de vibraciones analizaron haciendo una reducción de sus características. A través del programa Python se crearon los programas para la reducción y se ingresaron instrucciones para graficar los resultados.

4.1.1 PCA

Debido a la alta complejidad en la distribución de los datos tomados de las bombas de pistones axiales, se agrupará la información mediante el Análisis de Componentes Principales (PCA) el cual reduce una inmensa cantidad de información en datos correlacionados en un espacio que permita una mejor visualización de los eventos [30]. Con el PCA se simplifica una gran cantidad de datos garantizando la conservación de la información. Estos componentes se consiguen gracias a la combinación lineal de los datos iniciales a través de sus varianzas.

Con esta técnica se clasifican subespacios con las características principales de los datos tomados maximizando la varianza entre los ejes, se calcula la matriz de covarianza con la que se obtienen los vectores y los valores propios, se organizan de mayor a menor para eliminar los elementos no significativos y obtener finalmente los componentes principales que representan la mayor variabilidad [31].

La herramienta utilizada para la construcción del PCA será Python, donde se construirá el algoritmo para la extracción de las componentes principales gracias a la función *pca.fit_transform*. Se definió para ambos casos extraer 3 componentes principales, ya que entregaron el mayor porcentaje en representación del total de los datos para ambos casos.

Para la reducción realizada en las señales de vibraciones, se extrajeron las 3 variables principales donde el primer componente representa el 77.78 % del total de los datos, el segundo componente el 12.67 % y el tercer componente 6.28 %, para sumar un total de 96.75% de representación total de la base de datos inicial. En los ultrasonidos la distribución

también se realizó entre los tres componentes distribuidos en 48.2 %, 39.62% y 11.01 %, para un total de datos explicados por la herramienta del 98.84 %.

A partir de la aplicación de esta técnica se construyó una nueva base de datos expresada en sólo tres componentes, así se obtuvo la primera etapa del aprendizaje no supervisado que continuará con una etapa de agrupamiento después de conocer otros dos métodos de reducción.

4.1.2 TSN-E

La distribución estocástica de puntos más cercanos (TSN-E) fue introducida desde 2008 por Van der Maaten y Hinton buscando lograr el escalado de datos multidimensionales. Esta técnica permite escalar datos de diferentes dimensiones de una forma sencilla, por lo que es muy utilizada actualmente en el diseño de las máquinas de aprendizaje.

A diferencia del PCA que genera grandes distancias entre los componentes a través de la maximización de la varianza, el t-SNE sólo crea distancias pequeñas entre los pares generados beneficiando la visualización de señales no lineales. Esto lo consigue realizando una distribución de la probabilidad en similitudes de parejas de datos, posteriormente traslada los puntos de alto valor con los de bajo valor de manera aleatoria, para finalmente buscar reproducir la distribución inicial sobre la final con el número de datos cercanos o coincidentes.

Finalmente, se utiliza la distribución de probabilidad con un grado de libertad para evitar la superpoblación en los datos y permitir una visualización en un espacio de dos o tres dimensiones [32].

Gracias a Python se desarrolló la técnica del t-SNE reduciendo las bases de datos de vibraciones y ultrasonidos a dos variables principales mediante la función `TSNE(random_state=RS).fit_transform`. Así se construyó una nueva base de datos con dos variables principales que permitirán visualizar de una mejor manera los datos al llevarlos a la etapa de agrupamiento.

4.1.3 UMAP

El algoritmo de aproximación y proyección de datos uniformes (UMAP) permite también una ligera separación entre grupos similar al t-SNE y también desempeña mejores resultados en la reducción de señales no lineales en su dimensión original como en bajas dimensiones. A diferencia del t-SNE, el UMAP realiza su cálculo a mayor velocidad y mejora la preservación de la estructura original de los datos.

El UMAP construye una gráfica que representa las altas dimensiones de los datos y posteriormente optimiza un gráfico con las bajas dimensiones buscando la mayor similitud posible, finalmente se extiende un radio que conecta los datos minimizando las distancias críticas, hasta conectar todos los datos disminuyendo las conexiones entre vecindades y garantizando que no se pierda la estructura original.

Para aplicar esta última técnica de reducción, se desarrolló en Python el algoritmo a través de la biblioteca Umap de *Scikit-learn*, obteniendo una nueva base de datos que se podrá identificar gráficamente en la siguiente etapa del proceso.

Después de desarrollar los algoritmos de reducción dimensional de los datos, se combinará con la estrategia de agrupamiento, que permitirá complementar, visualizar y concluir lo referente a la información obtenida de la bomba y su posterior etapa de clasificación.

4.2 AGRUPAMIENTO DE LOS DATOS

Continuando a la aplicación de los métodos de reducción dimensional, se complementó el proceso visto previamente con el agrupamiento por similitud de características de los datos tomados, para esto se utilizaron combinaciones de los métodos de reducción dimensional con el método de agrupamiento K-means como se verá a continuación.

4.2.1 K MEANS

El K-medias (K-means) es uno de los más simples y eficientes algoritmos de agrupamiento no supervisados [35] que permite generar grupos de datos con propiedades similares [34] distribuyendo los datos en k grupos al minimizar la varianza entre cada grupo [33].

Esta técnica se basa en la partición de los datos buscando hallar un número especificado de clases representadas por sus centroides [32], la distancia se toma como una medida de la similitud entre los datos obtenidos (entre menos distancia mayor similitud) [36].

Para iniciar con el desarrollo del algoritmo será estrictamente necesario definir el número de grupos definidos para la clasificación el cual será el valor K de la clasificación [33,34,35,36], así como la métrica que se manejará para definir la similitud de los elementos y obviamente la matriz de datos de entrada del sistema [33,35].

Posteriormente se deben seleccionar las coordenadas iniciales para la clase central [34,36], asignar cada vector descriptor a una clase como una distancia euclidiana entre ese valor y la clase central, la cual deberá ser la más baja de todas; y finalmente calcular las coordenadas de las nuevas clases [34] repitiendo hasta que se tenga convergencia en los valores medios de las clases [36].

Finalmente se obtiene una reducción en la distancia métrica entre los centros de los elementos de cada clase y los datos adquiridos, así el resultado será una máxima homogenización en las clases [34].

Para obtener un mejor resultado es recomendable remover los datos incorrectos o atípicos de la clasificación construyendo una base de datos mejorada. Si la nueva cantidad de datos representa más del 75% de los datos originales podemos proceder al siguiente paso con la clasificación supervisada, de no ser así debe repetirse y replantearse el K means hasta que se obtenga un mejor resultado [36].

En esta etapa, a las señales temporales de vibraciones y ultrasonidos de las que se extrajeron los diez descriptores temporales, se les realizó una reducción dimensional mediante el PCA, el TSN-E y el UMAP (como se vio en el capítulo anterior) para generar una nueva base de datos de menor tamaño, simplificando la información medida en la bomba. Esta información resultante se tomó como los datos de entrada para el K-Means.

Se creó un primer K-means sólo con las etiquetas originales de los datos de vibraciones que facilitará identificar la distribución original como se puede ver en la gráfica izquierda de la Figura 4-1. Se puede ver como el eje del pca1 en su centro representa la mayoría de los datos, seguido por el pca2 y finalmente complementados en una menor representación por el pca3. Posteriormente se agruparon los datos reducidos gracias al K-means para representar el agrupamiento final realizado por la herramienta, dando como resultado lo visto en la gráfica derecha de la Figura 4-1. Se obtiene una base de datos agrupada, pero que presenta superposición de datos en las tres clases generadas, presentando alta probabilidad de confusión entre dos productos principalmente (amarillo y verde).




Figura 4-1: Comparativo de imágenes PCA, K-Means de vibraciones (Fuente Propia)

El otro PCA desarrollado (ultrasonidos), se graficó también con las etiquetas originales y después del agrupamiento mediante el K-means, donde cada componente principal representa un eje del gráfico (Figura 4-2). La mayor representación se puede apreciar en

el centro del eje del pca1, seguido por el pca2 y finalmente el pc3 que complementa la reducción.

Se realizó también el K-means con la base de datos creada a partir del PCA y se graficó en tres dimensiones donde se puede ver también que el agrupamiento final no permite separar completamente las clases, teniendo varios puntos de superposición.

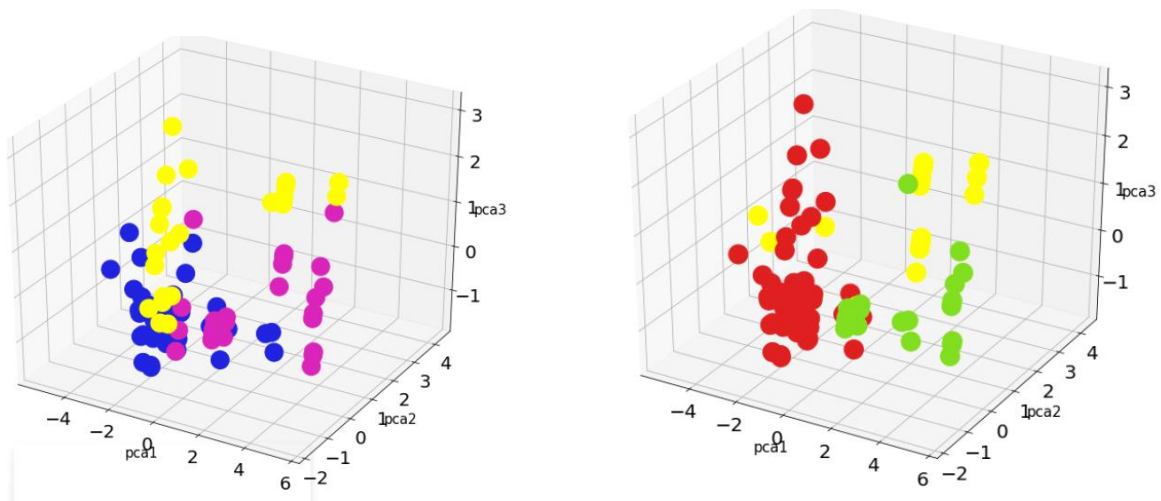


Figura 4-2: Comparativo de imágenes PCA, K-Means de ultrasonidos (Fuente Propia)

Se realizó la misma actividad para comparar los datos originales y los agrupados después de aplicar el t-SNE visualizándolos por medio de gráficas en dos dimensiones.

Se graficaron los datos de vibraciones agrupados sólo con la información de las etiquetas para conocer su distribución original al agruparlos con el K-means (Figura 4-3). Es posible identificar la reducción de componentes entre los dos ejes representados, donde una de las clases presenta características diferentes y fácilmente perceptibles (amarillo).

Posteriormente se graficó el agrupamiento realizado por el K-means a los datos reducidos, donde en este caso se pueden diferenciar una misma clase diferencial pero otras dos que no permiten una gran separación entre sí.




Figura 4-3: Comparativo de imágenes t-SNE, K-Means de vibraciones (Fuente Propia)

Lo mismo se hizo con los datos reducidos de los ultrasonidos, viendo inicialmente el agrupamiento de las etiquetas originales ubicadas en los dos ejes que representan las componentes generadas (Figura 4-4).

Para la distribución de los datos de ultrasonidos reducidos por el t-SNE a tres características y agrupados por el K-means, se ve un resultado mejorado en el agrupamiento con esta combinación, pero donde la separación entre clases no es totalmente clara.




Figura 4-4: Comparativo de imágenes t-SNE, K-Means de ultrasonidos (Fuente Propia)

Las últimas combinaciones serán mediante el UMAP y el K-Means donde se visualizará inicialmente la distribución de los datos de vibraciones teniendo en cuenta sólo las etiquetas de los datos (Figura 4-5). Es visible la diferencia marcada por los datos de una clase (amarillo) frente a los dos restantes que no permiten apreciar diferenciación entre ellas.

A la derecha se graficará la distribución de los datos después de la reducción y el agrupamiento con el K-means. Se aprecia una misma clase diferencial (rojo) mientras que mejora la separación entre las otras dos, a pesar de que no lo suficientemente separadas como se podría esperar para un adecuado proceso de clasificación.




Figura 4-5: Comparativo de imágenes UMAP, K-Means de vibraciones (Fuente Propia)

Para finalizar esta etapa, se realizó la misma combinación UMAP-K-Means con los datos de las etiquetas de ultrasonidos (Figura 4-6). Las dos zonas donde se distribuyen los datos no permiten marcar una separación clara entre los datos.

Como complemento se graficará la distribución final después de agrupar con el K-Means los datos reducidos a dos componentes por el UMAP. La distribución de las dos clases mejora la distribución original y genera una clase que diferencia(rojo), igual que lo visto con las vibraciones, el agrupamiento de las otras dos clases mejora pero no tiene una frontera clara de separación.




Figura 4-6: Comparativo de imágenes UMAP, K-Means de ultrasonidos (Fuente Propia)

El uso de estas técnicas no supervisadas de reducción permite concluir que estos tipos de señales temporales no fueron distribuidos en grupos homogéneos como para concluir que a partir de esta reducción se puede proceder a un proceso de clasificación completamente eficiente debido a sobreposición y fronteras no muy bien marcadas entre clases, lo que puede generar confusión en un clasificador no supervisado. La conclusión a esta hipótesis se verá en el siguiente capítulo.

4.3 CLASIFICADORES

Para cerrar la etapa de entrenamiento no supervisado, se implementarán dos técnicas de clasificación mediante redes neuronal y árboles de decisión. Con estas técnicas se obtendrán datos de la eficiencia en la clasificación de la información obtenida para validar la identificación en las condiciones de operación de la bomba de pistones.

4.3.1 REDES NEURONALES DE CLASIFICACIÓN

Una red neuronal es un modelo computacional conformado por diferentes líneas conectadas entre sí y recibiendo información de forma paralela, compuestas procesadores de señales simples llamados neuronas. Estas neuronas deberán ser entrenadas con ejemplos para que, al momento de recibir una señal de entrada, entreguen un valor de salida modificado.

Un vector ingresa a las neuronas de primer nivel y se multiplica por el valor del peso de la neurona con la que interactúa, posteriormente saldrá a la siguiente capa de neuronas después de pasar por una función limitadora, la cual se utiliza para que el valor ingresado al vector no supere la capacidad de la siguiente neurona. Este vector resultante se irá sumando a un vector consolidado al final que será el producto resultante del sistema de clasificación [38].

Para clasificar las bases de datos obtenidas después de la reducción y el agrupamiento, se aplicará la implementación de una red neuronal de reconocimiento de patrones (patternnet) creada desde Matlab, la cual se configuró con los siguientes parámetros:

- Método de aprendizaje: Regularización bayesiana
- Función de desempeño: Error cuadrático medio (MSE)
- Épocas: 31
- Capas ocultas 10
- Función de activación: Sigmoide
- Capas de salida: 3

Se ingresaron las matrices obtenidas con el desarrollo de las técnicas previas utilizando la herramienta Matlab como ambiente de trabajo. El algoritmo para el desarrollo de la red se realizó así:

- 1 Se ingresaron las matrices de entrada y se creó una matriz adicional en código binario para la identificación de las clases referentes a cada muestra.

- 2 Los datos fueron distribuidos de la siguiente forma: 70% de los datos para entrenamiento, 15% para validación y el 15% restante para la evaluación de la red.
- 3 Posteriormente, se procedió con el entrenamiento de la red con tiempos promedio de 30 a 40 segundos.
- 4 Finalmente, con la partición de datos para evaluación, se midió el desempeño de cada algoritmo de acuerdo con el porcentaje de exactitud en la clasificación de estos datos (fiura).

Estos resultados de exactitud permitieron identificar que los valores más altos fueron obtenidos al clasificar los datos de vibraciones después de una reducción dimensional por el t-SNE y el UMAP. Lo anterior coincide con la conclusión que se tuvo en el proceso de agrupamiento, al identificar más separación entre clases gracias a la combinación de estas técnicas de reducción con el K-means.

Para medir la calidad en las predicciones realizadas por los clasificadores supervisados y no supervisados será la exactitud (*accuracy* en inglés). Mediante este indicador se mide la cantidad de predicciones correctas definido así:

$$\text{Exactitud} = \frac{\text{Número de predicciones correctas}}{\text{Número total de predicciones}} \quad (1)$$

Las medidas de desempeño de las redes al momento de medir la exactitud en la clasificación realizada por cada una de las combinaciones de las diferentes técnicas (Tabla 4-1), muestran mejores resultados en las vibraciones con reducción de t-SNE y UMAP, debido a que su buen desempeño en reducción de características a señales no lineales es más marcado que el realizado por el PCA para este tipo de datos, según se indicó en la teoría expuesta previamente.

Tabla 4-1: Comparativo de resultados en exactitud de clasificación para entrenamiento no supervisado (Fuente Propia)

TÉCNICA	PCA- KMEANS- PATTERNET	TSNE- KMEANS- PATTERNET	UMAP- KMEANS- PATTERNET
Vibraciones	73.3%	85.7%	82.9%
Emisiones ultrasónicas	14.3%	76.9%	76.7%

Aunque los resultados de clasificación son aceptables en la mayoría de las combinaciones hechas, los algoritmos han demostrado que pueden clasificar los datos obtenidos reduciendo y agrupando la información entregada, sin requerir de un etiquetado de estos. Será necesario comparar con los algoritmos supervisados y validar cuál será el más conveniente al momento de identificar los modos de operación de las bombas de pistones axiales.

5 ENTRENAMIENTO SUPERVISADO

El entrenamiento supervisado permite generar un sistema de clasificación a partir de una serie de datos de entrada, una función de tratamiento y unos datos de entrenamiento esperados para entregar unas etiquetas de clase como resultado final.

La etapa de entrenamiento será crucial al momento de poner a punto el sistema, y de obtener la separación de clases requerida para cumplir el objetivo, será necesario conocer entre los diferentes tipos de entrenamiento supervisado existente para el cumplimiento de la necesidad requerida [37].

Avanzando con los procesos de entrenamiento y de identificar el clasificador que mejor pueda identificar las condiciones de operación de la bomba de pistones, se entrenará nuevamente la red patternnet para evaluar su desempeño frente a un entrenamiento supervisado, se aplicará también el árbol de decisión buscando reglas no complejas y sin cálculo de altos costos operacionales. En el capítulo también se explorará con redes convolucionales construidas a partir de las descripciones gráficas realizadas aprovechando las características de las señales iniciales en el dominio de la frecuencia y el tiempo.

5.1 VALIDACIÓN CRUZADA

Es una técnica utilizada para validar la calidad de un modelo de clasificación ya que, dada la naturaleza estocástica de los datos, las variables y parámetros que lo constituyen, no siempre se tienen buenos resultados en el desempeño del modelo. Con la validación cruzada se garantiza independencia y un mejor uso de los datos de prueba y los datos de entrenamiento.

Para una correcta validación, el total de los datos deberán ser divididos en un conjunto de datos de entrenamiento y prueba, y un conjunto de datos de validación (a veces llamados de optimización); posteriormente el conjunto de datos de prueba se divide en subconjuntos que se utilizarán para evaluar el desempeño del modelo. Se repetirá el procedimiento de forma que cada muestra sea diferente cada vez en los datos de prueba y el error de predicción obtenido se almacenará para la comparación con las nuevas muestras.

La validación cruzada entrega un rango de error confiable cuando el procedimiento completo de validación ha finalizado y se han comparado todos los resultados [40].

Mediante el programa Matlab, se desarrolló la validación cruzada buscando mejorar los resultados del árbol de decisión que se verá en este capítulo.

5.2 RED NEURONAL NN USANDO DESCRIPTORES TEMPORALES

La red neuronal de reconocimiento de patrones aplicada en el entrenamiento no supervisado se utilizará en este caso para clasificar las señales temporales obtenidas gracias a los descriptores temporales de las señales de vibraciones, campos magnéticos,

emisiones acústicas y de ultrasonido. Con una configuración de la red similar a la vista en el capítulo anterior, se procedió con el proceso de entrenamiento siguiendo el mismo paso a paso realizado en el entrenamiento no supervisado.

El entrenamiento de la red a partir de los descriptores temporales entrega mejores resultados en la exactitud de la clasificación en las emisiones ultrasónicas y las vibraciones (Tabla 5-1), esto indica que las señales temporales para estas técnicas diferencian de mejor manera los modos de operación de la bomba de pistones con este clasificador. Cabe resaltar también que sobresale la mejora en la clasificación de las señales temporales de campos magnéticos, por lo que al parecer es esta la mejor técnica para clasificar sus datos.

Tabla 5-1: Comparativo de resultados en exactitud de clasificación para entrenamiento no supervisado con red NN (Fuente Propia)

TÉCNICA	PATTERNET
Vibraciones	92%
Campos magnéticos	80%
Emisiones acústicas	66%
Emisiones ultrasónicas	95%

5.3 ARBOLES DE DECISIÓN

Un árbol de decisión es un algoritmo basado en un sistema de clasificación de una gran cantidad de variables que permite realizar predicción entre un determinado número de datos sin requerir de una estructura compleja. Su distribución se da a través de ramificaciones que construyen una figura igual a la de un árbol con raíces y hojas al final.

Esta técnica selecciona la característica que mejor representa la base de datos, y a partir de este dato construye las divisiones posteriores. De acuerdo con la entropía, definida como la aleatoriedad presente en la base de datos de entrada, se calculan las mayores similitudes entre los datos y se establece el mejor desempeño de predicción del árbol de decisión, por ello entre menor sea la entropía más eficiente será la herramienta.

Si el tamaño de la muestra es demasiado grande será necesario dividir entre bases de datos de validación y de entrenamiento, las cuales permiten decidir el tamaño adecuado del árbol y los resultados esperados para el modelo [39].

Será una adecuada herramienta para utilizar en la presente tesis después de definir los nodos principales, las ramas, las particiones y la complejidad requerida de acuerdo con los datos ya clasificados en la etapa anterior.

Para complementar las redes utilizadas se implementó también la clasificación mediante el árbol de decisión construido a partir de los datos obtenidos por los descriptores temporales.

La metodología utilizada para el desarrollo del árbol fue el siguiente:

- Se utilizó como herramienta la aplicación *Classification Learner* del programa Matlab
- Se tomaron como datos de entrada las matrices creadas al desarrollar los descriptores temporales a partir de las señales medidas en la bomba donde se incluyen 9 variables ingresadas.
- Las categorías incluidas fueron los 3 de productos medidos referenciando cada muestra ingresada

- Se realizó validación cruzada con cinco iteraciones para evitar sobre entrenamiento del árbol
- El árbol se configuró con 100 nodos internos y su criterio de división fue el índice de impureza de Gini.
- De allí se tomó la opción *Fine Tree* y se procedió con el entrenamiento del clasificador.

A continuación (Tabla 5-2), el resumen de los datos obtenidos en las medidas de exactitud del árbol al momento de evaluar la clasificación de los datos medidos donde continua la misma tendencia de resultados de las técnicas previas con mejores resultados en las técnicas de vibraciones y ultrasonidos. Esto muestra que las señales temporales descritas benefician el proceso de clasificación de las medidas de vibraciones y emisiones acústicas mediante algoritmos de estructuras no complejas.

Tabla 5-2: Comparativo de resultados en exactitud de clasificación para entrenamiento no supervisado con árbol de decisión (Fuente Propia)

TÉCNICA	ÁRBOL DE DECISIÓN
Vibraciones	75.6%
Campos magnéticos	57.1%
Emisiones acústicas	62%
Emisiones ultrasónicas	89%

5.4 REDES PROFUNDAS

Después de ver las redes anteriores, el siguiente paso a seguir en el desarrollo de entrenamiento supervisado es la implementación de redes profundas que incluyan casos de clasificación tomando las muestras obtenidas con el procesamiento con espectrogramas y escalogramas.

5.4.1 ENTRENAMIENTO SUPERVISADO CON ESPECTROGRAMAS

Tomando como datos de entrada para el desarrollo de la red profunda, se implementaron los espectrogramas obtenidos en la transformación realizada a las señales de vibraciones en la bomba de pistones.

Para la Figura 5-1 se tomaron 3 muestras de espectrogramas de vibraciones generados por cada una de las clases o modos de operación ingresados, estas imágenes serán clasificadas por una red neuronal convolucional desarrollada en Matlab para la identificación de los casos.




Figura 5-1: Comparativo de espectrogramas de vibraciones (Fuente Propia)

Utilizando el diseñador de redes profundas de Matlab (Deep Network Designer), se creó una red neuronal convolucional que pueda identificar las distintas características en los datos de entrada a través de sus diferentes capas, aprenderlas y después clasificarlas de acuerdo con su etiqueta de origen.

Como su nombre lo indica, la red realiza convoluciones que consisten en tomar un grupo de píxeles de la imagen, modificarla matemáticamente contra una matriz de kernel y generar una matriz de salida, a esta matriz se le aplica una función de activación y una reducción de tamaño conservando las principales características. Así se realizan convoluciones hasta llegar a la última capa la cual se convierte a una red multicapa, y finalmente se conecta mediante una función a la capa de salida que tendrá el número de clases a definir.

A continuación, el proceso realizado por el algoritmo para el desarrollo de la red neuronal profunda:

- A la red profunda se ingresaron como 90 espectrogramas de los tres productos diferentes medidos con las vibraciones de la bomba.

- Estas imágenes almacenadas con un tamaño de 224 por 224 píxeles fueron sometidas a una partición aleatoria de datos de entrenamiento y validación de un 80 y 20 por ciento respectivamente.
 - Posteriormente se crea la red neuronal a utilizar y se ingresan los parámetros principales de entrada para el entrenamiento de la red así:
 - Número de capas: 15
 - Épocas: 32
 - Frecuencia de validación: 7 iteraciones
 - Tasa de aprendizaje: 0.01
 - Función de activación: ReLu
 - Submuestreo: Max-Pooling
 - Función de activación final: Softmax

Se procede a desarrollar el entrenamiento de la red neuronal que tomó 6 minutos con 35 segundos, acompañado del proceso de validación según la frecuencia especificada.

El resultado final en exactitud del proceso de validación de la red para este caso fue de 95.5%, indicando que esta red neuronal profunda con el preprocesamiento previo de los datos de entrada tiene altas probabilidades de clasificar las condiciones de operación de la bomba de pistones.

5.4.2 ENTRENAMIENTO SUPERVISADO CON ESCALOGRAMAS

La segunda red neuronal profunda implementada fue una red convolucional preentrenada en Matlab llamada Googlenet. Los datos por clasificar con esta red fueron los escalogramas de vibraciones generados en la etapa de descripción.

Esta técnica de aprendizaje automático es llamada aprendizaje por transferencia "*transfer learning*", donde se utiliza un entrenamiento ya realizado en la red neuronal gracias a patrones previos de imágenes que no necesariamente pertenecen al proceso.

Generalmente, para garantizar el adecuado desempeño de una red neuronal convolucional es necesario disponer de gran capacidad computacional y de una gran cantidad de datos de entrenamiento, y debido a que en este proceso no se cuenta con estos requerimientos; se optó por aplicar el aprendizaje por transferencia como alternativa para mejora en el rendimiento y clasificación correcta de los escalogramas.

La Figura 5-2 muestra algunos escalogramas de ondículas en vibraciones tomados de los tres productos diferentes que representan las diferentes condiciones de operación de las bombas. Estas imágenes se llevarán a la red convolucional para proceder con el proceso de entrenamiento y clasificación según el producto al que pertenezca.

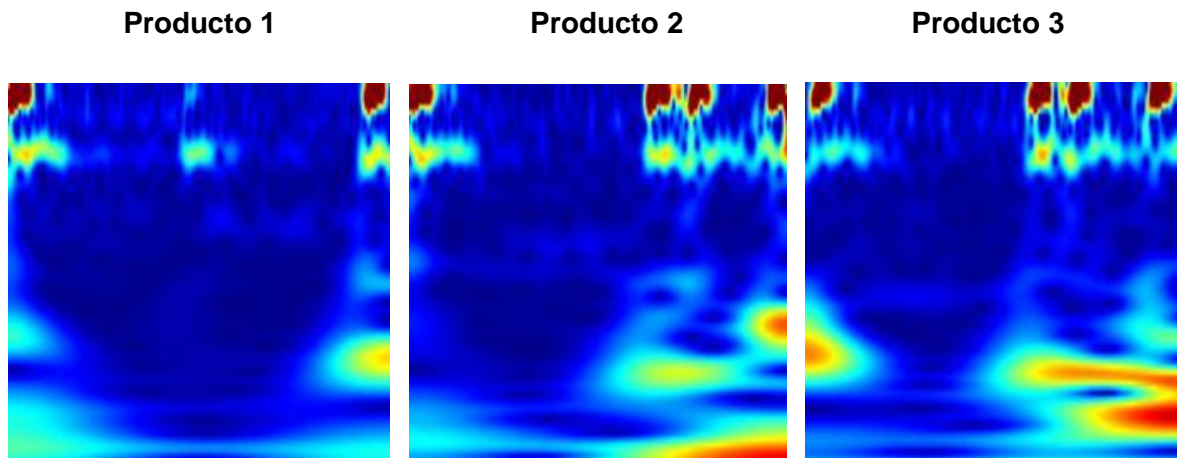


Figura 5-2: Comparativo de escalogramas de vibraciones (Fuente Propia)

Estos fueron los parámetros utilizados en la red Googlenet:

- Número de capas: 144
- Épocas: 20
- Frecuencia de validación: 10 iteraciones
- Tasa de aprendizaje: 0.001
- Función de activación: ReLu
- Submuestreo: Max-Pooling
- Función de activación final: Softmax

El proceso de entrenamiento de la red tomó 12 minutos con 15 segundos, entregando al final un valor de exactitud en la validación de la clasificación de 100%.

Es posible concluir que ambas técnicas de aprendizaje profundo representan alta probabilidad de éxito en la clasificación, y que principalmente las señales de vibraciones generan un alto nivel de confiabilidad en el proceso de clasificación para la identificación de los casos de operación de las bombas.

5.4.3 OTRAS COMBINACIONES

Buscando comparar las técnicas aplicadas, se creó también un entrenamiento por con aprendizaje por transferencia de otra red de Matlab llamada Squeezenet que sólo se diferencia de la anterior por tener 15 épocas y 68 capas.

Se combinaron las cuatro técnicas: vibraciones, campos magnéticos y emisiones acústicas y de ultrasonido, descritas con escalogramas y espectrogramas, y entrenadas con las tres redes profundas mencionadas. De esta forma fue posible comparar los resultados de cada técnica y determinar los más favorables para la identificación de los casos.

Se puede concluir del proceso de entrenamiento realizado con las redes profundas, que los niveles de mejor desempeño en la exactitud de los algoritmos al momento de validar el proceso de entrenamiento fueron mayores utilizando la técnica de vibración; mientras que los campos magnéticos entregan los resultados más bajos (Tabla 5-3). Esto nos indica que las técnicas de caracterización de las señales como herramientas de identificación de los cambios en tiempo y frecuencia de las señales, son más visibles al medir las vibraciones en el equipo, y en sentido contrario al medir los campos magnéticos en el acople bomba motor son más difíciles de percibir por su estabilidad ante las diferentes condiciones de operación del equipo.

Tabla 5-3: Comparativo de resultados en exactitud de clasificación para entrenamiento supervisado con redes profundas (Fuente Propia)

TÉCNICA	TIPO DE IMAGEN	RED PROFUNDA	EXACTITUD
Vibraciones	Escalogramas	Googlenet	100%
Vibraciones	Escalogramas	Squeezenet	100%
Vibraciones	Escalogramas	CNN	100%
Vibraciones	Espectrogramas	Googlenet	94%
Vibraciones	Espectrogramas	Squeezenet	94%
Vibraciones	Espectrogramas	CNN	95%
Campos magnéticos	Escalogramas	Googlenet	44%

TÉCNICA	TIPO DE IMAGEN	RED PROFUNDA	EXACTITUD
Campos magnéticos	Escalogramas	Squeezenet	55%
Campos magnéticos	Escalogramas	CNN	64%
Campos magnéticos	Espectrogramas	Googlenet	36%
Campos magnéticos	Espectrogramas	Squeezenet	36%
Campos magnéticos	Espectrogramas	CNN	40%
Emisiones acústicas	Escalogramas	Googlenet	70%
Emisiones acústicas	Escalogramas	Squeezenet	82%
Emisiones acústicas	Escalogramas	CNN	55%
Emisiones acústicas	Espectrogramas	Googlenet	77%
Emisiones acústicas	Espectrogramas	Squeezenet	67%
Emisiones acústicas	Espectrogramas	CNN	72%
Emisiones ultrasónicas	Escalogramas	Googlenet	84%
Emisiones ultrasónicas	Escalogramas	Squeezenet	77%
Emisiones ultrasónicas	Escalogramas	CNN	81%
Emisiones ultrasónicas	Espectrogramas	Googlenet	94%
Emisiones ultrasónicas	Espectrogramas	Squeezenet	77%
Emisiones ultrasónicas	Espectrogramas	CNN	84%

Como conclusión de la etapa de entrenamiento supervisado es posible determinar que el proceso de realizado con la red NN el resultado más favorable al entrenar con descriptores temporales es dado en los datos de ultrasonido, para los árboles de decisión también sobresale el resultado obtenido al clasificar esta misma técnica. Adicionalmente, al implementar las redes profundas el mejor resultado lo dan las señales de vibraciones tanto para escalogramas como para espectrogramas, siendo estos los mejores resultados de todo el análisis desarrollado.

6. EVALUACIÓN DE METODOS SELECCIONADOS

En búsqueda de dar cumplimiento al cuarto objetivo, y así poder evaluar el desempeño del mejor clasificador desarrollado; se utilizaron como herramientas gráficas para medir los resultados la matriz de confusión y la curva ROC. La aplicación de estas técnicas permitió generar las conclusiones del ejercicio realizado y determinar si las herramientas utilizadas fueron las adecuadas para la clasificación de los datos medidos en la bomba hidráulica de pistones axiales.

Como se vio en el capítulo anterior, los mejores resultados obtenidos en la exactitud de la clasificación para identificar los modos de operación fueron obtenidos con los datos tomados de las vibraciones generadas por la bomba, analizados por escalogramas y espectrogramas y clasificados por las redes profundas, seguidos por los ultrasonidos con descriptores temporales y clasificados por el árbol de decisión y la red NN.

El proceso de evaluación incluirá también la clasificación no supervisada de las señales de vibraciones clasificadas por la red NN, recibiendo los datos agrupados del K-means y reducidos dimensionalmente por el t-SNE.

Con esto se evaluarán los clasificadores con los mejores resultados de esta tesis.

6.1 MATRIZ DE CONFUSIÓN

Una matriz de confusión contiene información sobre valores de datos actuales y valores de datos esperados en un sistema de clasificación supervisado con una gran capacidad de visualización. El desarrollo de este sistema constituye generalmente una matriz de comparación en la cual el número de predicciones se define por las columnas presentes, mientras que los datos reales se determinarán en las filas de la matriz. Las entradas en una matriz de confusión serán los correctos negativos, incorrectos positivos, incorrectos negativos y correctos positivos.

Las principales métricas por manejar en la matriz serán las siguientes:

- Exactitud: Se refiere a lo cerca que esté el valor del verdadero positivo.
- Precisión: Se define como la mínima dispersión de los valores.
- Sensibilidad: Indica la tasa de verdaderos positivos.
- Especificidad: como la tasa de verdaderos negativos [41].

A partir de una correcta evaluación, se podrá definir el mejor sistema de clasificación o conjunto de sistemas de clasificación para el desempeño esperado de la herramienta.

A continuación, el proceso desarrollado para la construcción de la matriz de confusión:

1. Se tomaron las imágenes o las matrices construidas con los descriptores temporales previamente seleccionados en la partición como datos de validación.
2. Estas muestras se clasificaron por medio de la red entrenada.
3. Esta selección realizada entrega unas etiquetas asignadas a cada muestra de acuerdo con la clase a la que pertenecen según el algoritmo lo consideró. Estos son los datos de predicción.
4. La exactitud será el resultado de comparar las clases entregadas en la predicción realizada contra las clases reales de este mismo grupo de datos, esto se expresa en términos del porcentaje.

Con esta información y con la herramienta *plotconfusion* de Matlab, se construyeron las expresiones gráficas de la matriz de confusión y la curva ROC.

Viendo la matriz de confusión de la red Googlenet con escalogramas de vibraciones y la convolucional de espectrogramas en vibraciones (Figura 6-1), se puede afirmar el éxito en la clasificación de los tres productos sólo con una mínima confusión con el producto 2 y el producto 3 que genera una disminución en el desempeño de la segunda red posiblemente por un sesgo generado al tener una mayor cantidad de datos del producto 3.

Clases de salida	Producto 1	4 22,20%	0 0,00%	0 0,00%	100% 0
	Producto 2	0 0,00%	5 27,80%	0 0,00%	100% 0
	Producto 3	0 0,00%	0 0,00%	9 50,00%	100% 0
		100% 0	100% 0	100% 0	100% 0
	Producto 1	Producto 2	Producto 3		

Clases de salida	Producto 1	4 8,9%	0 0,0%	0 0%	100% 0,0%
	Producto 2	0 0,0%	9 20,0%	2 4,4%	81,8% 18,2%
	Producto 3	0 0,0%	0 0,0%	30 66,7%	100% 0,0%
		100% 0%	100% 0%	93,8% 6,3%	95,6% 4,4%
	Producto 1	Producto 2	Producto 3		
	Clases objetivo				

Figura 6-1: Matrices de confusión redes profundas con vibraciones (Fuente Propia)

Para el caso de las emisiones ultrasónicas con sus descriptores temporales en la red NN se da un resultado de exactitud aceptable presentando un error al clasificar al producto 3, mientras que el árbol de decisión con estas mismas técnicas tiene errores promedio de un 10% al clasificar de cada producto (Figura 6-2), por lo que su medida de exactitud final disminuye respecto a las demás redes evaluadas.

Clases de salida	Producto 1	4 21,1%	0 0,0%	0 0,0%	100% 0,0%
	Producto 2	0 0,0%	6 31,6%	0 0,0%	100% 0,0%
	Producto 3	1 5,3%	0 0,0%	8 42,1%	88,9% 11,1%
		80,0% 20,0%	100% 0,0%	100% 0,0%	95,0% 5,3%
	Producto 1	Producto 2	Producto 3		

Clases de salida	Producto 1	12 34,0%	0 0,0%	1 3,0%	92,0% 8,0%
	Producto 2	1 3,0%	6 17,0%	0 0,0%	86% 14%
	Producto 3	0 0,0%	2 6,0%	13 37%	87% 13%
		92% 8%	75,0% 25,0%	93,0% 7,0%	89,0% 11,0%
	Producto 1	Producto 2	Producto 3		
	Clases objetivo				

Figura 6-2: Matrices de confusión red NN y árbol de decisión para ultrasonidos (Fuente Propia)

Finalmente, se aplicó la matriz de confusión para el clasificador no supervisado con las señales de vibraciones, definiendo que la red NN con datos agrupados por el K-means y reducidos por el t-SNE presenta errores al clasificar la etiqueta 1 (Figura 6-3). Las demás etiquetas se clasifican correctamente.

Clases de salida	Etiqueta 1	6 42,9%	0 0,0%	2 14,3%	75,0% 25,0%
	Etiqueta 2	0 0,0%	4 28,6%	0 0,0%	100% 0,0%
	Etiqueta 3	0 0,0%	0 0,0%	2 14,3%	100% 0,0%
		100,0% 0,0%	100% 0,0%	50% 50,0%	85,7% 14,3%
	Etiqueta 1	Etiqueta 2	Etiqueta 3	Clases objetivo	

Figura 6-3: Matriz de confusión red NN con entrenamiento no supervisado para vibraciones (Fuente Propia)

En general, los resultados de las técnicas evaluadas con la matriz responden a un patrón correcto de clasificación con fallos en casos puntuales. Esto se presenta en los clasificadores que toman las señales temporales como datos a identificar, en contraste las imágenes de escalogramas y espectrogramas presentan los mejores datos de evaluación en la matriz.

6.2 CURVA ROC

Es una representación gráfica que determina estadísticamente la exactitud del diagnóstico de una herramienta de clasificación mediante un plano de dos dimensiones atravesado por una curva de separación.

Su objetivo principal será establecer la ubicación del punto de corte de una escala continua donde se tendrán la sensibilidad y la especificidad más altas, medir la capacidad de clasificación del modelo y poder comparar diferentes modelos de clasificación [42].

Con esta evaluación será posible identificar la distribución en la clasificación entre los verdaderos positivos y los falsos positivos y el comportamiento del límite de discriminación en los clasificadores utilizados en la presente tesis, obteniendo un resultado final de validación de los clasificadores aplicados y su adecuado entrenamiento.

Se aplicará este medio de representación para evaluar los algoritmos de clasificación implementados, esto es posible identificando la proporción entre verdaderos positivos y falsos positivos identificados por el algoritmo en el proceso de evaluación de la red neuronal. Para esto se utilizaron las mismas redes neuronales buscando continuar con el proceso de evaluación de los mejores casos de clasificación obtenidos.

Se realizó la comparación del grupo de imágenes de validación, ingresando su etiqueta original y la etiqueta otorgada por el clasificador. Posteriormente se utilizó la función de Matlab *plotroc* que permitió generar la curva ROC de ambos clasificadores.

Se desarrollaron las curvas ROC para las dos mejores técnicas de con redes profundas (Figura 6-4), notando la clasificación perfecta en la primera con un 100% de verdaderos positivos (TPR) y 0% en falsos positivo(FPR). En la segunda red disminuyen los resultados por la confusión presentada en los productos 2 confundiéndolo con el 3.

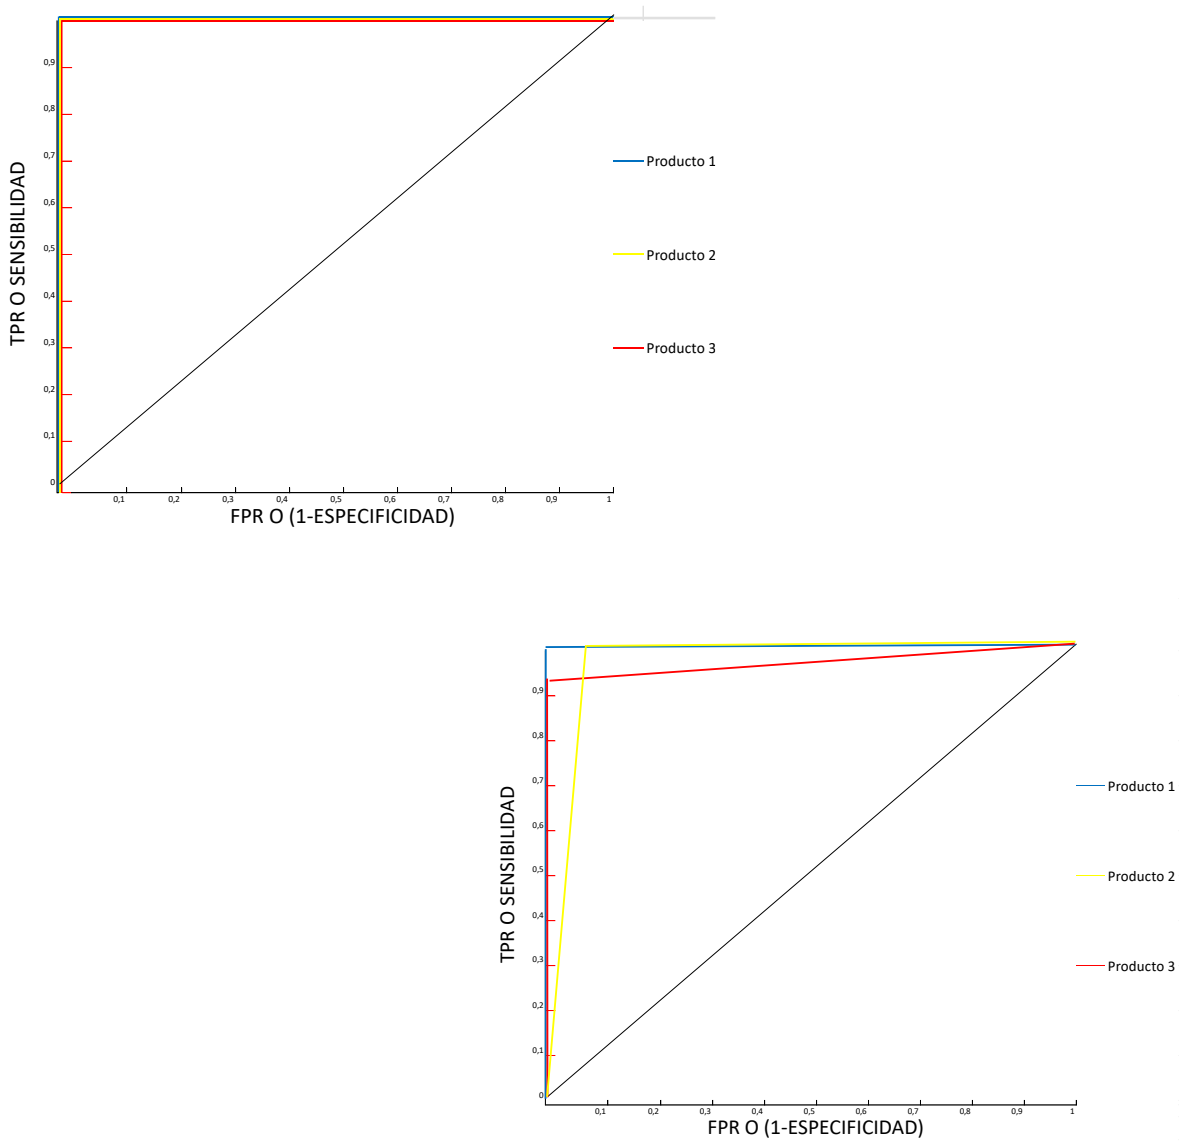


Figura 6-4: Curvas ROC para redes profundas con vibraciones (Fuente Propia)

Las redes supervisadas con descriptores temporales presentan un resultado menor pero adecuado ya que los puntos siguen estando cerca la coordenada (0,1) con un resultado mínimo de TPR del 75% (Figura 6-5).

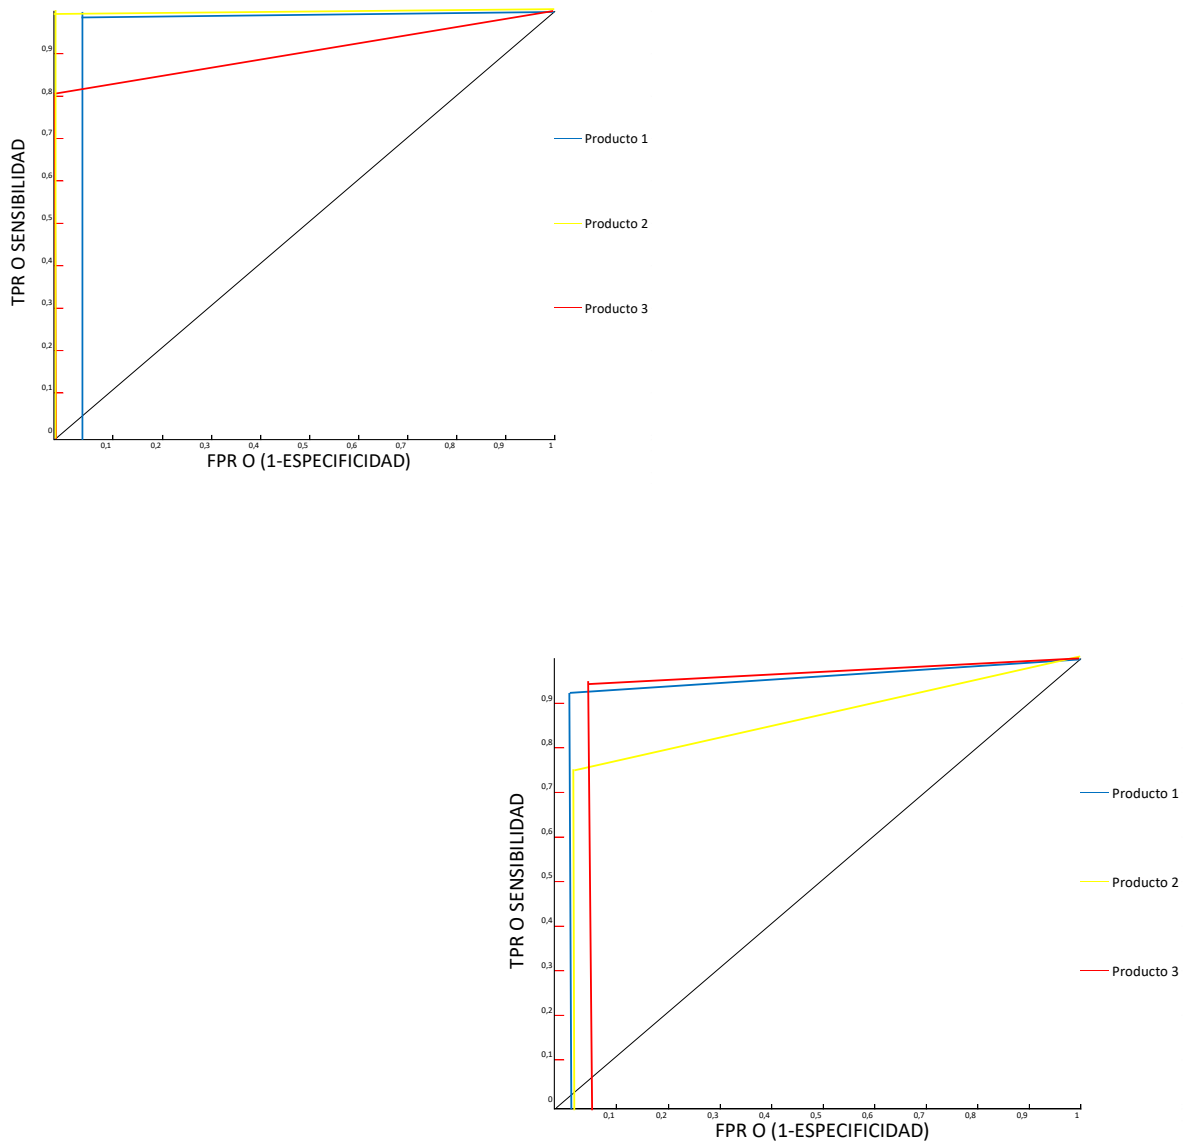


Figura 6-5: Curvas ROC de red NN y árbol de decisión para ultrasonidos (Fuente Propia)

Cerrando con la clasificación no supervisada, se presenta un punto bajo en detección de TPR del producto 3, pero el resultado continúa siendo favorable al estar siempre por encima de la línea diagonal o línea de no-discriminación encargada de definir lo aleatorio de la clasificación, no en estos casos (Figura 6-6).




Figura 6-6: Curva ROC de red NN con entrenamiento no supervisado para vibraciones (Fuente Propia)

Las técnicas de evaluación aplicadas demuestran la efectividad de los clasificadores elegidos en el proceso, y la elevada probabilidad de obtener buenos resultados al momento de clasificar los casos de operación de la bomba de pistones, utilizando las combinaciones ya indicadas para el tratamiento de los datos tomados.

Con este método gráfico de evaluación, es posible definir completamente cuales son los algoritmos más adecuados para identificar los diferentes modos de operación de la bomba de pistones y cumplir con el cuarto objetivo esperado por esta tesis.

7. CONCLUSIONES

Al cierre del desarrollo de la presente tesis se puede concluir que es posible identificar los modos de operación de las bombas de pistones mediante la adquisición de señales, su descripción con diferentes herramientas, clasificación con entrenamiento supervisado y no supervisado y evaluación final del entrenamiento. Esto queda demostrado con resultados exitosos en las señales de vibraciones descritas por medio de escalogramas y espectrogramas, y clasificadas por redes profundas. En una menor medida en las señales de ultrasonidos con descriptores temporales y clasificados por una red NN y un árbol de decisión, y también con los datos de vibraciones a través de estrategias no supervisadas con descriptores temporales reducidos mediante el t-SNE, agrupados por K-Means y clasificados por la red NN. Los demás métodos estudiados entregan en su mayoría resultados correctos en la identificación de las condiciones de operación, pero hemos resaltado los mejores resultados evaluados y adecuados para afirmar la hipótesis propuesta en la tesis.

Cada referencia operada por la máquina inyectora genera diferencias principalmente en las vibraciones generadas por la bomba, lo que facilitó que las señales de aceleración sean más diferentes entre sí para facilitar su proceso de identificación. Los ultrasonidos logran describir los casos de mejor manera cuando se analizan desde su comportamiento temporal, ya que las frecuencias que se detectan con esta técnica no varían mucho entre cada caso de operación analizado.

Las mediciones tomadas presentan impulsos elevados debido a los procesos de cierre y apertura de válvulas, esto hace que las señales tengan un comportamiento impulsivo por lo que la mejor técnica para su descripción son los escalogramas de ondículas que se enfocan en resaltar las principales frecuencias de la muestra. Esta misma característica reduce la

capacidad de identificación de las señales cuando se analizan sólo con su naturaleza temporal ya que no se generan muchas diferencias entre ellas.

Las técnicas no supervisadas pueden identificar las señales temporales y entregan un mejor desempeño al utilizar reductores de características que generan un buen rendimiento con señales no lineales como las tomadas de las bombas. El PCA no consiguió reducir los componentes principales con gran éxito para las técnicas de vibraciones y ultrasonidos, por lo que no se considera adecuado para el análisis de las señales adquiridas en este estudio.

Los algoritmos de entrenamiento supervisado responden de una mejor forma a la clasificación de señales estables en el tiempo cuando se utilizan redes NN y árboles de decisión, cuando las señales presentan cambios impulsivos con constantes variaciones en su frecuencia, las redes convolucionales presentan mejores desempeños al ingresar imágenes de entrada como escalogramas y espectrogramas.

Como conclusión de la etapa de entrenamiento supervisado es posible determinar que el proceso de realizado con la red NN el resultado más favorable al entrenar con descriptores temporales es dado en los datos de ultrasonido, para los árboles de decisión también sobresale el resultado obtenido al clasificar esta misma técnica. Adicionalmente, al implementar las redes profundas el mejor resultado lo dan las señales de vibraciones tanto para escalogramas como para espectrogramas, siendo estos los mejores resultados de todo el análisis desarrollado.

Finalmente, esta tesis resume con éxito la posibilidad de identificar los modos de operación de las bombas de pistones axiales de caudal fijo cuando se utiliza la combinación correcta de técnicas para entrenar un algoritmo de inteligencia artificial que clasifique muestras temporales del equipo operando en condiciones normales de trabajo.

8. BIBLIOGRAFÍA

- [1] Ajit Kumar Pandey, K. Dasgupta, N. Kumar and Alok Vardhan: *“Leakage Analysis of Bent-axis Hydro-motors: An Experimental Study”*. Journal of the Chinese Society of Mechanical Engineers, Vol.38, No.1, pp 93~98 (2017).
- [2] Pavel SRB, Michael Petru: *“Numérica simulation of composite car seat cushion”*. MM Science Journal, june 2020, DOI : 10.17973/MMSJ.2020_06_2020011.
- [3] Carlo Fiorentini, Caronno Pertusella, Maurizio Corti, Caronno Pertusella: *“Method and apparatus for feeding a polyurethane mixture into hollow bodies”*. European patent office, EP2366525A1. Pub. No. US 2011/0221085A1.
- [4] Wanner International Ltd: *“Diaphragm pumps for polyurethane production”*. World Pumps: Volume 2013, Issue 1, Page 8. January 2013.
- [5] RAMPF Group, Inc: *“Dosing pumps for sealing compounds”*. World Pumps: Volume 2009, Issue 519, Pages 20-21. December 2009.
- [6] Kazushige Nakagawa: *“Bent axis type axial piston pump or motor”*. European Patent Office, EP0158084B1. Patent Patent Number:4872394. Date of Patent: Oct. 10, 1989.
- [7] G.S. Highfill, L.A. Halverson: *“Lowering total cost of ownership with breakthrough magnetic torque transfer technology”*. IEEE Xplore. DOI: 10.1109/CITCON.2006.1635720. Cement Industry Technical Conference, 2006. Conference Record. May 2006.
- [8] Jie Tao, Yilun Liu, and Dalian Yang: *“Bearing Fault Diagnosis Based on Deep Belief Network and Multisensor Information Fusion”*. Hindawi Publishing Corporation, Shock and Vibration. Volume 2016, Article ID 9306205, 9 pages August 2016.

[9] Christian Lessmeier, James Kuria Kimotho, Detmar Zimmer, Walter Sextro: “*Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification*“. Conference: European Conference of the Prognostics and Health Management Society At: Bilbao, Spain. July 2016

[10] Hui Huang, Ganyong Wu, Yongyuan Wu, Shumei Chen: “*Identification of acoustic sources for bent-axis axial piston motor under variable loads*“. Journal of Sound and Vibration 468 (2020) 115063. November 2019.

[11] Niloofar Ghareisi, Mohammad Mehdi Arefi: “*Analyzing the Vibration Signals for Bearing Defects Diagnosis Using the Combination of SGWT Feature Extraction and SVM*“. IFAC PapersOnLine 51-24 (2018) 221–227.

[12] Haedong Jeong, Seungtae Park, Sunhee Woo, and Seungchul Lee: “*Rotating Machinery Diagnostics using Deep Learning on Orbit Plot Images*“. Procedia Manufacturing. Volume 5, 2016, Pages 1107–1118.

[13] Miguel Alberto Cabañas: “*Monitorización y clasificación de defectos en rodamientos de bolas*“. Proyecto fin de carrera, Departamento de ingeniería mecánica, Universidad Carlos III de Madrid. 2011

[14] Qinghong Gong, Hui Hunag, Ganyong Wu, Shumei Chen and Heng Du: “*Analysis and application of a new noise test system for the hydraulic motor*“. Journal of Advanced Mechanical Design, Systems, and Manufacturing. Vol.13, No.4. November 2019

[15] B. Sreejith, A.K. Verma and A. Srividya: “*Fault diagnosis of rolling element bearing using time-domain features and neural networks*“. IEEE Region 10 Colloquium and the Third ICIIS, Kharagpur, INDIA December 8-10. DOI: 409. 2008

[16] Djamel Zarour, Salim Meziani, Marc Thomas: “*Experimental studies for bearings degradation monitoring at an early stage using analysis of variance*“ Diagnostyka.. DOI: 10.29354/diag/4, Volume 19, issue 4, pages 81-87. 2008

- [17] Mansour A. Karkouba, Osama E. Gada, Mahmoud G. Rabie: “ *Predicting axial piston pump performance using neural Networks* “. Mechanism and Machine Theory, Volume 34, Issue 8, Pages 1211-1226. November 1999.
- [18] Omar José Lara Castro: “ *Nuevas Metodologías no Invasivas de Diagnósis de Defectos Incipientes en Rodamientos de Bola* ”. Tesis doctoral. Departamento de ingeniería mecánica, Universidad Carlos III de Madrid, 2007
- [19] Paolo Casoli, Mirko Pastori, Fabio Scolari and Massimo Rundo. “ *A Vibration Signal-Based Method for Fault Identification and Classification in Hydraulic Axial Piston Pumps*”. Energies: 12, 953; DOI:10.3390/en12050953. March 2019.
- [20] Mohammadreza Kaji, Jamshid Parvizian, Hans Wernher van de Venn: “ *Constructing a Reliable Health Indicator for Bearings Using Convolutional Autoencoder and Continuous Wavelet Transform* “. Applied Sciences (2076-3417). Vol. 10, Issue 24, p8948. 1p. December 2020
- [21] Paresh Girdhar: “ *Practical machinery vibration analysis and predictive maintenance I title* “. eBook ISBN: 9780080480220. Page 6-10. 2004
- [22] R Keith Mobley: “ *Vibration fundamentals, I title II series*”, page 3-64. Butterworth Heinemann. 1999.
- [23] Vimal Saxena, Nilendu Kar Chowdhury, S. Devendiran: “ *Assessment of Gearbox Fault Detection Using Vibration Signal Analysis and Acoustic Emission Technique* “. IOSR Journal of Mechanical and Civil Engineering. (IOSR-JMCE). Volume 7, Issue 4, PP 52-60. August 2013.
- [24] Frooz Purarjomandlangrudi, Ghavameddin Nourbakhsh: “ *Acoustic emission condition monitoring: an application for wind turbine fault detection* “. International Journal of Research in Engineering and Technology. Volume: 2 Issue: 5 907 – 918. May 2013
- [25] Yi-Chang Wu, Bo-Syuan Jian: “ *Magnetic field analysis of a coaxial magnetic gear mechanism by two-dimensional equivalent magnetic circuit network method and finite-element method* “. Applied Mathematical Modelling, Volume 39, Issue 19, Pages 5746-5758. October 2015

[26] G. C. Neves, A. F. F. Filho: "*Magnetic Gearing Electromagnetic Concepts*". Journal of Microwaves, Optoelectronics and Electromagnetic Applications. DOI: 10.1590/2179-10742017v16i1874. Vol 16, No 1, March 2017

[27] Fausto Pedro García Márquez, Mayorkinos Papaelias: "*An overview of wind turbine maintenance management*". Non-Destructive Testing and Condition Monitoring Techniques for Renewable Energy Industrial Assets. Chapter 3, Pages 31-47. 2020.

[28] Brian E.D. Kingsbury, Nelson Morgan, Steven Greenberg : "*Robust speech recognition using the modulation spectrogram*". Speech Communication
Volume 25, Issues 1–3, Pages 117-132. August 1998

[29] Achraf Lahrache, Marco Coconcelli, Riccardo Rubini: "*Anomaly detection in a cutting tool by k-means clustering and support vector machines*". Diagnostyka Vol18, Issue 3, Pag:21–29. March 2017.

[30] Mengyu Chai, Jin Zhang, Zaoxiao Zhang, Quan Duan: "*Acoustic emission studies for characterization of fatigue crack growth in 316LN stainless steel and welds.*". Applied Acoustics, Volume 126, Pages 101-113, November 2017.

[31] Changsheng Zhua, Christian Uwa Idemudiaa, Wenfang Fengba: "*Improved logistic regression model for diabetes prediction by integrating PCA and K-means techniques*". Informatics in Medicine Unlocked. DOI: 100179. Volume 17. April 2019.

[32] Binu Melit Devassy, Sony George: "*Dimensionality reduction and visualisation of hyperspectral ink data using t-SNE*". Forensic Science International. DOI 110194. Volume 311, June 2020,

[33] Achraf lahrache, Marco coconcelli, Riccardo rubini: "*Anomaly detection in a cutting tool by k-means clustering and support vector machines*". Diagnostyka, vol 18, Issue 3, pag:21-29, December 2016.

[34] Mengyu Chai, Jin Zhang, Zaoxiao Zhang, Quan Duan: "*Acoustic emission studies for characterization of fatigue crack growth in 316LN stainless steel and welds.*". Applied Acoustics, Volume 126, Pages 101-113, November 2017.

-
- [35] Benjamin Lindemann, Fabian Fesenmayr , Nasser Jazdi , Michael Weyrich: “*Anomaly detection in discrete manufacturing using self-learning approaches* “ *Procedia CIRP*. Volume 79, Pages 313-318. 2019.
- [36] Changsheng Zhua, Christian Uwa Idemudiaa, Wenfang Fengba:”*Improved logistic regression model for diabetes prediction by integrating PCA and K-means techniques*”. *Informatics in Medicine Unlocked*. DOI: 100179. Volume 17. April 2019.
- [37] Lucio Mwinmaarong Dery, Benjamin Nachman, Francesco Rubboc, Ariel Schwartzmanc: “ *Weakly supervised classification in high energy physics* “. *Journal of Physics: Conference Series*, Volume 1085, Issue 4. July 2017.
- [38] Donald F. Specht: “ *A General Regression Neural Network* “. *IEEE transtactions of neural networks*. DOI: 10.1109/72.97934. Vol 2, No 6. Usa, 1991.
- [39] Yan-yan, Ying Lu: “*Decision tree methods: applications for classification and prediction*”. *Shanghai Arch Psychiatry* DOI: 10.11919/j.issn.1002-0829.215044, Vol 27(2), Pag 130–135. Apr 2015.
- [40] Johan A. Westerhuis, Huub C. J. Hoefsloot, Suzanne Smit, Daniel J. Vis: “ *Assessment of PLSDA cross validation* “. *Metabolomics* Vol 4, Issue 1, pag:81-89. February 2008
- [41] A.K. Santra, C. Josephine Christy: “*Genetic Algorithm and Confusion Matrix for Document Clustering*”. *International Journal of Computer Science Issues*, Vol. 9, Issue 1, No 2, January 2012.
- [42] Zhe Hui Hoo, Jane Candlish, Dawn Teare: “ *What is an ROC curve?* “ *Emerg Med J*, Vol 34, page:357–359, March 2017