



UNIVERSIDAD  
**NACIONAL**  
DE COLOMBIA

# **Determinación de la condición de las válvulas antirretorno tipo clapeta oscilante mediante el análisis de señales temporales y algoritmos de inteligencia artificial**

**José Ignacio Amaya Rodríguez**

Universidad Nacional de Colombia

Facultad de Minas, Departamento de Mecánica

Medellín, Colombia

2022



# **Determinación de la condición de las válvulas antirretorno tipo clapeta oscilante mediante el análisis de señales temporales y algoritmos de inteligencia artificial**

**José Ignacio Amaya Rodríguez**

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

**Magister en Ingeniería Mecánica – Profundización**

Director:

Ph.D., Alejandro Restrepo Martínez

Línea de Investigación:

Profundización

Grupo de Investigación:

GPIMA

Universidad Nacional de Colombia

Facultad de Minas, Departamento de ingeniería Mecánica

Medellín, Colombia

2022

## Declaración de obra original

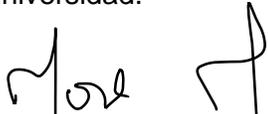
Yo declaro lo siguiente:

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.



---

José Ignacio Amaya Rodríguez

Fecha 28/02/2022

## Resumen

Las válvulas antirretornos son complementos de mucha utilidad dentro de las líneas industriales de extracción de café. Estas válvulas pueden presentar fallas durante su funcionamiento debido al desprendimiento del disco, desgaste del asiento o fatiga del resorte, generándose fallas y pérdidas de tiempo en los procesos. Actualmente, el aprendizaje profundo mediante las redes neuronales convolucionales ha permitido investigar y procesar gran cantidad de datos, lográndose excelentes resultados en la predicción del estado de componentes industriales. Es así, como este trabajo se centra en las técnicas de mantenimiento predictivo de vibraciones, ultrasonido y emisión acústica por medio de la captura de señales temporales, análisis de descriptores temporales, estrategias de reducción de dimensionalidad como PCA, tSNE y UMAP, además, del agrupamiento con entrenamiento Kmeans. Adicionalmente, se empleó el método SFS para la selección de las características más significativas de los descriptores temporales y de esta manera mejorar la capacidad computacional del análisis de los datos.

Se utilizaron redes NN (Patternet) como clasificadores en el entrenamiento no supervisado y modelos de árbol de decisión para evaluar patrones obtenidos durante los entrenamientos realizados. Además, para el entrenamiento supervisado se emplearon representaciones gráficas de espectrogramas y escalogramas, los cuales se obtuvieron con arquitecturas de redes profundas como GoogleNet, SqueezeNet y una red convolucional propuesta desarrollada dentro de la experimentación.

La evaluación de los entrenamientos se realizó mediante la matriz de confusión y curva ROC para determinar la eficiencia de los clasificadores empleados. Los resultados obtenidos en esta investigación permitieron determinar el comportamiento de la válvula antirretorno, clasificar el estado (buena o mala) y concluir que, la red GoogleNet para espectrogramas presentó el mejor desempeño con respecto a los demás clasificadores estudiados. Este estudio permitirá en el futuro desarrollar una estrategia predictiva para anticiparse al fallo de la válvula antirretorno.

**Palabras clave:** Mantenimiento predictivo, vibración, emisión acústica, ultrasonido, redes neuronales, reducción de dimensionalidad, matriz de confusión.

# Condition determination of swing check valves using time signal analysis and artificial intelligence algorithms

## Abstract

Non-return valves are very useful complements in industrial coffee extraction lines. These valves can present failures during its operation due to disc detachment, seat wear or spring fatigue, causing failures and loss of processing time. Currently, the deep learning by means of convolutional neural networks has made possible to investigate and process large amounts of data, achieving excellent results in the prediction of the condition of industrial components. Thus, this work focuses on predictive maintenance techniques of vibration, ultrasound and acoustic emission by means of the temporal signals capture, temporal descriptor analysis and dimensionality reduction strategies such as PCA, tSNE and UMAP, as well as Kmeans training clustering. In addition, the SFS method was used for the selection of the most significant characteristics of the temporal descriptors and thus improve the computational capacity of the data analysis.

NN (Patternet) networks were used as classifiers in the unsupervised training and decision tree models were used to evaluate patterns obtained during the training. In addition, for the supervised training we used graphical representations of spectrograms and scalograms, which were obtained with deep network architectures such as GoogleNet, SqueezeNet and a proposed convolutional network developed in the experimentation.

The evaluation of the training was performed using the confusion matrix and ROC curve to determine the efficiency of the classifiers used. The results obtained in this investigation allowed to determine the behavior of the non-return valve, classify the state (good or bad) and to conclude that, the GoogleNet network for spectrograms presented the best performance with respect to other classifiers studied. This study will allow in the future to develop a predictive strategy to anticipate the failure of the non-return valve.

**Keywords:** Predictive maintenance, vibration, acoustic emission, ultrasound, neural networks, dimensionality reduction, confusion matrix.

# Contenido

	Pág.
<b>Resumen</b> .....	<b>V</b>
<b>Lista de figuras</b> .....	<b>9</b>
<b>Lista de tablas</b> .....	<b>11</b>
<b>1. INTRODUCCIÓN</b> .....	<b>12</b>
1.1    Objetivos .....	15
1.2    General .....	15
1.3    Específicos.....	15
<b>2. MARCO TEÓRICO Y ESTADO DEL ARTE</b> .....	<b>16</b>
2.1    Marco teórico .....	16
2.1.1    Válvulas antirretornos .....	16
2.1.2    Modos de Fallo de las válvulas de antirretorno .....	18
2.1.3    Mantenimiento predictivo .....	18
2.1.4    Análisis de las señales temporales mediante descriptores estadísticos.....	23
2.1.5    Obtención de características dinámicas a través del análisis espectral de las señales.....	25
2.1.6    Aprendizaje automático o aprendizaje de máquina .....	30
Reducción de la dimensionalidad.....	35
2.2    Estado del arte .....	40
2.2.1    Aplicación de emisión acústica (EA) y señales de ultrasonido .....	40
2.2.2    Análisis de la vibración para detectar fugas en válvulas .....	41
2.2.3    Análisis de fallas en rodamientos usando autocodificador convolucional y transformación de ondas continuas.....	42
2.2.4    Sistema de diagnóstico de fallas del motor basado en el análisis de la intensidad del sonido y la red neuronal de pre procesamiento de paquetes de ondículas.....	43
<b>3. METODOLOGÍA</b> .....	<b>44</b>
3.1    Procedimiento de adquisición de datos .....	45
3.1.1    Vibración.....	45
3.1.2    Emisión acústica.....	46
3.1.3    Ultrasonido .....	47
3.2    Descriptores de la señal .....	48
3.3    Entrenamiento no supervisado .....	48
3.4    Entrenamiento supervisado .....	48
<b>4. RESULTADOS Y DISCUSIÓN</b> .....	<b>50</b>
4.1    Procedimiento de adquisición de datos .....	50
4.1.1    Adquisición de las señales.....	50
4.2    Descriptores de la señal .....	53
4.2.1    Descriptores temporales para la vibración .....	54
4.2.2    Descriptores temporales para la emisión acústica .....	57
4.3    Análisis de escalograma para vibración eje x .....	59
4.4    Entrenamiento no supervisado .....	60

4.4.1	Clasificadores de estrategias de reducción de dimensionalidad y agrupamientos .....	61
4.4.2	Aplicación de técnicas de reducción de dimensionalidad para la vibración eje X.....	62
4.4.3	Técnicas de selección de características de las señales temporales.....	65
4.4.4	Evaluación del desempeño del entrenamiento no supervisado .....	67
4.5	Entrenamiento supervisado .....	70
4.5.1	Clasificación de redes profundas.....	71
4.5.2	Análisis de espectrograma para la emisión acústica .....	73
4.5.3	Evaluación del desempeño de redes profundas .....	75
<b>5.</b>	<b>CONCLUSIONES.....</b>	<b>79</b>
	<b>BIBLIOGRAFÍA.....</b>	<b>82</b>

## Lista de figuras

	Pág.
<b>Figura 2-1</b> Válvula antirretorno y zonas de fallo.....	17
<b>Figura 2-2</b> Onda sonora y sus características.....	20
<b>Figura 2-3</b> Señal de emisión acústica y parámetros de caracterización.....	21
<b>Figura 2-4</b> Rango de espectro de Fourier para emisión acústica.....	27
<b>Figura 2-5</b> Espectrograma vibraciones válvula antirretorno.....	28
<b>Figura 2-7</b> Comparación entre los análisis FFT (tiempo-frecuencia) (a) y análisis Wavelet (tiempo-escala) (b).....	29
<b>Figura 2-8</b> Estructura de una red neuronal profunda.....	31
<b>Figura 2-9</b> Red convolucional.....	32
<b>Figura 2-10</b> Funcionamiento de una red Convolucional para la clasificación de imágenes.....	32
<b>Figura 2-11</b> Estructura de los filtros convolucionales SqueezeNet.....	34
<b>Figura 2-12</b> Gráfico de matriz de confusión.....	37
<b>Figura 2-13</b> Curva ROC.....	39
<b>Figura 3-1</b> Flujograma de la metodología de a seguir.....	44
<b>Figura 3-2</b> Disposición de instrumentos para la toma de las señales temporales en línea de descargue de borra de café.....	45
<b>Figura 3-3</b> Aceleración lineal en las coordenadas x, y, y z.....	46
<b>Figura 3-4:</b> Toma de señales en la válvula.....	47
<b>Figura 3-5:</b> Colocación detector ultrasónico de fugas TMST 1 para la toma de señales temporales ultrasónicas.....	47
<b>Figura 4-1</b> Señal temporal de la vibración eje x para la válvula buena y válvula mala ...	51
<b>Figura 4-2</b> Señal temporal emisión acústica para la válvula buena y válvula mala .....	52
<b>Figura 4-3</b> Señal temporal de ultrasonido para la válvula buena y válvula mala .....	53
<b>Figura 4-4</b> Análisis de los descriptores temporales para vibración en eje x, y, z y absoluta. Fuente propia.....	56
<b>Figura 4-5</b> Análisis de los descriptores temporales para la emisión acústica para la válvula buena.....	57
<b>Figura 4-6</b> Análisis de los descriptores temporales para la emisión acústica para la válvula mala .....	58
<b>Figura 4-7</b> Escalograma de la vibración eje x para la válvula buena.....	59
<b>Figura 4-8</b> Escalograma de la vibración eje x para la válvula mala .....	59

<b>Figura 4-9</b>	Gráficos de distribución real por pares de componentes principales (PCA)..	63
<b>Figura 4-10</b>	Agrupamientos obtenidos por PCA - Kmeans .....	63
<b>Figura 4-11</b>	Distribución real Vs agrupamiento generado para t-SNE .....	64
<b>Figura 4-12</b>	Distribución real vs agrupamiento generado por UMAP .....	64
<b>Figura 4-13</b>	Resultado para SFS (8 + t-SNE- Kmeans, predicción para la vibración eje X, a) proyección esperada y b) proyección predicha. ....	66
<b>Figura 4-14</b>	Resultados para SFS (4) + t-SNE - KMeans para emisión acústica. a) proyección esperada y b) proyección predicha. ....	66
<b>Figura 4-15</b>	Matriz de confusión para la vibración a) y emisión acústica b) – Patternet ..	68
<b>Figura 4-16</b>	Curva ROC de la vibración eje x (a) y emisión acústica (b) – Patternet.....	69
<b>Figura 4-17</b>	Espectrograma de la vibración eje x de la válvula mala .....	71
<b>Figura 4-18</b>	Espectrograma de la vibración eje x de la válvula buena .....	72
<b>Figura 4-19</b>	Gráfica de reducción de pérdida por épocas Googlenet de la vibración eje x .....	72
<b>Figura 4-20</b>	Espectrograma de la emisión acústica de la válvula buena.....	73
<b>Figura 4-21</b>	Espectrograma de la emisión acústica de la válvula mala .....	74
<b>Figura 4-22</b>	Gráfica de reducción de pérdidas por épocas Squeezenet de la emisión acústica.....	74
<b>Figura 4-23</b>	Matriz de confusión para la vibración a) y emisión acústica b) .....	75
<b>Figura 4-24</b>	Curva ROC para la vibración eje x (a) y emisión acústica (b).....	77

## Lista de tablas

<b>Tabla 1</b> Arquitectura de la red convolucional para GoogleNet y Squeezenet. ....	33
<b>Tabla 2.</b> Temporales de vibración eje x y emisión acústica por el método SFS.....	54
<b>Tabla 3</b> Representación numérica de los descriptores temporales para vibración .....	55
<b>Tabla 4</b> Comportamiento de los casos analizados de los clasificadores no supervisado	61
<b>Tabla 5.</b> Precisión de estrategias de reducción de dimensionalidad y clasificador. ....	62
<b>Tabla 6</b> Precisión de los métodos no supervisados.....	67
<b>Tabla 7</b> Métricas de la matriz de confusión para Patternet para las señales temporales de mejor desempeño.....	68
<b>Tabla 8</b> Exactitud de los métodos supervisados de entrenamiento profundo para espectrograma .....	70
<b>Tabla 9</b> Exactitud de los métodos supervisados de entrenamiento profundo para escalograma.....	70
<b>Tabla 10</b> Características del entrenamiento de reducción de pérdida para vibración eje x .....	72
<b>Tabla 11</b> Características del entrenamiento de reducción de pérdida para emisión acústica .....	74
<b>Tabla 12.</b> Métricas de la matriz de confusión para Googlenet para las señales temporales de mejor desempeño.....	76
<b>Tabla 13</b> Métricas de la matriz de confusión para Squeezenet para las señales temporales de mejor desempeño .....	76

# 1. INTRODUCCIÓN

En la industria cada vez es más relevante el mantenimiento predictivo de equipos e instrumentos mediante herramientas de análisis de gran cantidad de datos que ayuden a predecir el desgaste y comportamiento de estos, con la finalidad de poder tomar decisiones a tiempo en las líneas de los procesos, disminuyendo perdidas por tiempos muertos y retrasos en las producciones.

Los mantenimientos correctivos en una planta de extracción de café pueden ser debidos a fallas en las válvulas antirretorno ubicadas en la línea de descargue de borra y pueden presentarse alrededor de 40 eventos en un año, ocasionándose paradas en el proceso generando retrasos en los tiempos de producción y costo de oportunidad de \$68.000.000 por cada evento generado. Las fallas o desgastes en este tipo de válvulas de antirretorno pueden generarse debido a las oscilaciones presentadas en el flujo de proceso, vibraciones en tuberías que aceleran el desgaste del material y sus componentes internos.

Las válvulas antirretornos, son componentes mecánicos que por sus características de operación son fundamentales en los procesos productivos industriales. Debido a esto, su función y estado constituyen un importante desafío para los departamentos de mantenimiento a la hora de definir posibles fallos de estos componentes.

Uno de los factores que impacta en el funcionamiento de los procesos es el desgaste natural de máquinas y sus componentes o piezas como las válvulas de retención tipo clapeta, en las que debido al uso continuo de presentan daños como desprendimiento del

disco, fatiga del resorte y desgaste en el asiento. El mantenimiento predictivo es importante dentro del buen desempeño de una planta de procesos, debido a que permite predecir el comportamiento, desgastes, vida útil de cada parte o componentes críticos y con ello conservar las máquinas e instrumentos en funcionamiento de forma continua, manteniendo su eficiencia y reduciéndose la parada de los procesos. Lo anterior ayuda a mejorar no solo los procesos sino la seguridad, confiabilidad, disponibilidad, calidad y eficiencia (Ilić, Trojić, Lazić, & Filipovi, 2019; Selcuk, 2017).

Basados en la importancia de las válvulas antirretorno para el correcto funcionamiento de las plantas de extracción de café, se identifica que no se cuenta con un método para describir las señales relacionadas al comportamiento en operación de las válvulas. Consecuentemente, no se puede determinar el deterioro de la válvula antes de que ocurra el fallo. Lo anterior exige definir las características de operación y establecer variaciones en las señales que evidencian los cambios en el funcionamiento de los componentes de la válvula.

La hipótesis anterior abre la posibilidad de realizar estudios con técnicas mantenimiento del predictivo como: ultrasonido, vibración y emisión acústica, con el propósito de establecer el deterioro de la válvula a lo largo del tiempo. Además, se plantea dar solución al siguiente interrogante: ¿partiendo del análisis de datos y utilizando técnicas predictivas de mantenimiento como ultrasonido, emisión acústica y vibraciones, se podrán definir los patrones que identifican el daño?

La propuesta presentada en esta investigación plantea determinar la condición de las válvulas antirretorno tipo clapeta oscilante, mediante un método que establezca la condición de operación de las válvulas antirretorno. Se plantea la valoración de métodos predictivos como ultrasonido, emisión acústica y vibraciones debido a que estos métodos tienen el potencial de censar las variaciones en las válvulas, el análisis de los descriptores temporales, y el empleo de estrategias de reducción de dimensionalidad como PCA, tSNE y UMAP, además, del agrupamiento de los datos con Kmeans.

El entrenamiento no supervisado se realiza con la red NN (Patternet) y modelos de árbol de decisión para evaluar patrones obtenidos durante los entrenamientos. Además, para el entrenamiento supervisado se emplearon representaciones graficas de espectrogramas y escalogramas, los cuales se obtuvieron con arquitecturas de redes profundas como GoogleNet, SqueezeNet y una red convolucional propuesta desarrollada dentro de la experimentación. La evaluación del desempeño de los entrenamientos supervisados y no supervisados se realiza mediante la matriz de confusión y curvas ROC para obtener la precisión de los modelos utilizados para predecir el estado de la válvula.

## **1.1 Objetivos**

### **1.2 General**

Determinar la condición de las válvulas anti retorno tipo clapeta oscilante mediante el análisis de señales temporales y algoritmos de inteligencia artificial

### **1.3 Específicos**

Desarrollar un procedimiento de toma y acondicionamiento de datos de las señales temporales en válvulas antirretorno tipo clapeta oscilante.

Seleccionar una señal temporal que identifique variaciones asociadas a la operación de la válvula antirretorno.

Entrenar un clasificador, usando descriptores temporales, espectros de frecuencia y espectrograma de la señal temporal seleccionada.

Evaluar el desempeño de las estrategias de aprendizaje supervisado, usando matriz de confusión y curva ROC.

## 2. MARCO TEÓRICO Y ESTADO DEL ARTE

En este capítulo se describen la teoría, antecedentes y el estado del arte de técnicas como la vibración, emisión acústica y el ultrasonido aplicadas para la solución de problemas de predicción de fallas de válvulas antirretorno tipo clapeta; se especifican también los descriptores temporales como la media, desviación estándar, RMS, factor de pico, curtosis, máximos, mínimos, entre otros mediante los cuales se analizan estadísticamente las señales capturadas, además se describe el análisis de los espectrogramas y escalogramas mediante la transformada rápida de Fourier, la transformada Wavelet y los algoritmos de entrenamiento y aprendizaje de maquina supervisado y no supervisado.

### 2.1 Marco teórico

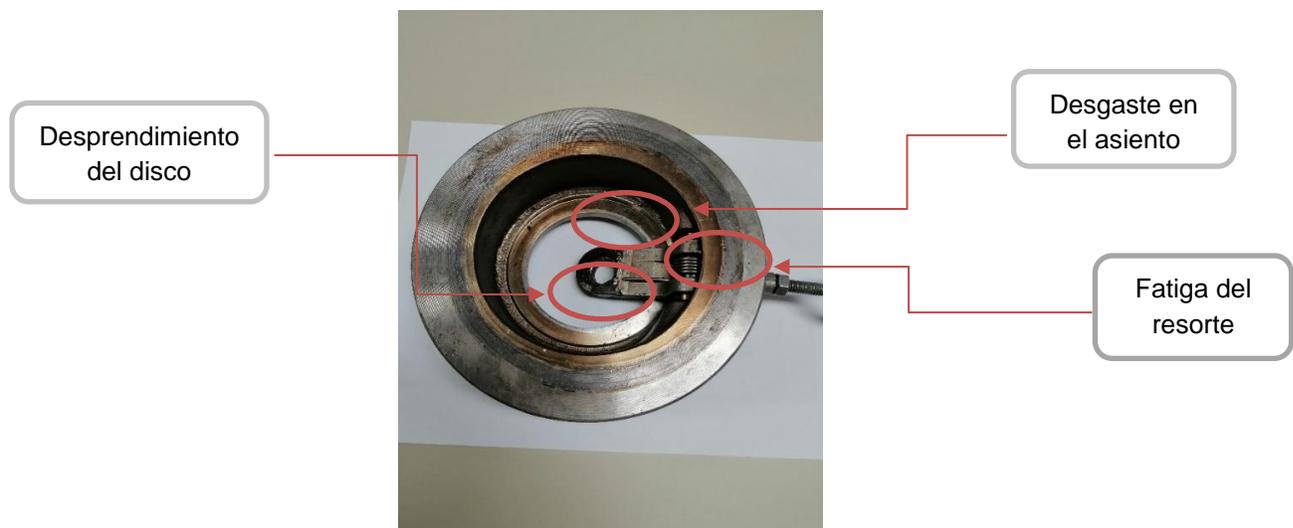
#### 2.1.1 Válvulas antirretornos

Las válvulas antirretorno, también llamadas válvulas de retención, son complementos usados ampliamente en la industria como parte de los sistemas de seguridad (Kim, Kim, & Park, 2017). Estas cumplen la función de dirigir el flujo en una dirección, cerrando por completo el paso de un fluido que se encuentre en circulación dentro de un sistema, permitiendo el paso en un sentido y restringiendo el paso de dicho fluido en contraflujo (Shin, Kim, & Kang, 2018)

La principal característica de las válvulas antirretorno tipo clapeta oscilante, se define en el hecho que el disco tiene un recorrido mínimo logrando llegar a la posición de apertura y

cierre total en poco tiempo, permitiendo la activación rápida del componente, lo que facilita la restricción oportuna del fluido.

En este tipo de válvulas suelen presentarse deterioros en sus componentes internos que generan fallas en el funcionamiento de las mismas, y por ende en la línea del sistema de flujo donde se encuentren instaladas, generándose pérdidas en los procesos, despresurizaciones, paradas de producción entre otros. La falla de las válvulas puede darse debido al desgaste de partes como el pasador de bisagras, interferencias con objetos extraños, brazos, discos de asientos, pasadores de tuercas de discos, pasadores rotos, disco parcialmente abierto, disco agrietado, disco atrapado en el interior del anillo de asiento (Kim et al., 2017). En la figura 2-1 se muestra una válvula antirretorno tipo clapeta oscilante de cuatro pulgadas en acero inoxidable, la cual presenta tres modos de fallo: desprendimiento del disco, fatiga en el resorte y desgaste en el asiento.



**Figura 2-1** Válvula antirretorno y zonas de fallo.  
Fuente propia

### 2.1.2 Modos de Fallo de las válvulas de antirretorno

En los modos de fallo de las válvulas antirretorno se identifican tres tipos, los cuales se definen así: por fatiga en el resorte, por desgaste en el asiento y por desprendimiento del disco de cierre. A continuación, se explica cada tipo de fallo:

- La fatiga en el resorte es un tipo de desgaste que ocurre como consecuencia del número de ciclos dados en el sistema. Esto tiene origen en el hecho de que la presión de vapor no constante genera un movimiento oscilatorio del disco de cierre.
- El desgaste en el asiento es un tipo de desgaste que se refiere a los golpes presentados entre el disco y el asiento de la válvula, la generación del defecto ocasiona una caída presión en la línea de vapor.
- El desprendimiento del disco es un tipo de desgaste que se presenta cuando la soldadura que sostiene el disco del tornillo sujetador se fisura y revienta. Este desprendimiento es el más catastrófico de los tipos de fallo, ya que genera obstrucción inminente en la línea de precalentamiento.

### 2.1.3 Mantenimiento predictivo

El mantenimiento predictivo radica en la realización de ensayos o toma de datos mediante técnicas no destructivas, que permiten hacerle seguimiento al funcionamiento de los equipos o a partes de estos que sean susceptibles a deterioro, detectándose y localizando las fallas o averías en estos (Olarte & Botero, 2011; Olarte, Botero, & Cañon, 2010). Además, este tipo de mantenimiento sirve como apoyo al preventivo, pudiéndose realizar la predicción del desgaste de los componentes para detectar anomalías que puedan presentarse y simular su comportamiento en el tiempo y su uso (Olarte et al., 2010).

El mantenimiento predictivo es importante dentro del buen desempeño de una planta de procesos, debido a que permite predecir el comportamiento, desgastes, vida útil de cada rodamiento o componentes críticos y con ello conservar las máquinas e instrumentos en buen funcionamiento de forma continua, manteniendo su eficiencia y disminuyendo paradas de los procesos. Este tipo de mantenimiento ayuda a mejorar no solo los procesos sino la seguridad, confiabilidad, disponibilidad, calidad y eficiencia (Ilić et al., 2019; Selcuk, 2017).

Actualmente, existen diversas herramientas empleadas por la industria para evaluar y analizar el desempeño de los distintos componentes críticos en los equipos y con ello llegar a predecir su comportamiento asociado a desgastes, entre las que se encuentran el análisis de vibraciones, el análisis de aceites, pulsos eléctricos, análisis de gases, ultrasonidos y la termografía (Gómez, 2017; Ilić et al., 2019; Olarte et al., 2010), La principal ventaja que tienen las técnicas predictivas está asociada a que las inspecciones realizadas a los componentes se pueden realizar sin requerir la parada de equipos para su inspección, ayudan a reducir costos de mantenimiento en el largo plazo y generan diagnósticos precisos de las condiciones mecánicas de los equipos de forma objetiva (Penkova Vassileva, 2007).

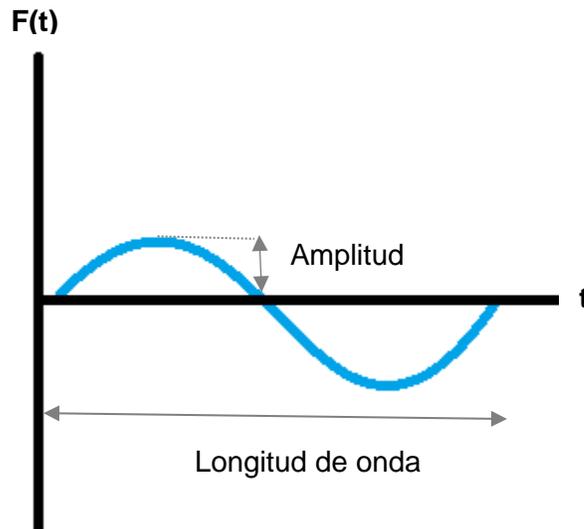
### **Análisis por Ultrasonido**

La técnica de ultrasonido se define como una estrategia predictiva no destructiva de inspección de componentes, en la cual se analizan patrones que definan la propagación de señales de ondas sonoras del ultrasonido. Este método se hace útil a la hora de definir posibles fallos en los equipos y su principal característica se fundamenta en que es capaz de percibir las ondas sonoras de tipo inaudible, dichas frecuencias se encuentran en rangos superiores a 20KHz (Santos De La Cruz, Eulogio; Cancino Vera, Néstor; Yenque Dedios, Julio; Ramírez Morales, David; Palomino Pérez, 2005).

El ultrasonido es medido mediante ondas mecánicas longitudinales de alta frecuencia, en la figura 2-2, se observa la estructura de una onda sonora y sus características de longitud

y amplitud. Las ondas son producidas por las vibraciones de objetos y estas viajan a través de un medio sólido, líquido o gas. Los componentes de equipos e instrumentos generan sonidos característicos en condiciones normales de funcionamiento o de desgaste, a los cuales puede realizarse seguimiento y e identificar cambios en sus patrones (Olarte & Botero, 2011; Selcuk, 2017). Es decir, que el sonido generado por un componente en buen funcionamiento o averiado de una máquina puede ser captado y medirse por medio detectores ultrasónicos o medidores de ultrasonidos que convierten las ondas de ultrasonido generadas por fugas de vapor, aire o defectos en materiales en ondas audibles.

Entre las fallas que pueden detectarse mediante esta técnica se encuentran: detección de fugas en sistemas de presión y vacío como en calderas, condensadores, intercambiadores de calor, enfriadores, sistemas de gas, hornos de vacío, etc.), inspección de trampas de vapor, evaluación de la integridad en sellos y juntas de tanques, fallas y/o fugas en válvulas, cavitaciones de bombas, detectar arco eléctrico, fugas en fluidos, perdidas de vacío, fricción en máquinas, etc. (Selcuk, 2017).



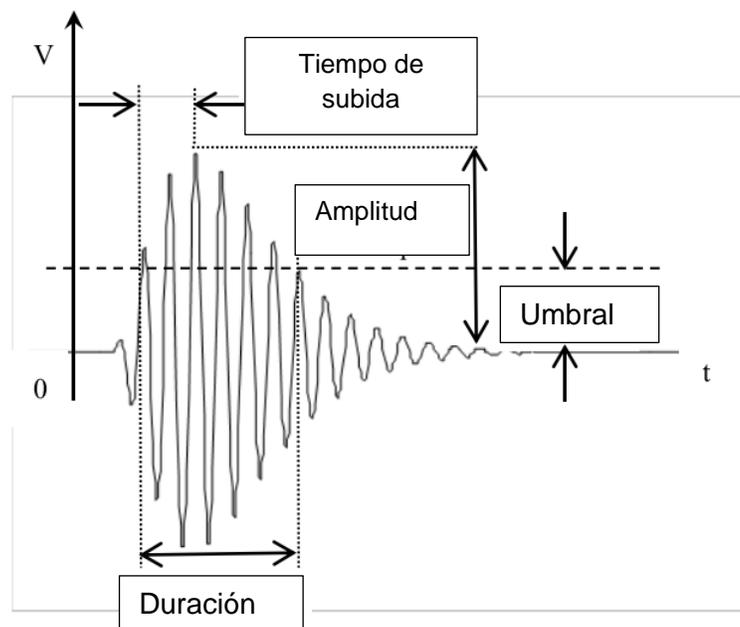
**Figura 2-2** Onda sonora y sus características.

Fuente (Olarte & Botero, 2011) modificado.

### **Análisis por Emisión acústica (EA)**

La técnica de emisión acústica es un método de inspección predictivo no destructivo, que fundamenta en el análisis de ondas elásticas transitorias figura 2-3, en las cuales se

presenta una liberación rápida de energía generada por la deformación o un fallo del material. Las señales de EA se clasifican en señal de ráfagas las cuales no son repetibles y se dan de manera discreta y la señal continua, la cual tiene amplitud y frecuencia variables, por lo general, estas son emisiones de baja energía generadas por fricciones dentro de una estructura sin presentar ninguna característica en el dominio del tiempo (Pacheco Córdova, Sánchez L, Cabrera, & Cerrada, 2018). La frecuencia para la EA se encuentra en el rango de 100kHz a 1MHz y una baja amplitud de 10  $\mu\text{V}$ , debido a esto, estas señales no son distorsionadas por el desequilibrio y desalineación que se dan en rangos más bajos de frecuencia (Filipussi, 2018; Romero R, Morales V, Osornio Ríos, Romero Troncoso, & Moríñigo S., 2018).



**Figura 2-3** Señal de emisión acústica y parámetros de caracterización.  
Fuente (Filipussi, 2018)

Este tipo de técnica permite identificar posibles procesos de deformación propios de los componentes mecánicos (Magallanes & Martín Sánchez Mtz, 1992). Las mediciones de EA consisten en la colocación de micrófonos que permiten la toma de datos audibles, permitiendo la captura y posterior análisis de las señales, con el objetivo de determinar y relacionar los patrones de frecuencias con el estado de operación componente en estudio.

La emisión acústica se ha empleado en la industria para el control de los procesos de fabricación mecánica, así, como en la industria de la construcción, investigaciones de materiales y fugas en tuberías (Yan et al., 2015). Se hace interesante el desarrollo analítico con esta técnica en la problemática en estudio; debido a que en el componente estudiado se presentan algunos cambios de energía que determinan alguna diferencia en el comportamiento de la válvula, esto basado en las características del fluido y a que en la válvula se generan liberaciones de energía que pueden ser identificados sonoramente.

### **Análisis de Vibraciones**

La vibración se podría definir como la oscilación mecánica que se presenta en un cuerpo con relación a una posición de referencia. En consecuencia, la vibración se caracteriza estableciendo variación de la amplitud (magnitud de la señal) y la frecuencia (número de ciclos) en función del tiempo. En general las vibraciones generan fatiga en los componentes sometidos a esta (Torres, Royo, & Rabanaque, 2015). Las máquinas y sus componentes tienen un grado de vibración durante su funcionamiento en buen estado; pueden presentarse cambios en la vibración debido a desgastes o deterioros en los componentes.

El espectro de la señal de las vibraciones está constituido por la frecuencia en el eje horizontal, mientras que el eje vertical puede variar de acuerdo al parámetro que mejor describa la información adquirida, el cual puede ser aceleración, velocidad o desplazamiento. En cuanto a la severidad de las fallas, estas son medida a través de la amplitud, por lo que este tipo de gráficos suele ser muy empelado y para su análisis se debe tener en cuenta factores de escala como pico, pico a pico o RMS. En el análisis de las vibraciones el factor pico es la representación desde el valor cero de referencia hasta el máximo valor; así mismo, la amplitud pico se emplea para medir la aceleración a partir del valor RMS (Rosa, Miles, & Perez, 2009).

La vibración se puede expresar mediante tres unidades: aceleración, velocidad y desplazamiento. El desplazamiento representa la distancia total recorrida por el componente (pico a pico), y se utiliza para evaluar máquinas de bajas revoluciones. La velocidad de la vibración es empleada para analizar máquinas de baja y media velocidad

y el rango de frecuencias esta de 10Hz a 1000Hz. En cuanto a la aceleración, esta hace relación a un cambio de velocidad, en esta se mide la amplitud del pico o RMS y se emplea para el análisis se altas frecuencias como las generadas por engranajes y rodamientos, su unidad de medida es Gs (1G = aceleración producida por la gravedad)  $\text{In/s}^2$  o  $\text{mm/s}^2$ .

De acuerdo a (Tao, Liu, & Yang, 2016) las señales de vibración empleadas para diagnosticar fallas en los rodamientos tiene dos enfoques efectivos, que son el procesamiento de señales y reconocimiento de patrones, para este último se utiliza ampliamente el aprendizaje profundo y la inteligencia artificial, como lo son la lógica difusa, la máquina de soporte de vectores (SVM) y las redes neuronales (NN).

## **2.1.4 Análisis de las señales temporales mediante descriptores estadísticos**

### **Descriptores temporales**

Los descriptores temporales son métodos matemáticos que permiten definir el comportamiento estadístico de las variables que se desean medir, con el fin de analizar su comportamiento basado en el dominio del tiempo (Tao et al., 2016) entre los que encontramos: media, máximo, mínimo, pico a pico, media absoluta, varianza, desviación estándar, curtosis, RMS, factor de forma, factor pico, oblicuidad, factor de impacto, factor de margen y estándar. El estudio de estos descriptores permite observar el comportamiento de las señales, además de definir las variaciones que se presentan en los diferentes puntos de la señal capturada.

A continuación, se presentan algunos descriptores temporales con sus respectivas fórmulas:

- La ecuación (1-1) representa la desviación estándar, la cual determina la dispersión del conjunto de datos (Tao et al., 2016); se definen las variables así:  
n: número de datos  
  
x<sub>i</sub>: es el dato temporal

$\bar{x}$ : es la media de los datos temporales

$$\left( \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{1/2} \quad (1-1)$$

- La ecuación (1-2) representa la curtosis, esta determina el grado de concentración de datos (Tao et al., 2016).

Xstda: es la desviación estándar de los datos temporales analizados.

$$\frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)x_{std}^4} \quad (1-2)$$

- El valor RMS (*Root Mean Square*) representa la media cuadrática y está definido matemáticamente como la raíz cuadrada del promedio de los datos al cuadrado, el cual puede hallarse en el dominio del tiempo mediante la ecuación (1-3) (Tao et al., 2016).

$$\left( \frac{1}{n} \sum_{i=1}^n |x_i|^{1/2} \right)^2 \quad (1-3)$$

- La ecuación 1-4 representa el factor pico, el cual define el valor máximo de la frecuencia.

Xp: es el valor del pico

Xrms: es el valor de rms de los datos temporales analizados

$$\frac{X_p}{x_{rms}} \quad (1-4)$$

- Factor de forma

$$\frac{X_{rms}}{\bar{x}} \quad (1-5)$$

- Varianza de los datos

$$\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} \quad (1-6)$$

- Media absoluta

$$\frac{1}{n} \sum |x_i| \quad (1-7)$$

- Oblicuidad

$$\frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)x_{std}^3} \quad (1-8)$$

- Factor de margen

$$\frac{x_p}{x_{rms}} \quad (1-9)$$

Con el análisis de los descriptores temporales se deben obtener características de simplicidad, repetibilidad y diferenciabilidad.

- Simplicidad: el descriptor debe representar las características de la señal de forma clara y sencilla, permitiendo la fácil interpretación.
- Repetibilidad: El descriptor debe ser independiente del momento en que se genere.
- Diferenciabilidad: El descriptor debe presentar un alto grado de diferenciación frente a otros descriptores.

### 2.1.5 Obtención de características dinámicas a través del análisis espectral de las señales

La toma de señales a través de sensores y el procesamiento digital de esta gran cantidad de datos permite tener interpretaciones, conocer y estimar el comportamiento y estado de equipos e instrumentos. El análisis espectral de las señales permite analizar de forma detallada el comportamiento de la misma y sus componentes armónicos, así, el procesamiento de estas es crítico debido a que los rangos de frecuencia seleccionados deben proporcionar información adecuada a cerca del comportamiento del proceso u objeto en estudio. Para el análisis y filtración de las señales se emplea la transformada de Fourier en el cálculo de la transformada discreta de señales estacionarias y la transformada de Wavelet para las no estacionarias, las cuales se describen a continuación.

## Transformada Rápida de Fourier (FFT)

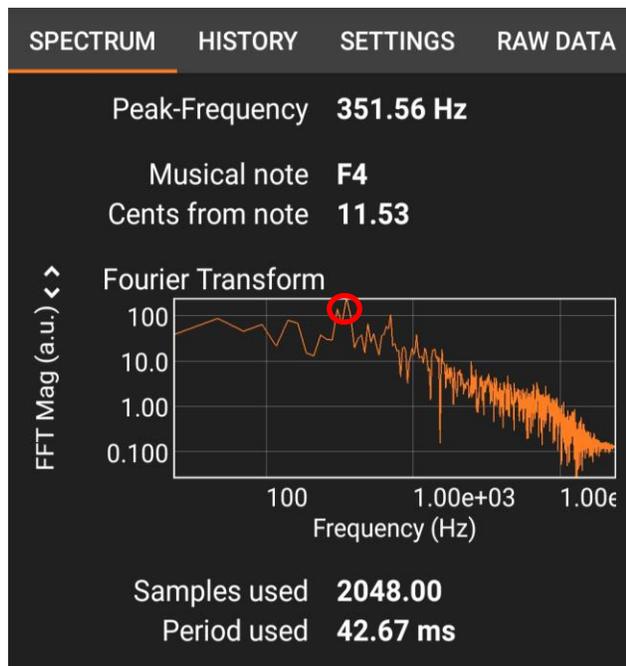
La transformada rápida de Fourier (*FFT* por sus siglas en inglés) es un algoritmo que permite analizar las frecuencias de las señales armónicas que componen una señal. La transformación de la señal calcula el aporte de cada valor de frecuencia a la formación de la señal. Este algoritmo calcula la transformada discreta de Fourier (*DFT*) basado en la división del tiempo o descomposición iterativa, con lo que se eliminan los cálculos repetitivos, pudiéndose llegar a reducir el tiempo (de varios minutos o segundos) (Spilsbury & Euceda, 2016). En la ecuación (1-6) se presenta de la Transformada discreta de Fourier.

$$F\left(\frac{n}{NT}\right) = \frac{1}{N} \sum_{k=0}^{N-1} m(kT) e^{-j \frac{2\pi n k}{N}} \quad n = 0, 1, 2, \dots, N-1 \quad (1-10)$$

Donde,  $N$  es el número total de datos de la señal en el tiempo,  $NT$  es el dato máximo,  $T$  el periodo de frecuencia muestral;  $n$  es la muestra actual de la señal de tiempo y va desde 0 a  $N-1$ ;  $k$  hace referencia a la posición del coeficiente de Fourier y va desde 0 a hasta  $N-1$

La *DFT* se consigue mediante la optimización de la descomposición de la transformada en otras más simples hasta llegar a transformadas de 2 elementos, donde  $k$  puede tomar valor de 0 y 1; posteriormente estas se agrupan en otras de nivel superior, las cuales deben resolverse de nuevo, y así sucesivamente hasta llegar al nivel más alto (Cortés, A, & O, 2007).

La figura 2-4 representa la amplitud en el dominio de la frecuencia de la emisión acústica en la válvula antirretorno; en la que se observa que el valor del pico más de frecuencia se da en 351.56 Hz.

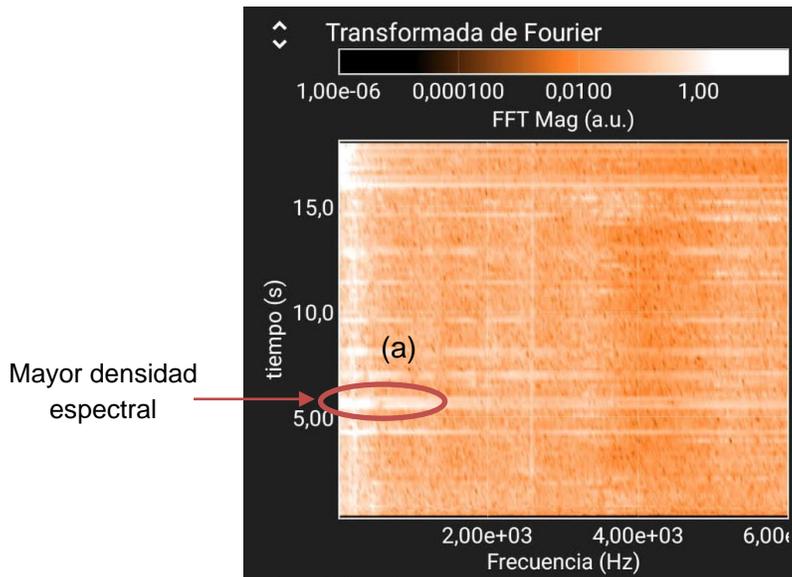


**Figura 2-4** Rango de espectro de Fourier para emisión acústica.  
Fuente propia

## Espectrograma

El espectrograma es una representación visual de varios espectros de Fourier que se hacen por ventaneo temporal. El gráfico se construye con espectros de Fourier de segmentos cortos de la señal y la intensidad en el color indica la magnitud de cada frecuencia. La importancia de esta representación es que permite determinar cambios de frecuencia en diversas ventanas temporales de la señal, permitiendo identificar las frecuencias dominantes de la señal y su evolución (Valencia S., 2019).

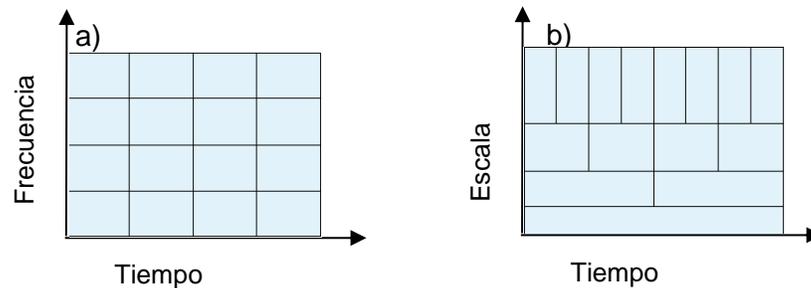
En la figura 2-5 se muestra un espectrograma tomado en campo donde se especifican las frecuencias presentadas, en la que en (a) se puede observar como la energía se encuentra distribuida en las diferentes ventanas del espectro, permitiendo identificar el punto (a) una mayor densidad espectral en función de la frecuencia.



**Figura 2-5** Espectrograma vibraciones válvula antirretorno.  
Fuente Propia

### Transformada de Wavelets

En el procesamiento de señales se pueden encontrar las estacionarias las cuales se localizan en el tiempo debido a que su frecuencia no varía y por ende se estudian mediante la transformada de Fourier que descompone los datos en términos de sus componentes sinusoidales (la señal se transforma de tiempo a base frecuencia o viceversa). Para las señales no estacionarias, es decir, su frecuencia varía en el tiempo, no es posible realizar el paso al dominio del tiempo mediante su transformada de Fourier para poder determinar el momento el cambio de la frecuencia. Es por ello que se hace necesario realizar análisis localizados en el tiempo (translación) y la frecuencia (dilatación) y el análisis Wavelet permite obtener una representación, descomposición (figura 2-7) y reconstrucción de este tipo de señales que presentan cambios abruptos, permitiendo utilizar intervalos grandes de tiempo en segmentos donde es necesario mayor precisión en baja frecuencia, así como a frecuencias más altas el uso de intervalos pequeños figura (2-6). (Nieto & Orozco, 2008).



**Figura 2-6** Comparación entre los análisis FFT (tiempo-frecuencia) (a) y análisis Wavelet (tiempo-escala) (b).

Fuente (Nieto & Orozco, 2008)

Las variaciones de los componentes espectrales de tiempo-frecuencia pueden medirse a través de la transformada Wavelet, la cual tiene una localización logarítmica de la frecuencia como se observa en la figura 2-6 b). Las Wavelets son una forma de ondas de duración limitada, irregulares y asimétricas, con un valor promedio de cero (ecuación 1-11). El análisis de las wavelets descompone la señal en versiones escaladas y desplazadas de la Wavelet original o madre (Cortés et al., 2007).

Este tipo de análisis permite realizar la representación del tiempo y la frecuencia de una señal, además de mejorar el análisis de las señales con oscilaciones e impulsos localizados, por lo que este tipo de transformada es utilizado en el estudio de señales transitorias. (Guillén Peña, Paredes, & Camacho, 2007), emplearon la transformada de wavelet en la detección y diagnóstico fallas de válvulas y transmisores, pudiéndose detectar cuatro tipos de fallas en los instrumentos evaluados, así como el desarrollo de métodos para la determinación de desajustes en la válvula o transmisor.

Ecuación de la función Wavelet

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (1-11)$$

## 2.1.6 Aprendizaje automático o aprendizaje de máquina

El aprendizaje de maquina consiste en la construcción algoritmos capaces de interpretar comportamientos y reconocer patrones mediante modelos matemáticos y de información suministrada (Valencia S., 2019). El aprendizaje se obtiene cuando se ajustan de manera automática los parámetros de los modelos y se adaptan a los datos del entrenamiento (Huertas Mora, 2020).

### Entrenamiento supervisado

El entrenamiento supervisado es una técnica que permite deducir una función partiendo de la introducción de datos llamados características y otros datos llamados etiquetas o clases las cuales son conocidas, a partir de los que se construyen modelos matemáticos para hacer la clasificación de los datos observados. Estos algoritmos de entrenamiento se categorizan por la diferenciación de acuerdo a la variable evaluada (cuantitativa o cualitativa). Para resultados cuantitativos se emplean algoritmos regresión como la regresión lineal, soporte de vectores, regresión de árboles de decisión, entre otros, y para resultados cualitativos se usan algoritmos de clasificación como máquina de soporte de vectores, arboles de clasificación, regresión logística, etc. (Huertas Mora, 2020).

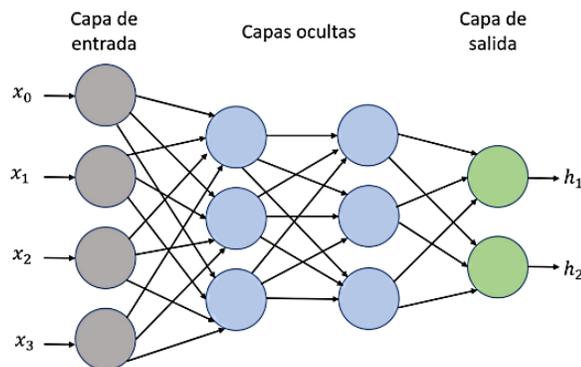
### Redes neuronales artificiales

Las redes neuronales artificiales (RNA) son un modelo artificial (computacional) y simplificado que se asemeja a su homólogo biológico en características básicas como autoadaptabilidad, auto organización y la tolerancia a errores para el tratamiento de la información. La funcionalidad de esta red se da como un conjunto de unidades llamadas neuronas artificiales, las cuales al estar interconectadas permiten transmitir señales entre sí. La información de entrada pasa por la red donde al ser sometida a diversas operaciones produce una etiqueta de salida (Match, 2001; Quiñones Huatangari et al., 2020).

Para el desarrollo de este trabajo se hace relevante la implementación de una estrategia basada en el procesamiento de señales, pues permite establecer etiquetas de salida asociadas los datos de entrenada introducidos en la red.

## Redes de Aprendizaje profundo

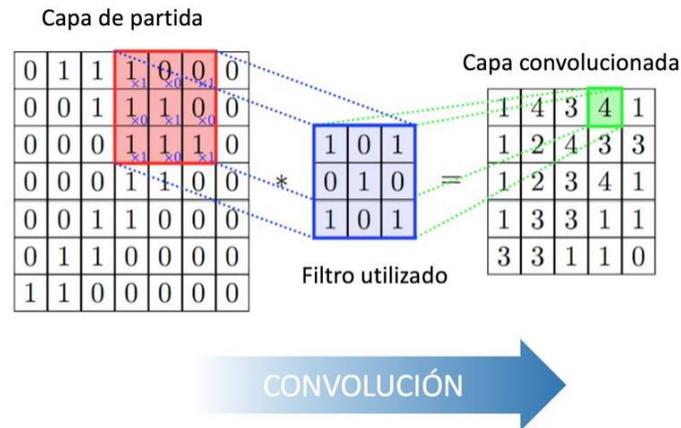
Una red neuronal de aprendizaje profundo (DNN por sus siglas en inglés) se obtiene cuando se agrupan varias capas (figura 2-7), permitiendo esto hacer la modelación de relaciones complejas de datos. Una de las características de las DNN para el estudio de pronósticos de serie de tiempo es que aportan a problemas con dependencias complejas no lineales entradas con diversas variables y pronósticos de varios pasos de tiempo (Huertas Mora, 2020).



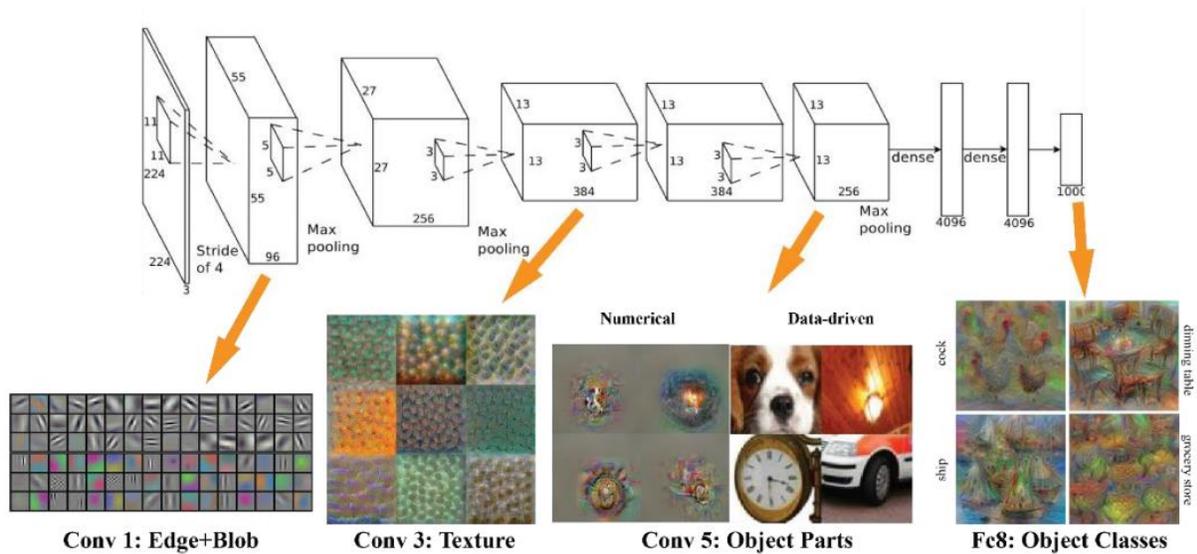
**Figura 2-7** Estructura de una red neuronal profunda.  
Fuente Huertas Mora, 2020

## Redes Neuronales Convolucionales (CNN)

Este tipo de red fue diseñada para resolver problemas mediante el análisis de imágenes, aunque actualmente también ha sido empleada en la clasificación de series de tiempo, arrojando buenos resultados. El aprendizaje y la extracción automática de características (figura 2-8 y figura 2-9) de datos del tipo serie de tiempo por medio de CNN permite la aplicación de modelos que incluyen capas convolucionales para la clasificación de fallas (Huertas Mora, 2020).



**Figura 2-8** Red convolucional.  
Fuente: (Tejada Layme & Gonzales Chama, 2020)



**Figura 2-9** Funcionamiento de una red Convolucional para la clasificación de imágenes.  
Fuente : (Tejada Layme & Gonzales Chama, 2020)

**Tabla 1** Arquitectura de la red convolucional para GoogleNet y Squeezenet.

Características	Red convolucional	
	Googlenet	Squeezenet
Tamaño de imágenes	[224 224]	[224 224]
% de datos de entrenamiento	80	80
% de datos de validación	20	20
Número de capas	144	68
Número de épocas	20	15
Frecuencia de iteraciones	10	7
Número de iteraciones	15	15

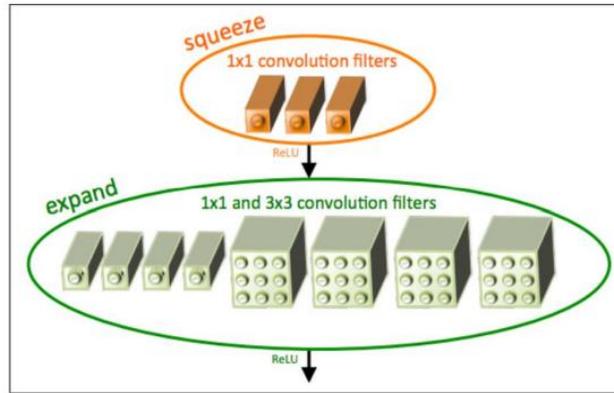
### Arquitecturas de redes convolucionales (Deep)

Las arquitecturas se emplean para la extracción de las características, las cuales se emplean para la clasificación y detección de etiquetas. El entrenamiento de las redes consiste en ajustar cada uno de los pesos de las entradas de todas las neuronas que forman parte de dicha red, con el fin de que las respuestas de la capa de salida se ajusten lo más posible a los datos de entrada. A continuación, se describen la arquitectura de las redes utilizadas en esta investigación.

**GoogleNet.** Es una red profunda que en su arquitectura (figura 2-10) presenta siete millones de parámetros con nueve módulos de inicio. Esta red presenta 22 capas conformadas por cuatro capas convolucionales, cuatro de agrupación máxima, tres de agrupamiento promedio, cinco completamente conectadas y tres de *softmax* para los clasificadores auxiliares de la red (Maeda Gutiérrez, 2019; Tejada Layme & Gonzales Chama, 2020).

**SqueezeNet.** Esta red convolucional tiene un total de 68 capas, de las cuales 18 son de profundidad. Esta red está compuesta por capas de compresión (squeeze) con una convolucional comprimida de un solo filtro 1x1, que integran a una capa de expansión

(*expand*) con varias mezclas de filtros 1x1 y 3x3 como se observa en la figura 2-11 (Ortega Triana, 2021).



**Figura 2-10** Estructura de los filtros convolucionales SqueezeNet.  
Fuente: (Ortega Triana, 2021)

**Red convolucional propuesta desarrollada dentro de la experimentación.** Es una red compuesta por 15 capas, 32 épocas, frecuencia de validación y siete iteraciones de validación

### Estructura de Red de reconocimientos de patrones

**Patternet:** Es una estructura neural sin capas profundas, conformada por un total de 10 capas para un entrenamiento del 80% y una validación del 20% y con un numero de 22 épocas.

### Entrenamiento no supervisado

En el entrenamiento no supervisado no se conocen las “etiquetas” de los datos (ejemplo buena o mala), debido a esto el algoritmo debe aprender a describir como es la estructura de los datos y reconocer patrones con lo que se generan nuevas entradas (Valencia S., 2019). En este tipo de entrenamiento se aplica el análisis por componentes principales y la agrupación de datos. La segmentación de los datos permite identificar patrones o agrupaciones de un conjunto de datos de múltiples dimensiones (Huertas Mora, 2020).

## Reducción de la dimensionalidad

La reducción de la dimensionalidad se emplea en el aprendizaje automático para disminuir el sobreajuste, visualizar e interpretar un conjunto de datos de alta dimensión, así como, como disminuir el costo computacional.

Este tipo de métodos estadísticos se pueden emplear para el aprendizaje supervisado y no supervisado, siendo el análisis de componentes principales (Pca) y la descomposición de componentes singulares (SSD) los algoritmos más empleados para las reducciones. Mediante estos métodos de reducción se pueden mapear conjunto de datos y llevarlos a subespacios de menor dimensión que contienen toda la información agrupada, representativa y significativa, favoreciéndose la comprensión, eliminándose ruidos en los datos y redundancias, con los que se mejora la clasificación de estos (Arroyo-Hernández, 2016).

El análisis de componentes principales (PCA), es un método matemático que relaciona un grupo de variables y las transforma en un grupo pequeño que sale por relacionar linealmente dichas variables. El propósito fundamental de este método es reducir la dimensionalidad del conjunto de datos e identificar las nuevas relaciones (Velez-Langs, 2014).

Esta técnica consiste en analizar datos de entrada que contienen diferentes observaciones descritas por variables independientes o dependientes y con relaciones no conocidas entre sí. En el PCA se realiza inicialmente la transformación lineal de los datos a un sistema de coordenadas ortogonales, donde los vectores de proyección de los datos de entrada son las direcciones de máxima varianza y las variables de estos datos de datos de entrada se llaman componentes principales (Enríquez, 2020).

K-means es un algoritmo empleado en el entrenamiento no supervisado, fácil de implementar para la extracción y agrupamiento de grandes cantidades de datos. Este tipo de algoritmo permite encontrar las K agrupaciones o particiones que están cercas y asociadas entre sí, y las lejanas que también están asociadas (Carvalho et al., 2019).

## Árbol de decisión

Los árboles de decisiones son diagramas que permiten definir una ruta lógica. Dichos diagramas parten de un nodo principal y desde allí se derivan otros nodos los cuales se fundamentan en resultados posibles del análisis. Un árbol de decisión es entonces el conjunto de características previamente definidas en una estructura, de tal manera que permite determinar una decisión final que sea adecuada en la solución de una problemática (Aranda & Sotolongo, 2013) y que requieren de un entrenamiento para ajustar el desempeño de la decisión.

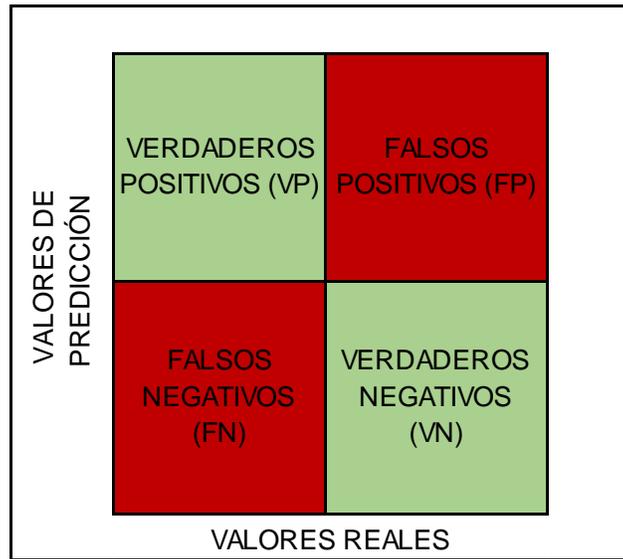
## Validación cruzada

La técnica de validación cruzada es una técnica utilizada para garantizar que los datos de la partición sean independientes en función de los datos de entrenamiento y los datos de prueba. La principal característica de este método consiste en calcular la media aritmética de las evaluaciones obtenidas; la selección de esta técnica es un pilar fundamental en el proceso analítico de un modelo de predicción funcional como mecanismo de generación de datos (Ochoa, 2019).

## Estrategia de evaluación

- **Matriz de confusión**

La matriz de confusión (figura 2-11) es un procedimiento de inteligencia artificial que ayuda a valorar y visualizar el desempeño de un algoritmo basado en el aprendizaje supervisado. Las columnas en la matriz representan el número de predicciones de las clases, y las filas hacen referencia a las instancias en la clase real (Valencia S., 2019). La importancia de este método se fundamenta en que permite identificar cómo y dónde el sistema confunde las dos clases reales con las predichas (Ariza-López, Rodríguez-Avi, & Alba-Fernández, 2018).



**Figura 2-11** Gráfico de matriz de confusión  
Fuente propia

$$Exactitud = \frac{VP+VN}{VP+VN+FP+FN} \quad (2-1)$$

Donde: VP son los datos verdaderos positivos, indican la porción de una buena predicción; VN relaciona los verdaderos negativos e indica la porción de una predicción buena de los negativos; FP es el porcentaje de falsos positivos y FN relaciona los positivos clasificados como negativos.

**Precisión:** correspondiente a una clasificación puede ser medida calculando el número de datos correctamente reconocido, la cantidad de datos correctamente reconocidos que hacen parte de clase y los datos que no fueron correctamente asignados.

$$Precisión = \frac{VP}{VP+FP} \quad (2-2)$$

**Sensibilidad:** corresponde a la posibilidad de clasificar correctamente la información evaluada. Esta dada por la ecuación 2-3.

$$Sensibilidad = \frac{VP}{VP+FN} \quad (2-3)$$

- **Característica Operativa del Receptor (Curva ROC)**

La curva ROC es una representación gráfica bidimensional de la proporción de verdaderos positivos respecto a los falsos positivos, que permite evaluar el rendimiento de un modelo por medio del cual se discriminan dos categorías (por ejemplo, para este estudio buena o mala). En este tipo de gráficos en el eje de las ordenadas se expresa la sensibilidad y en el de las abscisas los valores  $1 -$  especificidad para distintos puntos de corte sobre el valor cuantitativo estimado por el modelo (Montaño, 2002). La sensibilidad ( $S_E$ ) de un valor  $X$  es definida como la probabilidad de obtener un resultado positivo y viene expresada por la ecuación (1-12) y se obtiene de un subgrupo de casos de fallo ( $D=1$ ), y la especificidad ( $S_P$ ) es definida como la probabilidad de obtener un resultado negativo, ecuación (1-13) y es calculada en el subgrupo de casos sin fallo (Pérez, 2015).

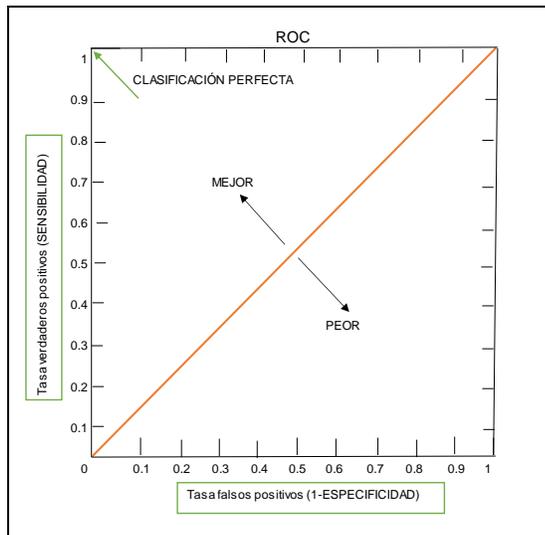
$$S_E(x_0) = TPR = P(X > x_0 \mid D = 1) \quad (1-12)$$

Dónde:  $X$  es la variable aleatoria continua;  $D$  es el estado, siendo  $D = 0$  verdadero y  $D = 1$  fallas;  $x_0$  es el punto de corte y TPR es la proporción de verdaderos positivos.

$$S_P(x_0) = TNR = P(X \leq x_0 \mid D = 1) \quad (1-13)$$

Siendo TNR la proporción de verdaderos negativos.

La curva ROC (figura 2-12) proporciona herramientas para seleccionar los modelos posiblemente óptimos y descartar modelos subóptimos en un plano dividido en dos dimensiones en la curva define un patrón de separación entre estos planos. Es así como la curva ROC permite visualizar, organizar y seleccionar clasificadores según su comportamiento (Pérez, 2015).



**Figura 2-12** Curva ROC  
Fuente propia

## 2.2 Estado del arte

### Antecedentes de investigaciones similares

A continuación, se exponen algunas investigaciones realizadas en las que se estudian la aplicación tecnologías no destructivas como la emisión acústica, la vibración, ultrasonido y el análisis de estos mediante modelos de aprendizaje profundo, algoritmo de máquina de soporte vectorial (SVM), para la detección de fallas en válvulas y rodamientos.

### 2.2.1 Aplicación de emisión acústica (EA) y señales de ultrasonido

En un estudio realizado, (Meland, Henriksen, Hennie, & Rasmussen, 2011) se evaluaron diferentes tecnologías no destructivas y de aplicación remota como la emisión acústica, presión dinámica y la vibración, para detectar fugas en válvulas tipo bola de cuatro pulgadas. El ensayo consistió en instalar válvulas con una fisura inducida de un mm o dos fisuras de un mm de ancho a cinco mm de distancia una de la otra en los sellos de politetrafluoroetileno (PTFE), esto con el objetivo de evaluar flujos de agua, glicol o nitrógeno. La falla se monitorea a una frecuencia de 20 KHz para una señal de tres segundos longitud y con nueve canales para captura de datos, de los cuales dos canales fueron para los sensores de EA (banda inferior de 0 a 100 kHz y banda ancha de 100 kHz a 1 MHz) y los otros corresponden al acelerómetro (con capacidad de medición de frecuencia hasta 10 kHz), los sensores de presión estática (uno en la cavidad de la válvula y el otro a la salida del flujo); los sensores de presión dinámica y el medidor de flujo.

Los resultados mostraron que las tasas de fuga variaron de acuerdo con el tipo de líquido empleado y a la fisura, obteniéndose mejores resultados para nitrógeno y el daño de doble ranura. Los resultados obtenidos de los diferentes sensores mostraron que la emisión acústica produce una buena correlación para los tipos de fisura cuando se emplea nitrógeno o glicol como fluidos, este último en banda inferior. Adicionalmente, se encontró que los perfiles de los espectros dependen del tipo de daño en el sello y que la parte de los espectros con la mayor respuesta está por debajo de 500 kHz.

Como conclusión se identificó en este estudio que el uso de sensores de EA y presión dinámica pueden ser empleados como métodos de detección remota de fugas en válvulas tipo bola. Lo cual se soporta en el hecho de que los coeficientes de correlación y los espectros de frecuencia de las señales mostraron la predicción de la tasa de fuga bajo condiciones determinadas.

En la investigación realizada por (Kim et al., 2017) emplearon el ultrasonido, la EA (sensor en el centro de la válvula) y la vibración para evaluar el desgaste y degradación de las válvulas de retención tipo oscilante. En los resultados para la fuga se encontró que la EA (rms) es directamente proporcional a la presión o rpm para un mismo tamaño de fuga e igualmente esta incrementa con el tamaño de la fuga. Respecto al desgaste del disco, el espectro de frecuencia estuvo en 150 a 250 kHz y para el objeto extraño de 100 a 150 kHz.

Como conclusión de este estudio se pudo identificar el espectro de desgaste del disco y del objeto extraño que genera fuga. Adicionalmente, la emisión acústica brinda información de interés en caudales bajos de la fuga y flujos inestables. Así mismo, con el monitoreo y detección de las EA se pueden conocer la degradación y envejecimiento de este tipo de válvulas.

### **2.2.2 Análisis de la vibración para detectar fugas en válvulas**

En un estudio realizado en (Venkata & Rao, 2019) se evaluó la avería en válvulas de control neumático analizando el cambio de la vibración en la tubería generada por variaciones en el patrón flujo de entrada (0-1000 lph) y suministro de presión. La válvula de control fue diseñada para operar entre 3 a 15psi. Lo cual es controlado por la corriente de entrada de 4-20 mA. En el ensayo se colocó un acelerómetro en la salida del caudal para obtener los datos de vibración necesarios para detectar dos tipos de fallos inducidos manualmente (flujo de entrada y presión de suministro). En el estudio se midió la variación de la señal, observándose variaciones proporcionales en el flujo de salida. Los datos de vibración se procesaron usando una técnica de procesamiento de señales tipo amplificación y la transformada rápida de Fourier. Posteriormente las señales de vibración se clasificaron

como fallos o normales mediante el algoritmo de máquina de soporte vectorial (SVM). Los resultados arrojaron que, de los 224 fallos inducidos en la válvula de control, 217 casos fueron detectados, indicando que, utilizando las señales de vibración, es posible detectar fallos en la válvula de control con una buena exactitud (97%).

En un estudio similar (El-Zahab, Mohammed Abdelkader, & Zayed, 2018) se empleó el método de vibración para identificar fugas en tuberías de suministro de agua a presión. En este trabajo se colocaron acelerómetros inalámbricos como sensores de vibración (de 0 Hz a 800 Hz) en el exterior de las válvulas que conectaban tuberías de hierro fundido de una pulgada y tuberías de PVC. Las señales de vibración fueron capturadas durante ocho horas de experimentación, se evaluaron y analizaron mediante máquinas de soporte de vectores (SVM), árbol de decisión y el clasificador Naive Bayes. Los resultados del estudio mostraron que los modelos desarrollados tuvieron una precisión del 98.25% para diferenciar entre estados con fugas y sin fugas. Adicionalmente, se logró la identificación de fugas grandes y pequeñas con una precisión del 83.71%. entre las tres técnicas utilizadas el árbol de decisión obtuvo el mayor rendimiento ya que proporcionó una alta precisión para la detección de fugas y el tamaño de estas. Estos resultados indican que el uso de acelerómetros como sensores de vibración constituyen una herramienta la detección temprana del fallo en las válvulas analizadas.

### **2.2.3 Análisis de fallas en rodamientos usando autocodificador convolucional y transformación de ondas continuas**

En un estudio realizado en (Kaji, Parvizian, & van de Venn, 2020) se propuso un método para construir un índice de salud (HI) a partir de la transformación de señales vibratorias en imágenes bidimensionales utilizando la Transformada Wavelet Continua (CWT) y el uso de un modelo de aprendizaje profundo (modelo autocodificador convolucional, CAE) tipo red neuronal. Los resultados obtenidos mostraron que el método propuesto es sensible a la degradación inicial del rodamiento y es consistente con el proceso de degradación, además, tiene un buen desempeño para detectar fallas incipientes. Del estudio se concluyó que el HI construido con este método es capaz de representar el estado del rodamiento y realizar un seguimiento de la evolución de la degradación durante la vida útil

del mismo. Además, la construcción del HI con el método propuesto no requiere conocimientos previos ni datos históricos de falla. Por lo tanto, es adecuado para aplicaciones industriales donde no se tienen históricos previos del sistema a analizar.

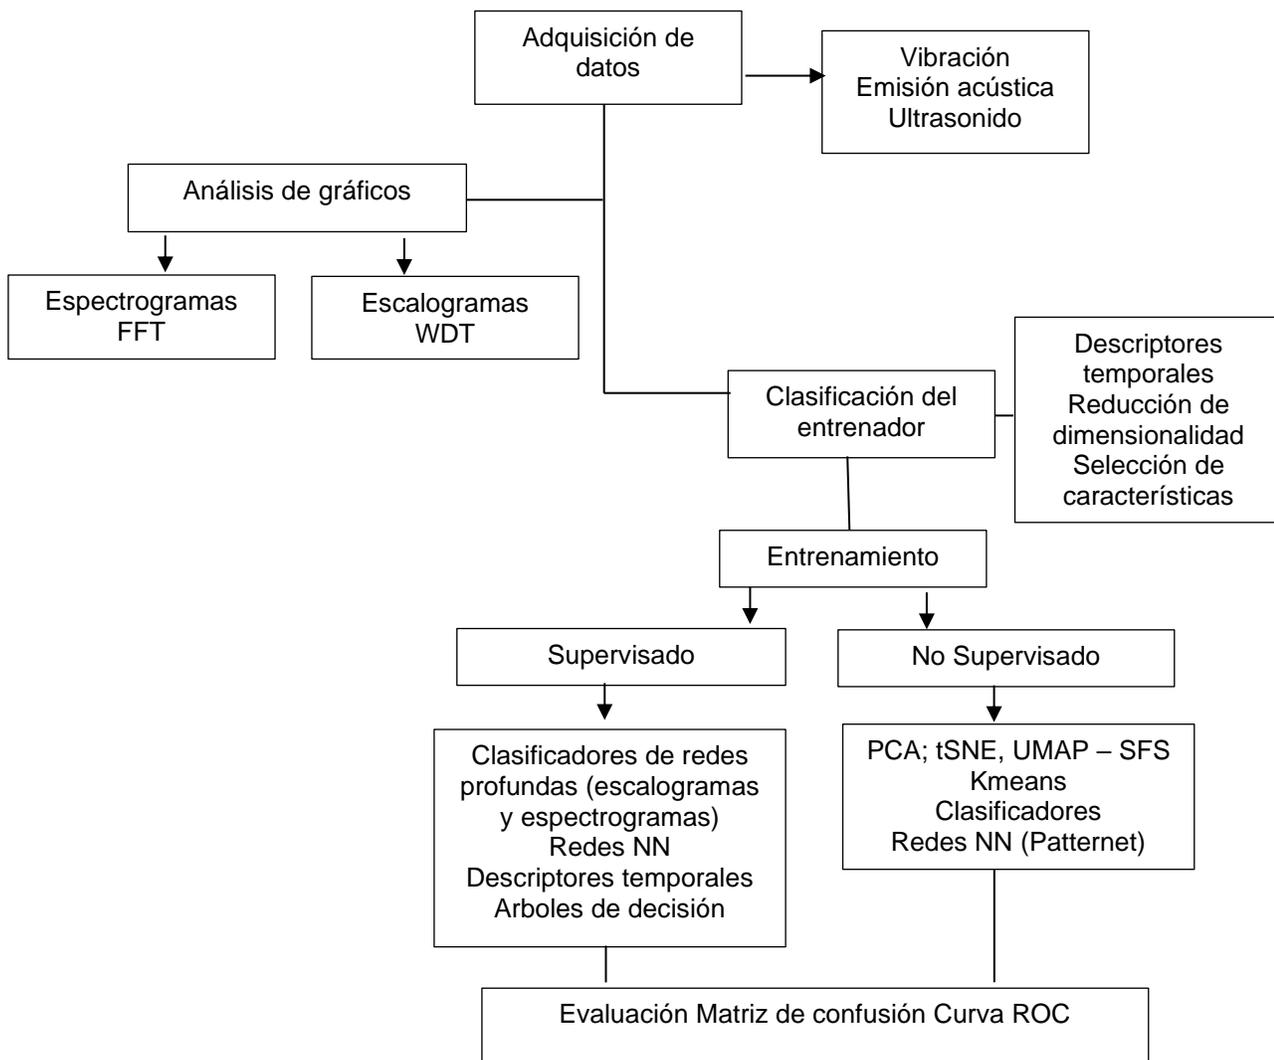
#### **2.2.4 Sistema de diagnóstico de fallas del motor basado en el análisis de la intensidad del sonido y la red neuronal de pre procesamiento de paquetes de ondículas**

Para el diagnóstico del estado de un motor de gasolina (Wang, Liu, Guo, & Wang, 2020) emplearon en su investigación técnicas de análisis de intensidad de sonido, un modelo de análisis de paquetes de ondículas incompletas (WPA) y redes neuronales artificiales (ANN) y un método de preprocesamiento WPA. Las señales de ruido se capturaron a partir de un motor en buen estado y con fallas. Las características de las señales se extrajeron con un modelo WPA incompleto, el cual estaba constituido por una DWT de cinco niveles y una WPA de cuatro niveles y la clasificación de las características se realizó con las ANN de multicasas.

Los resultados obtenidos arrojaron que debido a las características de tiempo- frecuencia y reconocimiento de patrones el modelo propuesto WPA-ANN basado en señales de ruido es efectivo para el diagnóstico de las fallas del motor de gasolina. Adicionalmente, Concluyen que este modelo puede ser utilizado para el diagnóstico de fallas en vehículos basados en las señales de ruido.

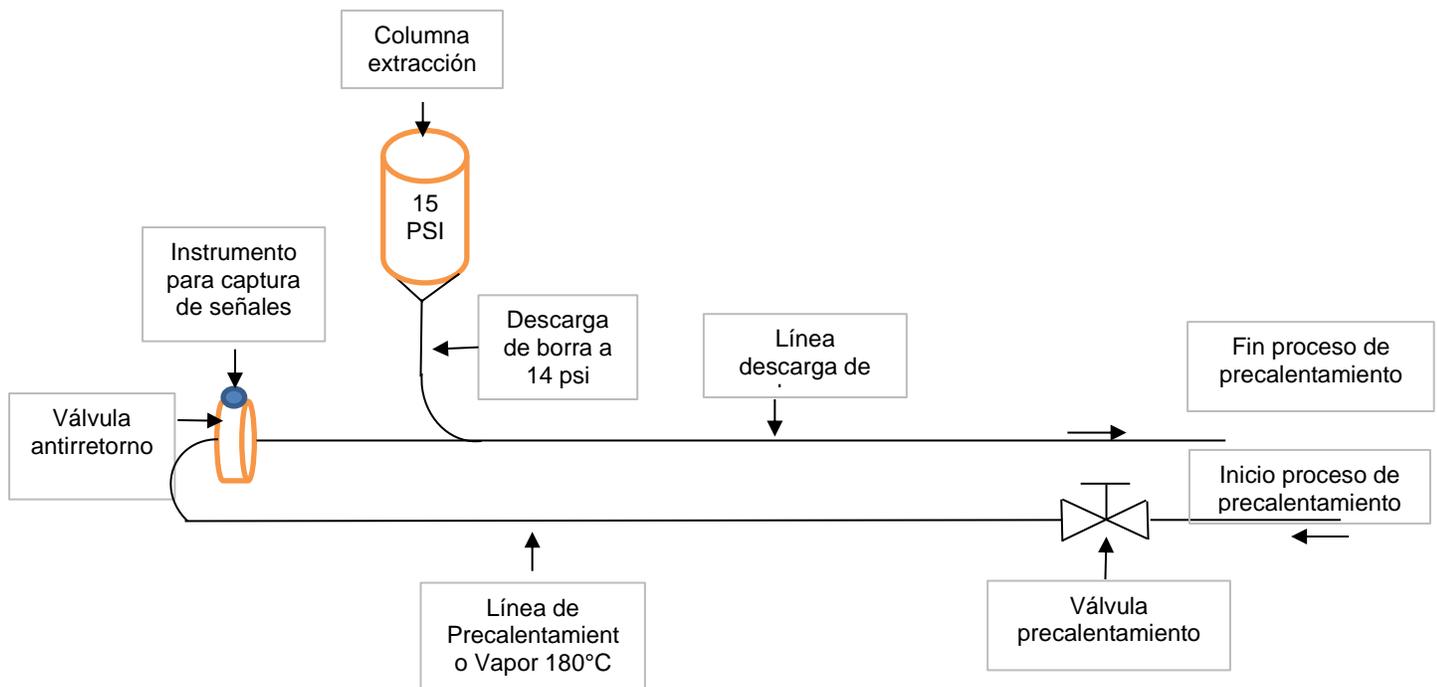
### 3.METODOLOGÍA

La metodología que se propone en este capítulo comprende la descripción detallada de la toma y procedimiento de las señales mediante las técnicas de vibración, ultrasonido y emisión acústica. Así mismo se plantea la descripción, proceso de entrenamiento de las redes neuronales y la definición de las medidas de desempeño que permitan evaluar las redes empleadas para los análisis. En la figura 3-1 se hace una descripción del proceso.



### 3.1 Procedimiento de adquisición de datos

La toma de los datos se realizó con la captura de 80 datos de las señales temporales de vibración, emisión acústica y ultrasonido sobre válvulas en buen estado de funcionamiento (buenas) y válvulas con fallas en su funcionamiento (malas).



**Figura 3-2** Disposición de instrumentos para la toma de las señales temporales en línea de descarga de borra de café.  
Fuente propia

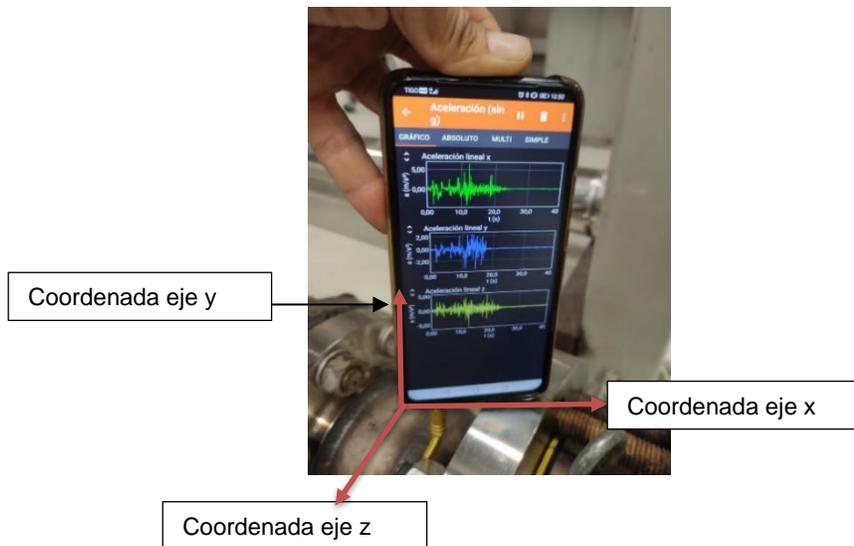
La toma de los datos se efectuó con la colocación de los instrumentos de medición ubicados sobre las válvulas antirretorno tipo clapeta oscilante que están instaladas en la línea de descarga de borra como se observa en la figura 3-2.

#### 3.1.1 Vibración

Las señales de vibración se tomaron con los sensores de acelerómetro (con potencia 0,3 mA, Precisión 0,0000095768 m/s<sup>2</sup> y rango 78,45 m/s<sup>2</sup>) y micrófono del teléfono inteligente

de la marca Huawei modelo Y9 Prime y la aplicación *Phyphox* sin g (sin gravedad) de libre acceso. Este tipo de acelerómetro tiene estructuras cristalinas microscópicas que responden a las fuerzas de aceleración e interpreta el voltaje de los cristales para definir la velocidad y dirección del teléfono.

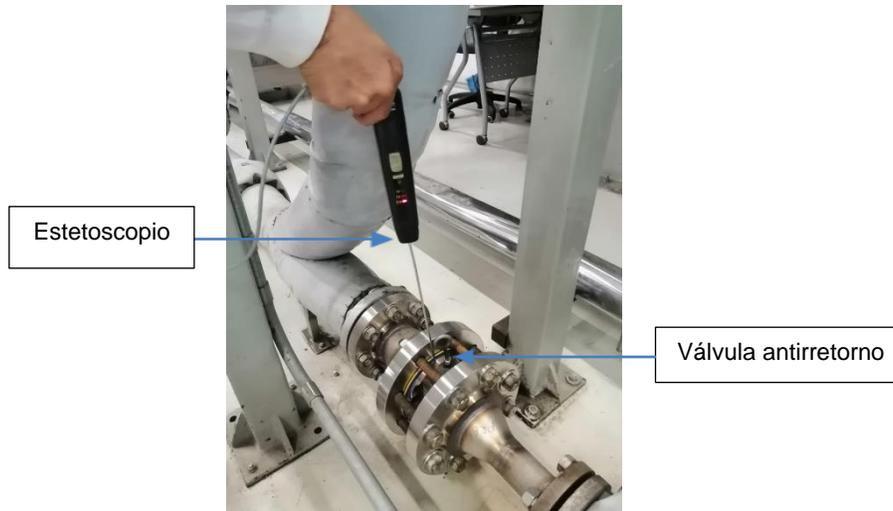
Posterior a la activación de la válvula se procedió a la lectura de la señal, capturándose señales para la aceleración lineal en las coordenadas x, y, z y absoluta como se observa en la figura 3-3. sobre las cuales se tomaron 40 señales de un minuto de duración para cada una.



**Figura 3-3** Aceleración lineal en las coordenadas x, y, z.  
Fuente Propia

### 3.1.2 Emisión acústica

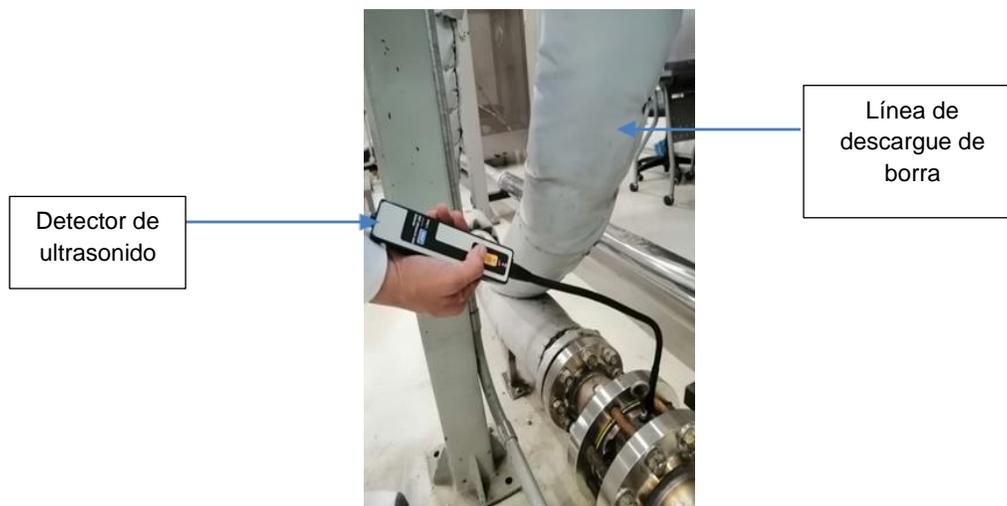
La captura de las señales de emisión acústica se realizó con un estetoscopio electrónico SKF TMST 3 con rango de frecuencia de 30 Hz -15 kHz, acoplado con una sonda de 70 mm para la captura de las señales audibles. Estas señales se convirtieron en audibles a una tasa de 40400 Hz por un tiempo de 52 segundos aproximadamente, dichas señales se grabaron por medio del celular en formato m4a.



**Figura 3-4:** Toma de señales en la válvula  
Fuente propia

### 3.1.3 Ultrasonido

Las señales ultrasónicas fueron captadas con un detector ultrasónico de fugas TMST 1 de SKF, el cual cuenta con un sensor abierto de 16 mm de diámetro interior y 19 mm de diámetro el exterior, con capacidad de detectar frecuencias de hasta 38,4 kHz,  $\pm 2$  kHz (-3 dB); acoplándose a este los auriculares y una sonda de longitud 70 mm. Estas señales se convirtieron en audibles a una tasa de 40400 Hz por un tiempo de 52 segundos aproximadamente, dichas señales se grabaron por medio del celular en formato m4a.



**Figura 3-5:** Colocación detector ultrasónico de fugas TMST 1 para la toma de señales temporales ultrasónicas.  
Fuente propia

## 3.2 Descriptores de la señal

Las señales temporales se analizaron con 15 descriptores temporales seleccionados previamente los cuales se describen a continuación: media, máximo, mínimo, pico a pico, media absoluta, varianza, desviación estándar, curtosis, RMS, factor de forma, factor pico, oblicuidad, factor de impacto, factor de margen y estandarizado, para posteriormente emplear estos descriptores temporales en los modelos de entrenamiento supervisado y no supervisado. Adicionalmente, se obtienen las transformaciones de espectrogramas y escalogramas, para con estas realizar los entrenamientos de redes profundas.

## 3.3 Entrenamiento no supervisado

El entrenamiento no supervisado para la reducción de la dimensionalidad se realizó con los algoritmos PCA, t-SNE, UMAP; la selección de las características de las señales de vibración eje x y emisión acústica se realizó con SFS y la extracción y el agrupamiento de los datos por medio Kmeans para ubicar las características más cercanas entre sí.

La clasificación de las características se realizó mediante la red neuronal de reconocimiento de patrones sin capas profundas Patternet teniendo en su arquitectura 10 capas y haciendo la partición de los datos del 80% para entrenamiento y del 20% para validación.

### - Evaluación

Para la evaluación del entrenamiento no supervisado de las señales temporales se utiliza la combinación de la reducción de la dimensionalidad con el clasificador de la siguiente manera: Pca – Kmeans- Patternet; tSN-E - Kmeans – Patternet y UMAP-Kmeans- Patternet con el fin de obtener el mejor resultado del entrenamiento.

## 3.4 Entrenamiento supervisado

Este entrenamiento permite que a partir de datos y etiquetas de entrada y mediante un proceso de entrenamiento se logre obtener unas etiquetas de salida. Para este análisis se

utilizan redes convolucionales de Googlenet, Squeezenet y una red convolucional propuesta desarrollada durante la experimentación.

Adicionalmente, se realizó la representación gráfica de las señales mediante espectrogramas y escalogramas para las variables de mejor desempeño con el fin de identificar las mayores densidades espectrales de energía de la señal tomada.

Los descriptores temporales de la vibración en sus tres ejes X, Y y Z y la absoluta se evaluaron mediante el análisis estadístico de las siguientes variables: media, máximo, mínimo, pico a pico, media absoluta, varianza, desviación estándar, curtosis, RMS, factor de forma, factor pico, oblicuidad, factor de impacto, factor de margen y estandarizado

Para realizar la comparación de redes profundas de Googlenet, Squeezenet y una red convolucional propuesta desarrollada durante la experimentación se utilizan el arbole de decisión para todas las señales con el objetivo de verificar el desempeño de las redes analizadas.

#### - **Evaluación**

Para los algoritmos de entrenamiento supervisado se evaluó el desempeño de las diferentes técnicas por medio de la matriz de confusión y la curva ROC para las variables de mejor desempeño.

La matriz de confusión se analizó mediante las métricas de desempeño de exactitud, sensibilidad, precisión y especificidad y en la curva ROC se analizó el área bajo la curva para evaluar el comportamiento de los modelos.

## 4.RESULTADOS Y DISCUSIÓN

En este capítulo se presentan los resultados de cada una de las etapas expuestas en la metodología del trabajo. El objetivo principal de esta investigación es determinar la condición de las válvulas anti retorno tipo clapeta oscilante mediante el análisis de señales temporales y algoritmos de inteligencia artificial como Googlenet, Squeezenet, Patternet y Red convolucional propuesta desarrollada dentro de la experimentación.

### 4.1 Procedimiento de adquisición de datos

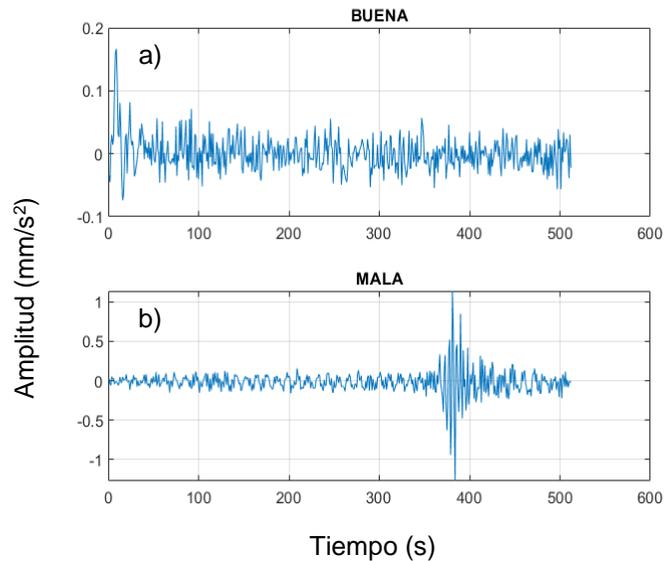
Los datos fueron tomados en la línea de descargue de borra de café de una planta industrial. La captura de las señales emitidas por la válvula tipo clapeta se realizó mediante herramientas de análisis no destructivo de vibración (en eje x, y, z y la absoluta), emisión acústica y el ultrasonido y la aplicación *Phyphox* (aceleración sin g), por un tiempo de 1 minuto, obteniéndose un total de 80 datos para cada una de las herramientas y etiquetados como 40 buenas y 40 malas, los cuales se estandarizaron a 512 datos por muestra eliminando los de tiempo muerto.

#### 4.1.1 Adquisición de las señales

##### 4.1.1.1 Vibración

El análisis de vibraciones logró identificar el comportamiento de la válvula en condición buena y mala. En la válvula buena figura 4-1 a) no se observan variaciones significativas

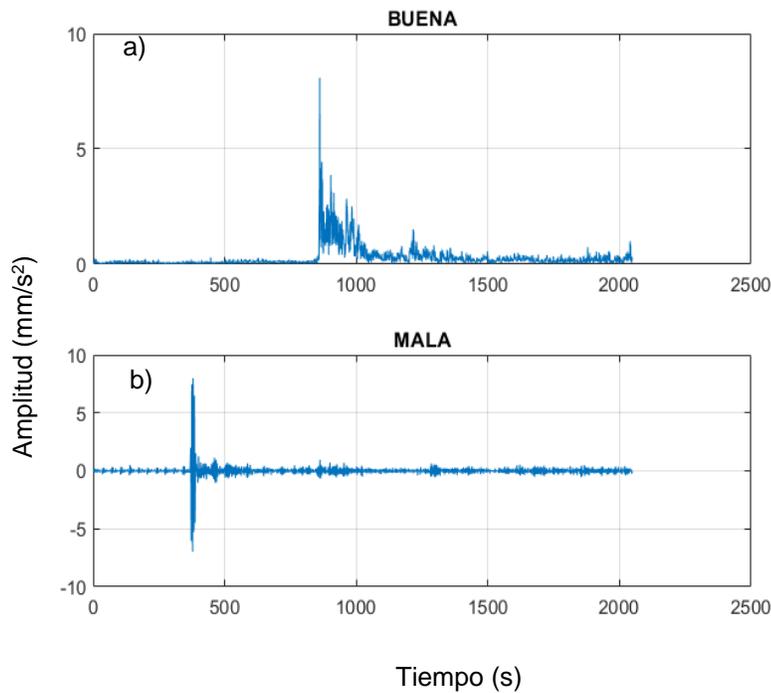
en los picos de la señal en relación al comportamiento de está, manteniéndose la amplitud por debajo de  $0,1 \text{ mm/s}^2$ . En el caso de la válvula mala figura 4-1 b) se observan picos que alcanzan una amplitud de la señal en un rango por debajo de  $-1 \text{ mm/s}^2$  y por encima de  $1 \text{ mm/s}^2$ , lo que muestra alto grado de variación de la señal.



**Figura 4-1** Señal temporal de la vibración eje x para la válvula buena y válvula mala  
Fuente propia

#### 4.1.1.2. Emisión acústica

De acuerdo a los análisis obtenidos en las mediciones con la emisión acústica se identifican variaciones en la señal que muestran diferencias en la condición de la válvula. En la señal obtenida de la válvula buena figura 4-2 a se observa un pico inicial hasta aproximadamente  $8 \text{ mm/s}^2$  y posteriormente, se presenta una rápida disminución de la amplitud por debajo de los  $3 \text{ mm/s}^2$  en el complemento de la señal, lo que indica que estabilidad de la señal. Para el caso de la válvula mala figura 4-2 b se observan picos que alcanzan una amplitud de la señal en un rango de  $-8 \text{ mm/s}^2$  a  $8 \text{ mm/s}^2$  aproximadamente, mostrando una variación marcada en la señal audible relacionada con el estado de la válvula.

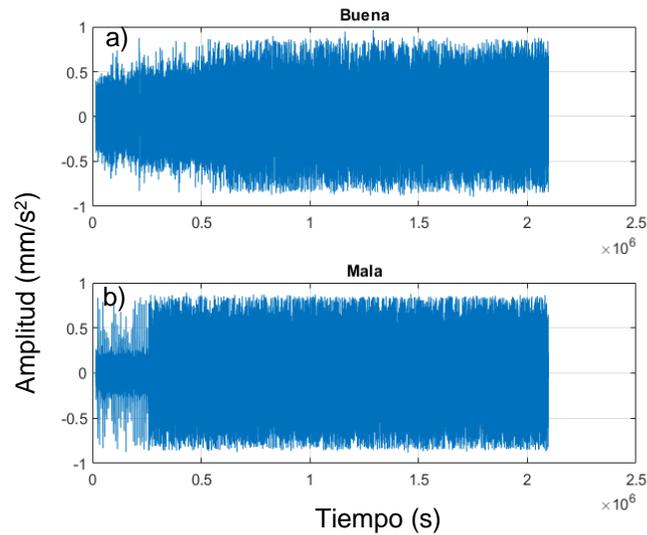


**Figura 4-2** Señal temporal emisión acústica para la válvula buena y válvula mala  
Fuente propia

#### 4.1.1.3. Ultrasonido

Para el caso de los análisis obtenidos con el ultrasonido no se logran identificar variaciones en la señal que demuestren diferencias en el estado de la válvula. Como se observa en la figura 4-3 la amplitud de la señal para ambas condiciones está en el rango de  $-9 \text{ mm/s}^2$  a  $9 \text{ mm/s}^2$ .

De acuerdo con el resultado obtenido de esta señal se puede definir que, para nuestro caso de estudio la medición realizada mediante ultrasonido no constituye una herramienta que permita diferenciar el estado de la válvula antirretorno.



**Figura 4-3** Señal temporal de ultrasonido para la válvula buena y válvula mala  
Fuente propia

Para la toma de datos de las tres técnicas se realizan en el mismo rango de tiempo inicial  $t_0$ ; la diferencia presentada en los valores de las diferentes figuras representa el momento donde cada técnica identifica variaciones en la señal tomada, es por ello que para el caso de Vibración la variación se da desde  $t_0$ , para las técnicas acústicas la variación se da aproximadamente en los valores de  $t_{400}$ .

## 4.2 Descriptores de la señal

La descripción temporal permite analizar el comportamiento de las señales en el dominio del tiempo con el fin de determinar la distribución de los datos en descriptores estadísticos que permitan definir las variaciones que se presentan en los diferentes puntos de la señal capturada.

En nuestro caso de estudio se definieron para vibración y emisión acústica 80 muestras para el análisis con los siguientes 15 descriptores temporales: media, máximo, mínimo, pico a pico, media absoluta, varianza, desviación estándar, curtosis, RMS, factor de forma, factor pico, oblicuidad, factor de impacto, factor de margen y estandarizado. Este análisis se define a partir de las iteraciones realizadas entre los descriptores con el método de

selección de características secuenciales (SFS por sus siglas en inglés) y se obtiene como resultado la selección de aquellos que tienen mayor significancia estadística, definiéndose para la vibración y emisión acústica los descriptores representados en la tabla 2.

**Tabla 2.** Temporales de vibración eje x y emisión acústica por el método SFS

Señal Temporal	Descriptores temporales
Vibraciones	Máximo, Mínimo, Pico a pico, Desviación Estándar, Curtosis, RMS, Factor de pico, factor de margen
Emisión Acústica	Promedio, Máximo, Mínimo, Pico a Pico

De acuerdo con los resultados obtenidos en la experimentación realizada se puede determinar que los descriptores seleccionados permitieron describir el comportamiento de los datos y mejorar la capacidad computacional para el análisis de los datos sin que se generen pérdidas en la información capturada.

### 4.2.1 Descriptores temporales para la vibración

En la tabla (3) y figura 4-4 se presenta el valor de los diferentes descriptores para la vibración en sus tres ejes (x, y, z) y la absoluta, en la que se evidencia que el máximo indica el valor numérico más alto del rango, para este se obtiene el valor más alto en la absoluta y el menor en el eje y.

El mínimo define el valor numérico más bajo del rango de los datos y se obtuvo en el eje x siendo de  $-0,3574 \text{ mm/s}^2$ ; Para el descriptor pico a pico el cual relaciona la distancia desde un pico positivo de la onda hasta un pico negativo de la misma arrojó como resultado que la mayor distancia de pico se da en el eje z y el menor en el eje x como se describe en la tabla 3.

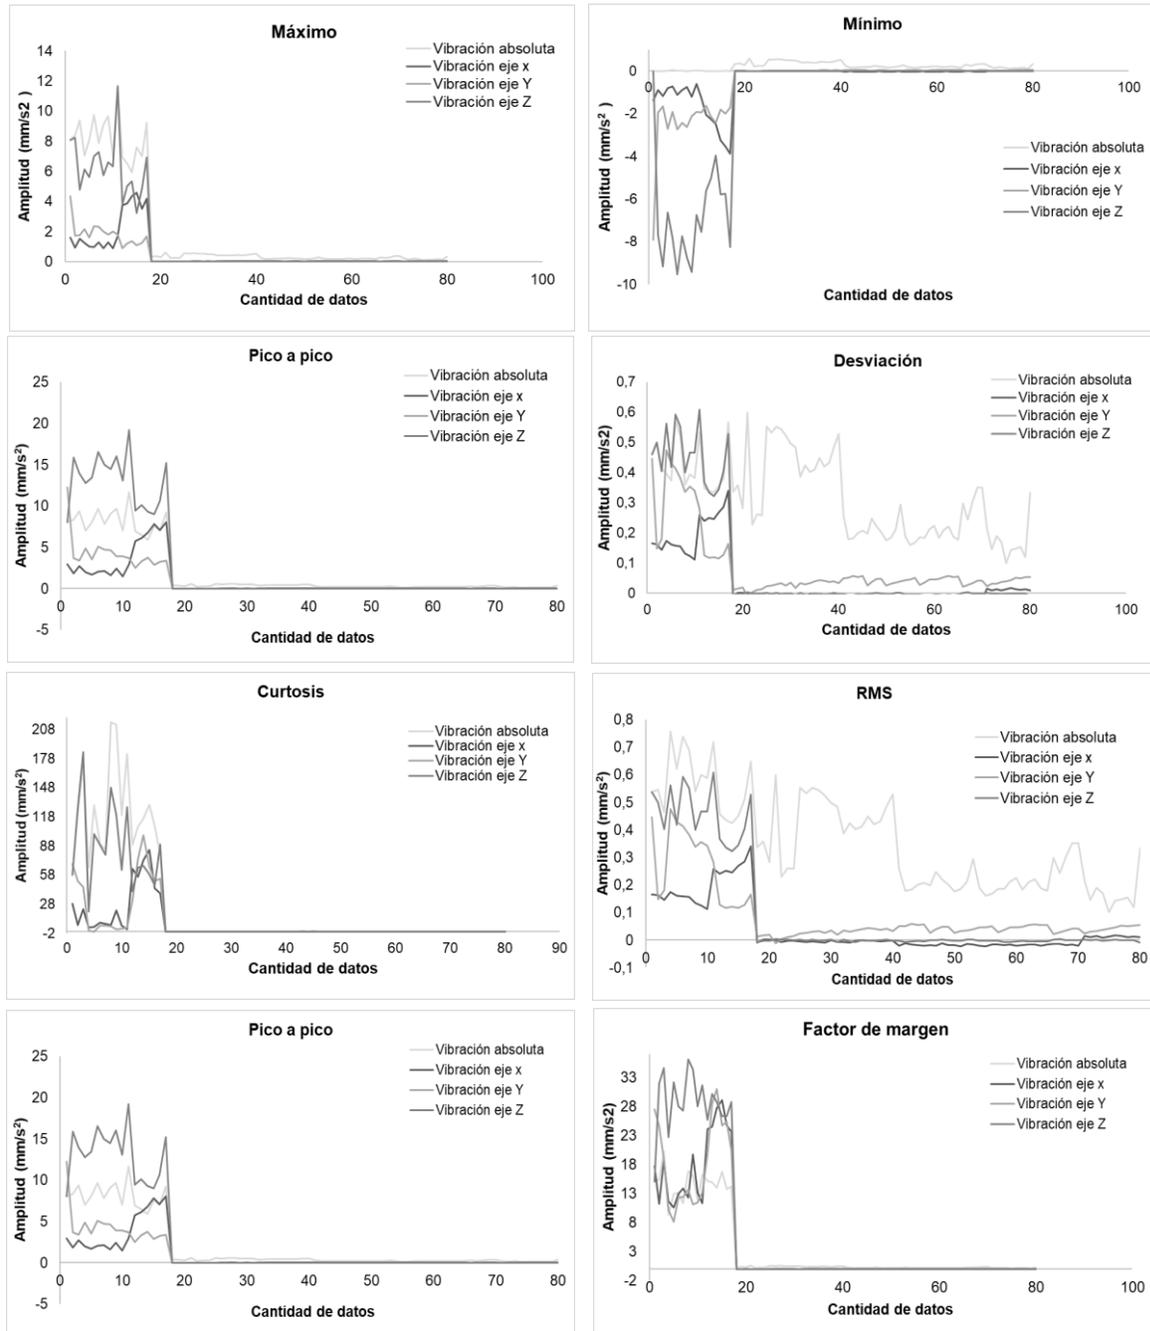
La medida de la dispersión de los datos o la desviación estándar analizada definió los valores respecto a la media, observándose que la mayor desviación se presenta en la vibración absoluta y la desviación menor de estos en el eje z. En cuanto curtosis se observó que la mayor elevación de la curva (distribución normal) se dio en la vibración absoluta y el aplanamiento de la misma en la vibración eje x.

Con el valor cuadrático medio - RMS de la forma de la onda, se obtuvo la magnitud de la señal en cada uno de sus ejes, observándose que la mayor se dio en la absoluta y la menor en el eje x (tabla 3).

**Tabla 3** Representación numérica de los descriptores temporales para vibración

Vibración	Valores de los descriptores temporales (mm/s <sup>2</sup> )							
	Máximo	Mínimo	Pico a pico	Desviación Estándar	Curtosis	RMS	Factor de pico	factor de margen
Eje x	0,4620	-0,3574	0,8133	0,0362	6,0348	0,0362	3,8265	3,925
Eje y	0,4185	-0,4899	0,9374	0,0860	7,2085	0,0861	3,9401	3,940
Eje z	1,3311	-1,4426	2,7723	0,0952	18,5876	0,0961	6,0883	6,088
Absoluta	1,9693	0,2319	1,9659	0,3188	26,2950	0,3500	3,3184	3,318

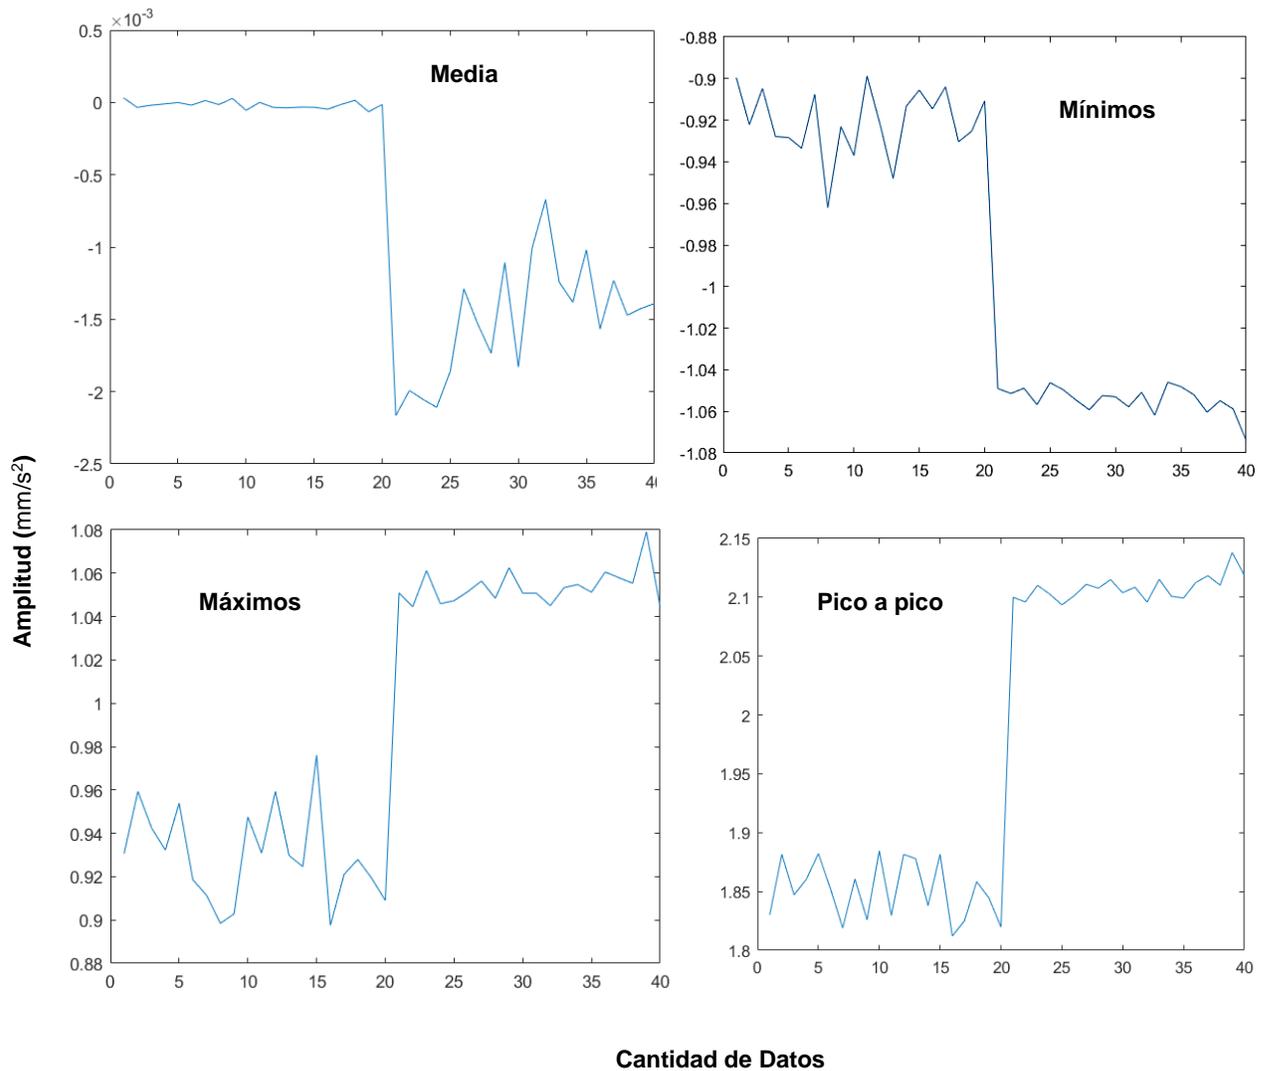
De acuerdo a los resultados obtenidos de los descriptores temporales anteriormente descritos la vibración en el eje x representa la mejor señal que mejor describe el desempeño de la válvula antirretorno.



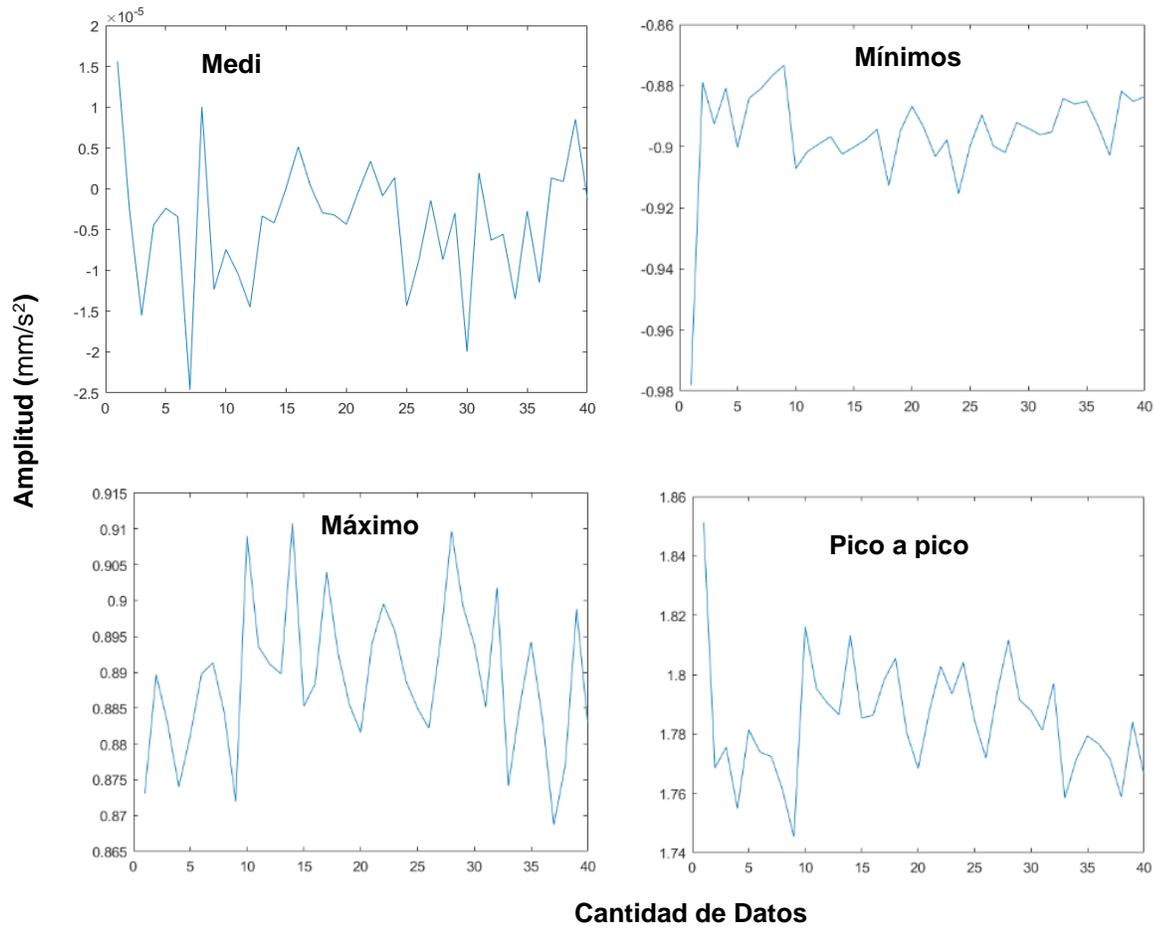
**Figura 4-4** Análisis de los descriptores temporales para vibración en eje x, y, z y absoluta.  
Fuente propia

### 4.2.2 Descriptores temporales para la emisión acústica

Como se observa en las figuras 4-5 y figuras 4-6, los resultados obtenidos de los descriptores temporales para la EA en el análisis del estado de la válvula, fueron la media con un valor de  $-0,825 \times 10^{-4}$ , el mínimo de  $-0,955 \times 10^{-4}$ , el máximo de  $0,940 \times 10^{-4}$  y el valor promedio de pico a pico de  $1,865 \times 10^{-4}$ .



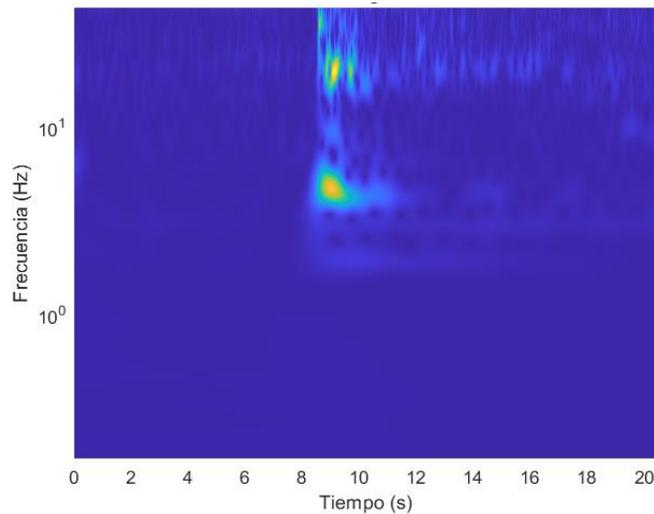
**Figura 4-5** Análisis de los descriptores temporales para la emisión acústica para la válvula buena.  
Fuente propia



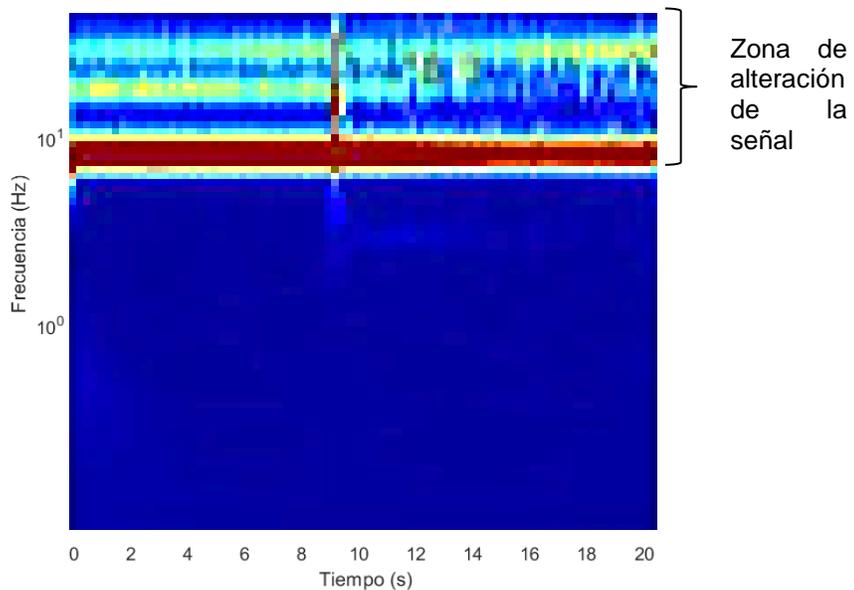
**Figura 4-6** Análisis de los descriptores temporales para la emisión acústica para la válvula mala Fuente propia

### 4.3 Análisis de escalograma para vibración eje x

La representación del escalograma (figura 4-7) muestra la señal espectral en función del tiempo y la frecuencia, con el fin de observar el comportamiento de esta respecto a la alteración o la continuidad de la señal tomada. Para este estudio se obtienen con este método 80 imágenes de señales de vibración con el fin de determinar el estado de la válvula antirretorno.



**Figura 4-7** Escalograma de la vibración eje x para la válvula buena  
Fuente propia



**Figura 4-8** Escalograma de la vibración eje x para la válvula mala  
Fuente propia

En los escalogramas se observan los mayores niveles de energía que se detectan mediante las señales temporales las cuales permiten la clasificación de los resultados partiendo de la intensidad de la energía. En la figura 4-7 se observa bajos niveles de energía en las diferentes ventanas del escalograma, relacionados con las mínimas alteraciones en la válvula antirretorno. Mientras que en la figura 4-8 se observa una zona de alteración de la señal con altas intensidades de energía en las ventanas aproximadamente a una frecuencia de  $10^1$  Hz, lo que indica altas variaciones relacionadas con el estado de la válvula antirretorno.

En concordancia con los resultados obtenidos, los análisis mediante los escalogramas permitieron la visualización energética del comportamiento de las señales de la vibración de la válvula en estado bueno y malo.

## 4.4 Entrenamiento no supervisado

Para este tipo de entrenamiento se hace un pre-entrenamiento ingresando unas características que buscan una clasificación de los datos. Este entrenamiento es no supervisado debido a que el algoritmo escoge como criterio de clasificación las características similares entre ellas y mide de la precisión del modelo, el cual se realiza utilizando las etiquetas esperadas (buena o mala) como si fuese un algoritmo supervisado.

La reducción de los datos se realizó con PCA, tSNE y UMAP y se combinó con la técnica de agrupamiento Kmeans, el cual asigna unas posiciones de diferentes puntos aleatorios en el plano, definiendo el número de vecinos más cercanos basado en sus características de similitud.

En la tabla 4 se observa de las combinaciones de los diferentes algoritmos de reducción de dimensionalidad (PCA, tSNE y UMAP) con la técnica de agrupamiento Kmeans y el clasificador Patternet. De los resultados obtenidos se observa que la combinación tSN-E – Kmeans- Patternet presenta las precisiones más altas con respecto a PCA – kmeans- Patternet y UMAP – Kmeans- Patternet.

**Tabla 4** Comportamiento de los casos analizados de los clasificadores no supervisado

Señal temporal	Precisión de algoritmos de reducción de dimensionalidad con el clasificador Patternet		
	PCA – kmeans-Patternet	tSN-E – Kmeans-Patternet	UMAP – Kmeans-Patternet
Vibración eje x	61%	<b>100%</b>	62.5%
Vibración eje y	55 %	80%	61%
Vibración eje z	60%	76%	59%
Vibración Absoluta	64%	82%	58%
Emisión acústica	75%	<b>100%</b>	75%
Ultrasonido	45%	65%	68%

En el análisis de cada una de las señales temporales se observó que las señales temporales de vibración eje x y la emisión acústica presentaron las precisiones más altas, mientras que el ultrasonido presentó la más baja precisión.

Se puede concluir que para los entrenamientos no supervisados el mejor desempeño se presenta en las combinaciones realizadas entre tSN-E - Kmeans - Patternet para las variables de vibración eje x y emisión acústica.

#### 4.4.1 Clasificadores de estrategias de reducción de dimensionalidad y agrupamientos

Para determinar la precisión de los métodos utilizados en la reducción de dimensionalidad se toman las señales temporales. Para realizar el análisis propuesto se toman los descriptores temporales obtenidos (ver tabla 2) y se ejecuta una reducción de dimensionalidad que busca disminuir el tamaño de la data. Este procedimiento permitió definir las eficiencias de las combinaciones utilizadas.

**Tabla 5.** Precisión de estrategias de reducción de dimensionalidad y clasificador.

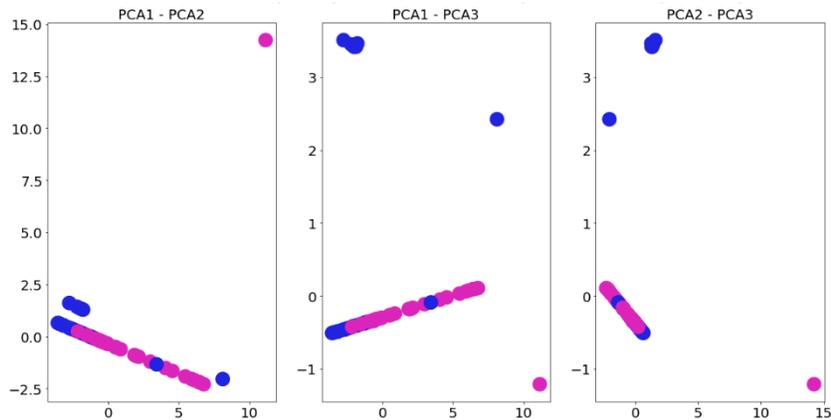
Señal temporal	PCA - Patternet	tSNE - Patternet	UMAP - Patternet
Vibración eje x	100%	<b>100%</b>	100%
Vibración eje y	75%	91,7%	100%
Vibración eje z	83,7%	100%	66%
Vibración Absoluta	83,35	91,7%	75%
Emisión acústica	100%	<b>100%</b>	100%
Ultrasonido	83,3%	91,7	66,7%

De los resultados obtenidos se observa en la tabla 5 que la combinación tSNE-Patternet presentó las presiones más altas con respecto a PCA-Patternet y UMAP- Patternet. Para las señales temporales analizadas con la combinación tSNE-Patternet se observó que la vibración eje x y la emisión acústica tuvieron las mejores precisiones.

#### 4.4.2 Aplicación de técnicas de reducción de dimensionalidad para la vibración eje x.

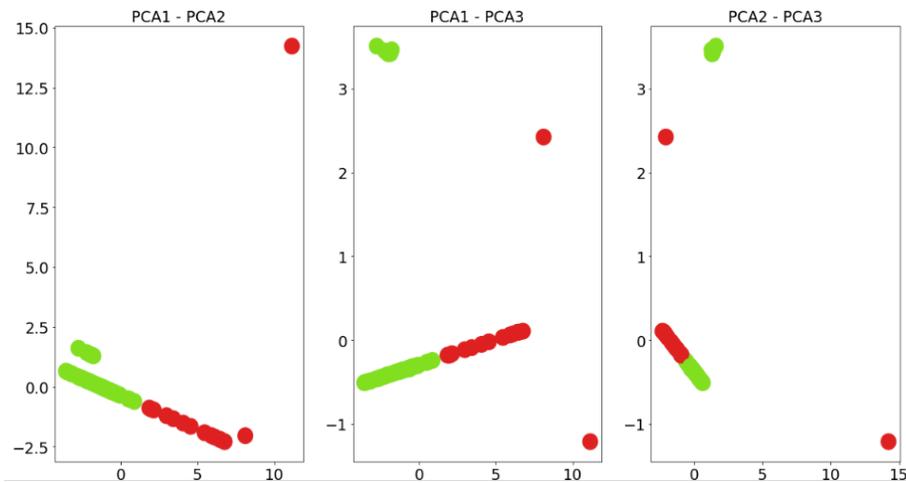
Se realizaron experimentaciones de reducción de dimensionalidad con el fin de disminuir de un conjunto de datos para mejorar la capacidad computacional requerida para el análisis, para lo cual se utilizaron las estrategias de entrenamiento no supervisado como PCA, tSNE y UMAP.

Para el análisis con PCA se realizó reducción de los datos a tres variables para lograr una exactitud superior al 80% en el entrenamiento de los datos ingresados. En la figura 4-9 se identificaron dos grupos con la distribución final de los datos, en los que se observa la dispersión de estos. De las tres variables finales se obtienen dos clasificaciones representadas en color azul para válvula buena y morado para válvula mala.



**Figura 4-9** Gráficos de distribución real por pares de componentes principales (PCA)  
Fuente propia

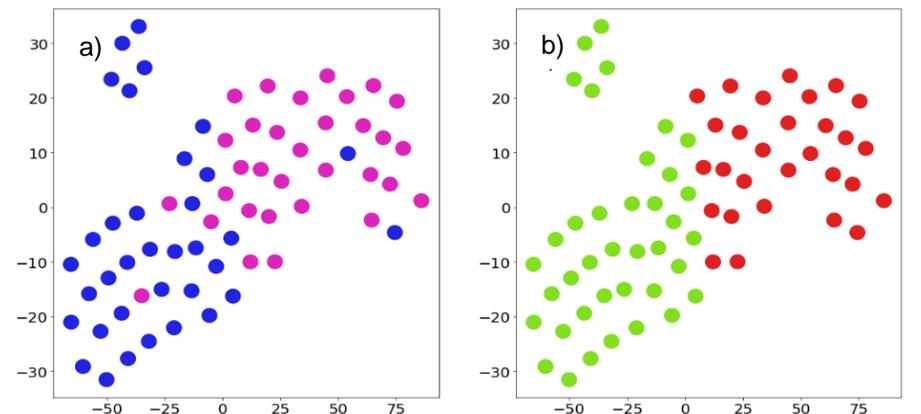
Con la combinación del reductor de dimensional PCA se define la nube de puntos inicial luego de procesarlos con el algoritmo de agrupamiento de datos Kmeans. En la figura 4-10 se logran identificar dos grupos de datos representados en verdes para la válvula buena y rojos para válvula mala, siendo la mejor la mejor combinación PCA1-PCA2.



**Figura 4-10** Agrupamientos obtenidos por PCA - Kmeans  
Fuente propia

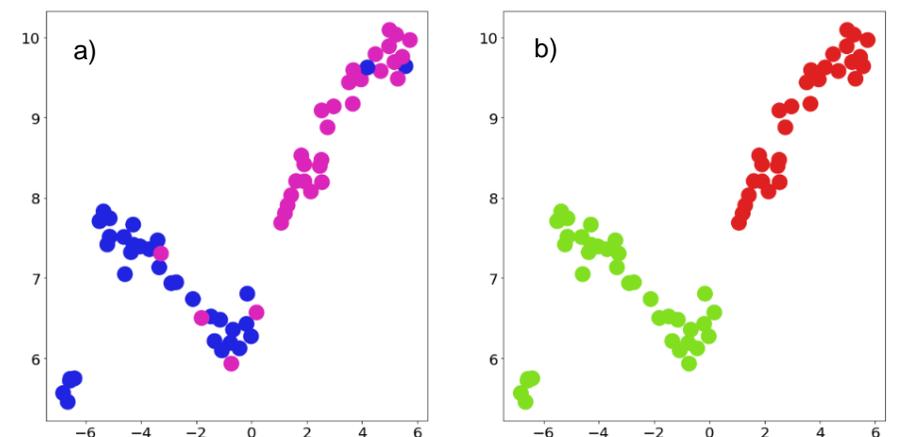
En la figura 4-11 se hace la predicción con dos variables finales donde el grafico (a) muestra la dispersión después de haber realizado tSNE y el segundo grafico (b) donde después de haber realizado tSNE se hace entrenamiento con Kmeans.

Con base en estos dos gráficos es posible cuantificar una exactitud del 91,25% de las predicciones correctas de ambas clases sobre la cantidad total de las detecciones posibles.



**Figura 4-11** Distribución real Vs agrupamiento generado para t-SNE  
Fuente propia

En la figura 4-12 se hace la predicción con dos variables finales donde el gráfico (a) muestra la dispersión luego de realizado el agrupamiento con UMAP y el gráfico (b) se hace entrenamiento con Kmeans. La exactitud presentada para la predicción del estado de la válvula para este entrenamiento fue del 92,5%.



**Figura 4-12** Distribución real vs agrupamiento generado por UMAP  
Fuente propia

### 4.4.3 Técnicas de selección de características de las señales temporales

Para el método de selección de características (SFS) se realizan modelos de cuatro características para emisión acústica y de ocho para la vibración en eje x. Esta selección se realiza luego de concluir el análisis de los 15 descriptores temporales propuestos, de los cuales la selección define aquellos de mejor eficiencia y después de realizar las iteraciones entre estos se obtiene el mejor desempeño.

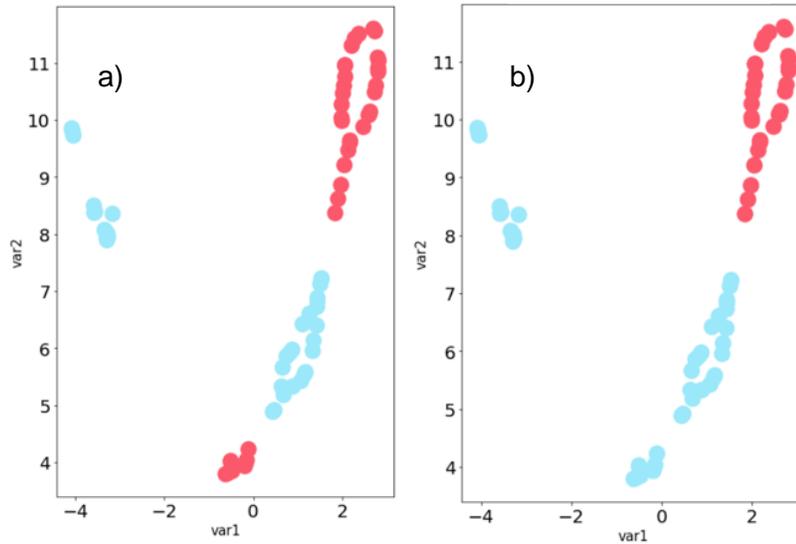
Posteriormente se realiza la combinación de los métodos de selección de características y reducción de dimensionalidad (SFS-tSNE, SFS- PCA, SFS –UMAP), la cual permite obtener los descriptores definidos y traducirlos en dos variables objetivo.

La tSNE utiliza dos variables lo cual se aplica en la generación de gráficos 2D en los que se define el agrupamiento. En las figuras 4-13 y 4-14 se observa la representación gráfica donde se evidencia la separación de los dos grupos de la data esto indica, lo cual que el agrupamiento seleccionado fue capaz de separar los grupos.

Para la reducción de dimensionalidad y selección de características del estado de las válvulas, se realiza la selección de los códigos y sus ajustes a los datos con la finalidad de aplicar los siguientes algoritmos de análisis para el entrenamiento no supervisado: PCA, SFS (selección de características), Kmeans, Umap y sus combinaciones SFS (2)-Kmeans, PCA – kmeans, tSN-E – Kmeans, UMAP – Kmeans, SFS (8) –tSNE-Kmeans y SFS (8) – UMAP-Kmeans.

Los métodos que se han propuesto buscan mejorar los resultados finales del agrupamiento; para esto se utilizaron técnicas de selección de características para lograr un mejor desempeño y adicionalmente se emplearon combinaciones de varios métodos que permitieron obtener mejores resultados de precisión del modelo. Estas combinaciones se realizan con técnicas de reducción de dimensionalidad (tSNE) y selección de características (SFS) (figura 4-13 y 4-14).

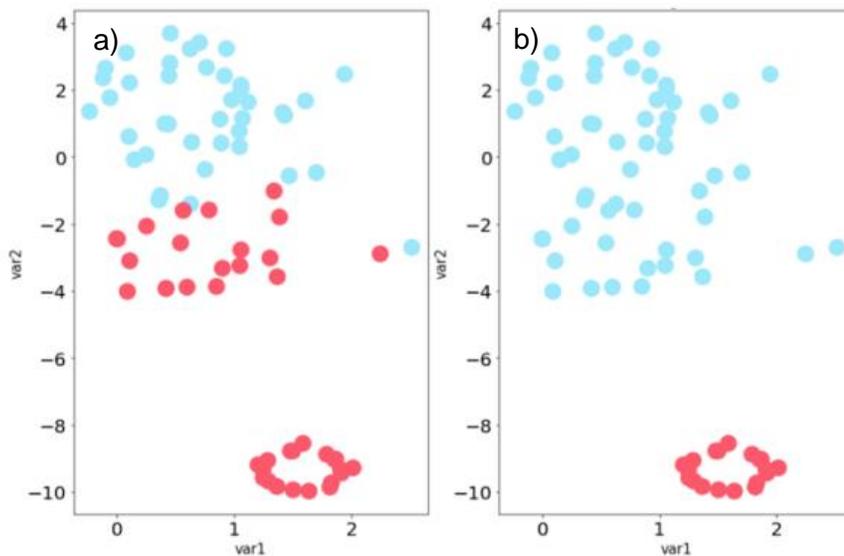
Los resultados obtenidos son evaluados mediante técnicas de agrupamiento (K-means), con la finalidad de obtener los valores más semejantes entre los vecinos más cercanos.



**Figura 4-13** Resultado para SFS (8 + t-SNE- Kmeans, predicción para la vibración eje X, a) proyección esperada y b) proyección predicha.  
Fuente propia

Del resultado de la combinación de selección de características con reducción de dimensionalidad y agrupamiento para la vibración eje x, se pudo observar la separación de los datos en dos grupos de características diferentes y agrupando entre ellas las de mayor similitud.

En la figura 4-13 a) se tiene el resultado de la proyección esperada la cual con respecto a la predicha b) se observan diferencias en el estado de la válvula mala (rojo). Este método permitió realizar una buena selección de características.



**Figura 4-14** Resultados para SFS (4) + t-SNE - Kmeans para emisión acústica. a) proyección esperada y b) proyección predicha.  
Fuente propia

De acuerdo a los resultados de la combinación de selección de características SFS (4) + t-SNE - Kmeans para la emisión acústica, se pudo observar la separación de los datos en dos grupos de características diferentes, aunque se observa que en esta combinación se presentó mayor confusión en los agrupamientos de los datos respecto a su similitud, obteniéndose una proyección predicha que confunde las características de los datos (figura 4-14 b)).

Los resultados obtenidos en los métodos de entrenamiento no supervisado (tabla 6), permiten identificar cual combinación es la que presenta mejor desempeño en la experimentación realizada; para las variables estudiadas se define que los mejores desempeños se presentaron en las variables de vibración eje x y emisión acústica con la combinación tSNE- Patternet.

Adicionalmente se presenta el resumen de los resultados de árbol de decisión, los cuales sirvieron para evaluar la clasificación de las redes utilizadas y donde se observa los mejores desempeños para la vibración en eje x y para la emisión acústica (tabla 5).

**Tabla 6** Precisión de los métodos no supervisados

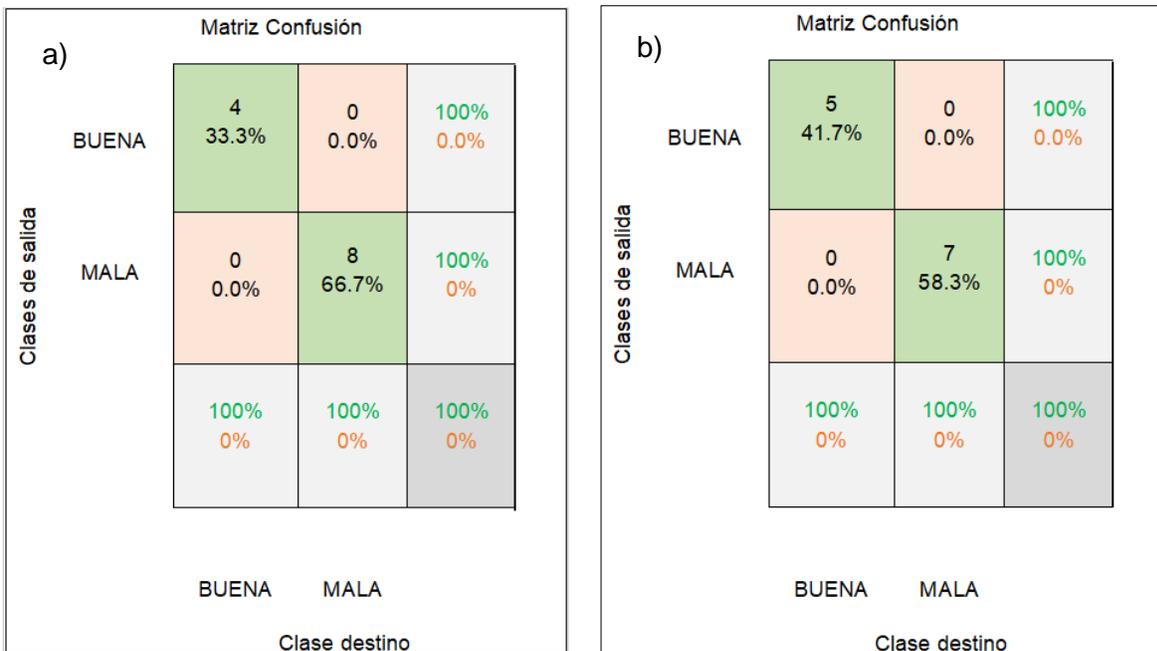
Señal temporal	Precisión de las combinaciones de entrenamiento no supervisado				
	Patternet	PCA - Pattenet	tSNE - Patternet	UMAP - Patternet	Árboles de decisión
Vibración eje X	100%	100%	<b>100%</b>	100%	<b>94,9%</b>
Vibración eje Y	83,3%	75,0%	91,7%	100%	91,1%
Vibración eje Z	75,0%	83,7%	100%	66,0%	81,0%
Vibración Absoluta	100%	83,3%	91,7%	75,0%	93,7%
Ultrasonido	83,0%	83,3%	91,7%	66,7%	94,9%
Emisión acústica	100%	100%	<b>100%</b>	100%	<b>95,7%</b>

#### 4.4.4 Evaluación del desempeño del entrenamiento no supervisado

Para la evaluación del desempeño de las redes neuronales se aplicaron herramientas que permiten validar los comportamientos de los resultados obtenidos. Para realizar estas validaciones se utilizó la matriz de confusión y la curva ROC, las cuales permiten definir si las redes utilizadas fueron adecuadas para clasificar los comportamientos de los datos.

#### 4.4.4.1. Matriz de confusión

Para el análisis de la matriz de confusión (figura 4-15) se utilizan los resultados presentados para las variables de estudio vibración eje x y emisión acústica con la utilización de entrenamientos no supervisados, en este resultado se observan las comparaciones entre los datos reales y las predicciones que hace el clasificador Patternet obteniéndose las siguientes métricas de resultados (tabla 7).



**Figura 4-15** Matriz de confusión para la vibración a) y emisión acústica b) – Patternet Fuente propia

**Tabla 7** Métricas de la matriz de confusión para Patternet para las señales temporales de mejor desempeño

Señal temporal	Métricas de la matriz de confusión – Patternet			
	Precisión	Exactitud	Sensibilidad	Especificidad
Vibración eje x	100%	100%	100%	100%
Emisión acústica	100%	100%	100%	100%

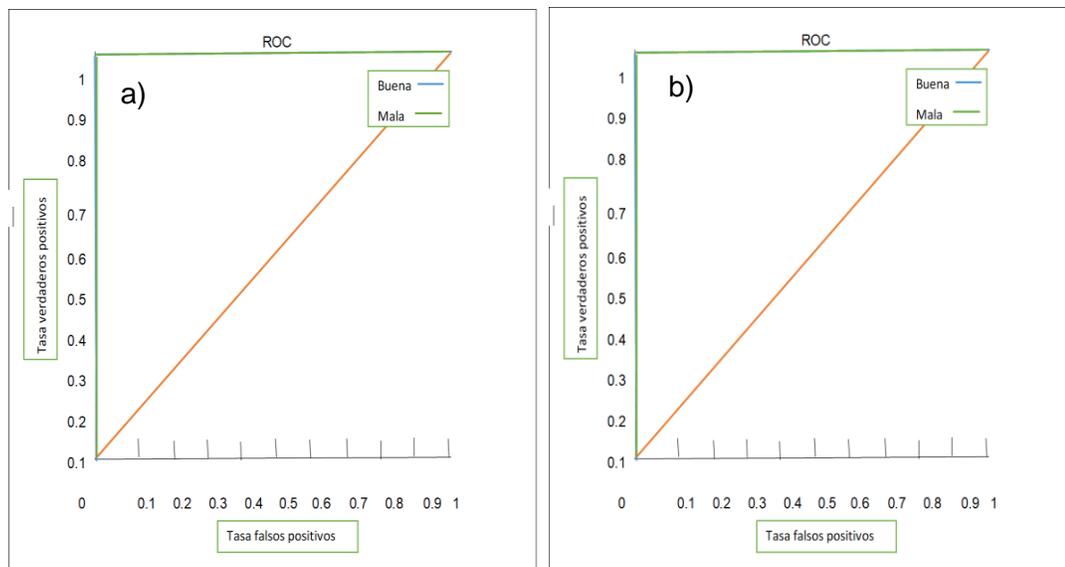
De acuerdo a los resultados obtenidos del análisis con la matriz de confusión para la vibración eje x y emisión acústica se observó que el resultado obtenido para sus

respectivas métricas fue del 100%, lo cual permite definir que esta validación sirve para hacer una buena clasificación de los datos.

#### 4.4.4.2. Curva ROC

Se plantea realizar la curva ROC como técnicas de evaluación de los clasificadores, la cual identifica el resultado presentado entre los verdaderos positivos en comparación con los falsos positivos que se dieron en el clasificador Patternet para vibración eje x figura 4-16 a) y emisión acústica figura 4-16 b).

Como se observa en gráficos se obtuvo una sensibilidad y especificidad del 100% en ambas señales temporales, debido que el cruce de entre los ejes se situó en la parte superior izquierda de la curva, lo cual indica una clasificación correcta del 100% de los datos analizados.



**Figura 4-16** Curva ROC de la vibración eje x (a) y emisión acústica (b) – Patternet  
Fuente propia

Con los entrenamientos no supervisados se logró separar los diferentes grupos de características del comportamiento de la data que se introduce en los diferentes algoritmos, lo cual permitió definir los grupos objetivos analizados en esta investigación.

## 4.5 Entrenamiento supervisado

Para la estrategia de entrenamiento supervisado se implementaron algunas redes de clasificación, con el fin de poder definir el comportamiento de los datos ingresados a los algoritmos propuestos. Las redes que se proponen para definir el conjunto de datos etiquetados (buenas y malas) son la Googlenet, Squeezenet y la red profunda propuesta durante la experimentación (CNN).

Estos análisis se realizaron para estrategias de entrenamiento profundo tanto para espectrogramas como para escalogramas de las cuales se obtiene la métrica de exactitud descritas en las tablas 8 y 9.

**Tabla 8** Exactitud de los métodos supervisados de entrenamiento profundo para espectrograma

Señal temporal	Redes de entrenamiento profundo para espectrograma		
	Googlenet	Squeezenet	CNN
Vibración eje X	100%	100%	100%
Vibración eje Y	100%	91.7%	95%
Vibración eje Z	95.8%	83.3%	95%
Vibración Absoluta	83.3%	91.7%	85%
Ultrasonido	100%	100%	60%
Emisión acústica	95.83%	100%	95%

**Tabla 9** Exactitud de los métodos supervisados de entrenamiento profundo para escalograma

Señal temporal	Redes de entrenamiento profundo para escalograma		
	Googlenet	Squeezenet	CNN
Vibración eje X	95,8%	100%	80%
Vibración eje Y	75%	91,6%	80%
Vibración eje Z	100%	100%	90%

<b>Vibración Absoluta</b>	83,3%	62,5%	85%
<b>Ultrasonido</b>	75%	54,2%	60%
<b>Emisión acústica</b>	95,8%	91,6%	90%

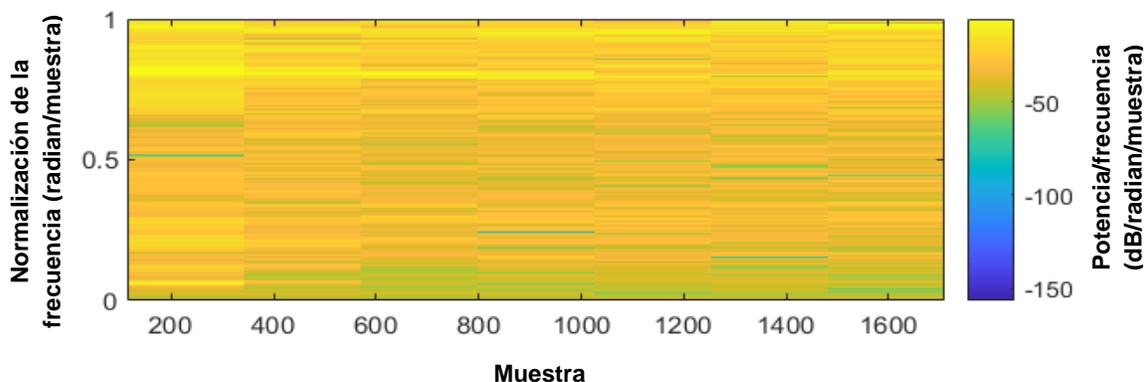
Estas redes profundas se emplearon en la experimentación como clasificadores de desempeño de las señales temporales estudiadas en esta investigación con el fin de obtener el mejor clasificador y la señal temporal permita determinar la condición operación de la válvula antirretorno.

De los resultados obtenidos se observa que las redes de entrenamiento profundo Googlenet y Squeezenet presentaron la mayor exactitud en la clasificación de los datos para las señales temporales de vibración eje x y la emisión acústica.

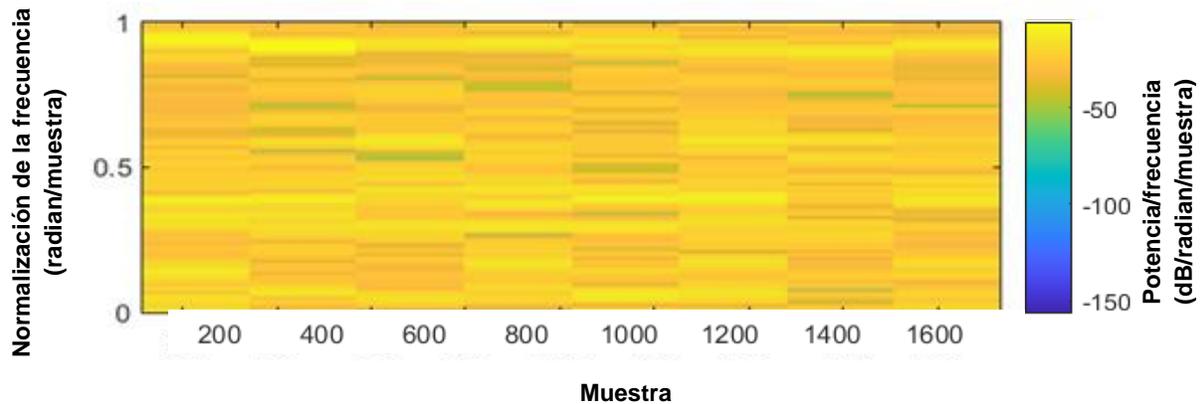
#### 4.5.1 Clasificación de redes profundas

Los resultados obtenidos en los espectrogramas para la figura 4-17 muestran el comportamiento de la señal en niveles bajos de energía con respecto a la escala de colores de la parte derecha del gráfico. Estos niveles se encuentran por debajo de 50 dB y se nota un incremento de los niveles de energía que sugieren un aumento en la señal, la cual se ubica entre 50 y 60 dB aproximadamente, reflejándose la variación del comportamiento de la válvula.

Para el resultado de la figura 4-18 también se observan bajos niveles de energía basados en la escala de colores del gráfico, dichos niveles se ubican en 50 dB aproximadamente.



**Figura 4-17** Espectrograma de la vibración eje x de la válvula mala  
Fuente propia

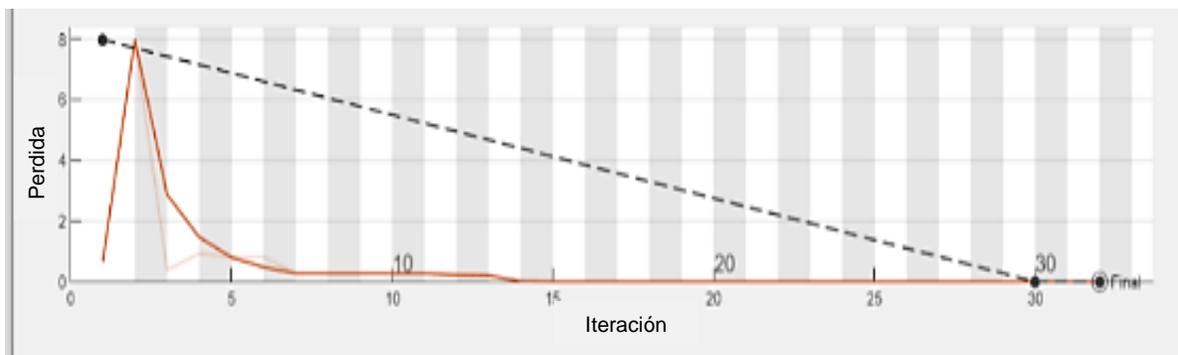


**Figura 4-18** Espectrograma de la vibración eje x de la válvula buena  
Fuente propia

En la tabla 10 se observan las características del entrenamiento de reducción de pérdida para googlenet obtenida del análisis de los datos de la vibración eje x y en la figura 4-19 representa la pérdida que se obtiene del entremaniemto profundo realizado con la red googlenet, el resultado que se obtuvo define que en la epoca 30 la pérdida se reduce a 0%, lo cual indica que la precisión del entrenamiento fue del 100% en la clasificación de los datos.

**Tabla 10** Características del entrenamiento de reducción de pérdida para vibración eje x

Características del entrenamiento	
Tiempo de entrenamiento	13 segundos
Ciclos de entrenamiento	32
Número de iteraciones	32
Iteraciones por época	1
Validación de frecuencia	30



**Figura 4-19** Gráfica de reducción de pérdida por épocas Googlenet de la vibración eje x  
Fuente propia

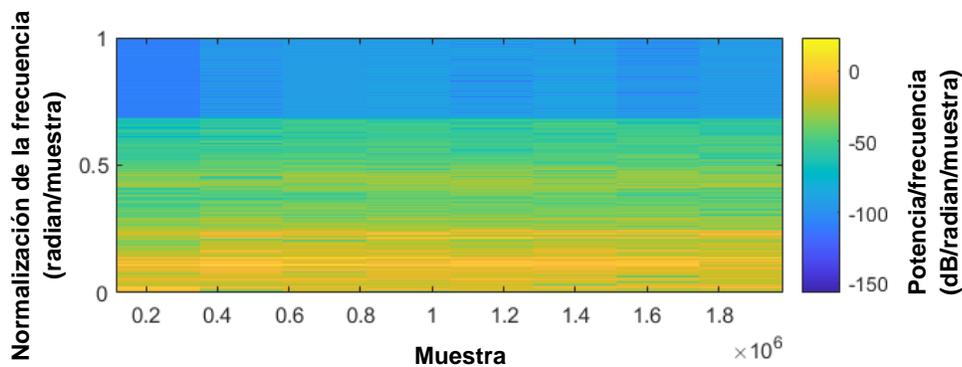
## 4.5.2 Análisis de espectrograma para la emisión acústica

El espectrograma muestra la intensidad de energía de la señal, la cual está representada en el lado derecho del gráfico, indicando los niveles de energía donde se observa más potencia en el dominio de la frecuencia.

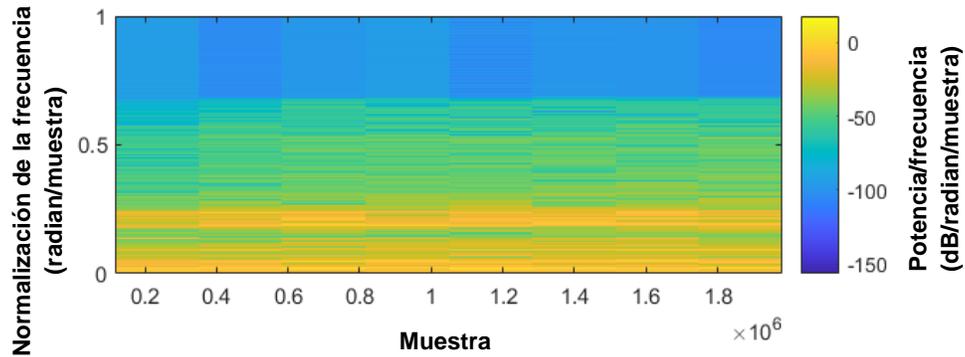
En la figura 4-20 se observaron tres franjas definidas que determinan diferentes niveles de energía. En la parte inferior se observa una baja intensidad de energía en un rango aproximado de 40dB. La segunda franja muestra un nivel de energía donde se combina una intensidad baja y una moderada con un rango aproximado entre 40 y 50 dB y en la tercera se observa una intensidad superior de energía con un valor aproximado de 70 dB.

Para la figura 4-21 también se observan tres niveles de energía, para la franja inferior se observa un nivel bajo de energía en un rango aproximado de 40dB, en la segunda franja muestra un rango de 50 dB y la tercera un rango aproximado de 80 dB.

Se podría concluir que para los espectrogramas obtenidos para emisión acústica no permite apreciar diferencias significativas a la hora de analizar los comportamientos de la válvula.



**Figura 4-20** Espectrograma de la emisión acústica de la válvula buena Fuente propia

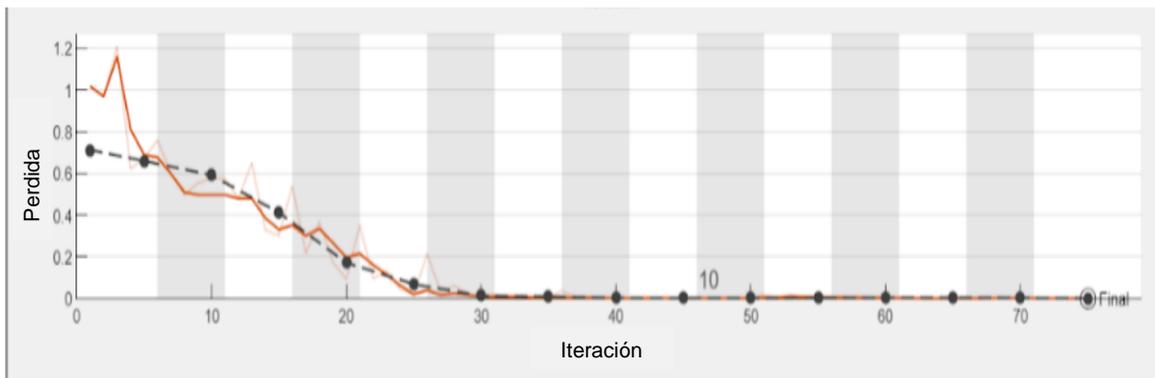


**Figura 4-21** Espectrograma de la emisión acústica de la válvula mala Fuente propia

En la tabla 11 se observan las características del entrenamiento de reducción de pérdida para Squeezenet obtenida del análisis de los datos de la emisión acústica y la figura 4-22 representa la pérdida que se obtiene del entrenamiento realizado con la red de entrenamiento profundo Squeezenet. El resultado que se obtuvo define que en la época 30 la pérdida se reduce a 0% lo cual indica que la precisión del entrenamiento fue del 100% en la clasificación de los datos.

**Tabla 11** Características del entrenamiento de reducción de pérdida para emisión acústica

Características del entrenamiento	
Tiempo de entrenamiento	19 segundos
Ciclos de entrenamiento	15
Número de iteraciones	75
Iteraciones por época	5
Validación de frecuencia	30



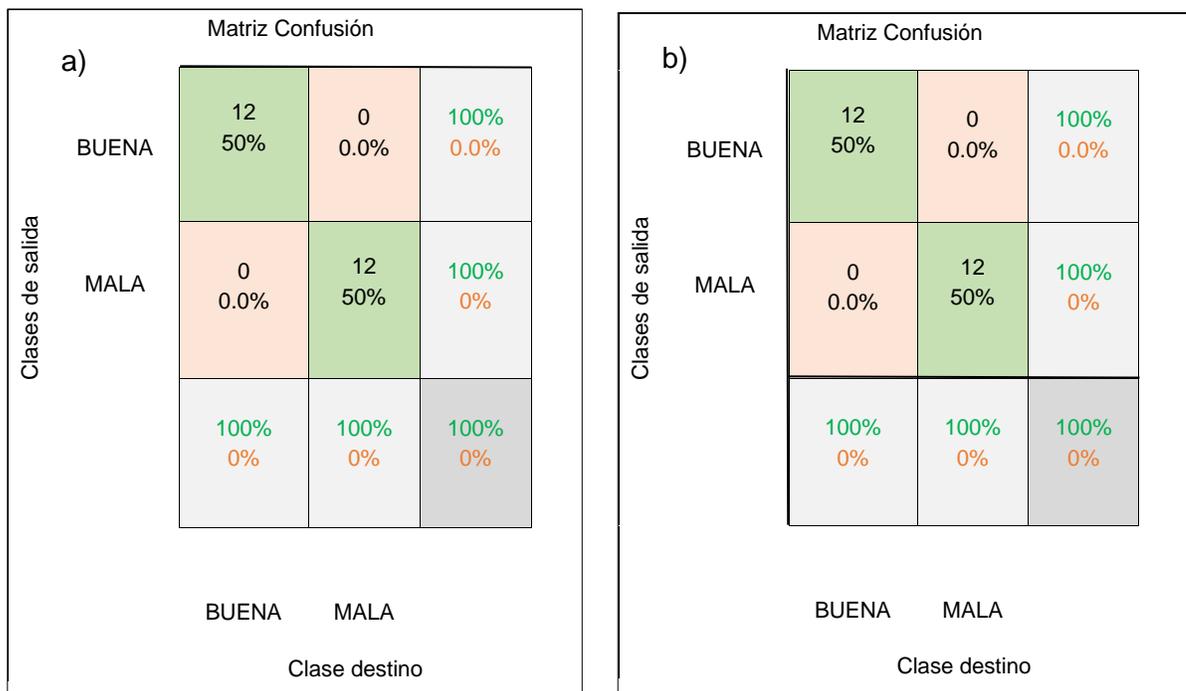
**Figura 4-22** Gráfica de reducción de pérdidas por épocas Squeezenet de la emisión acústica Fuente propia

### 4.5.3 Evaluación del desempeño de redes profundas

Para la evaluación del desempeño de las redes profundas se aplicaron herramientas que permiten validar los comportamientos de los resultados obtenidos. Para realizar estas validaciones se utilizó la matriz de confusión y la curva ROC, las cuales permiten definir si las redes utilizadas fueron adecuadas para clasificar los comportamientos de los datos que hacen referencia a las etiquetas de las válvulas (buenas y malas).

#### 4.5.3.1 Matriz de confusión

Para el análisis de la matriz de confusión (figura 4-23) se utilizaron los resultados obtenidos para las variables de estudio vibración eje x y emisión acústica con la utilización de entrenamientos supervisados. En este resultado se observan las comparaciones entre los datos reales y las predicciones que hace el clasificador de entrenamiento, las cuales entregan las diferentes métricas que permiten analizar dicha matriz con respecto al comportamiento de su exactitud tablas 12 y 13.



**Figura 4-23** Matriz de confusión para la vibración a) y emisión acústica b)  
Fuente propia

Para la evaluación de la matriz de confusión se plantean las diferentes métricas que permiten definir los comportamientos de las señales temporales, dichas métricas se analizan para redes profundas Googlenet y Squeezenet para las representaciones graficas de espectrogramas y escalogramas.

**Tabla 12.** Métricas de la matriz de confusión para Googlenet para las señales temporales de mejor desempeño

	<b>Métricas de la matriz de confusión- Googlenet</b>			
<b>Señal temporal</b>	<b>Precisión</b>	<b>Exactitud</b>	<b>Sensibilidad</b>	<b>Especificidad</b>
Vibración eje x escalograma	92,3%	100%	91,7%	100%
Vibración eje x espectrograma	100%	100%	100%	100%
Emisión acústica escalograma	92,3%	100%	91,7%	100%
Emisión acústica espectrograma	100%	92,3%	100%	91,7%

**Tabla 13** Métricas de la matriz de confusión para Squeezenet para las señales temporales de mejor desempeño

	<b>Métricas de la matriz de confusión- Squeezenet</b>			
<b>Señal temporal</b>	<b>Precisión</b>	<b>Exactitud</b>	<b>Sensibilidad</b>	<b>Especificidad</b>
Vibración eje x escalograma	100%	100%	100%	100%
Vibración eje x espectrograma	100%	100%	100%	100%
Emisión acústica escalograma	100%	85,7%	100%	83,3%
Emisión acústica espectrograma	100%	100%	100%	100%

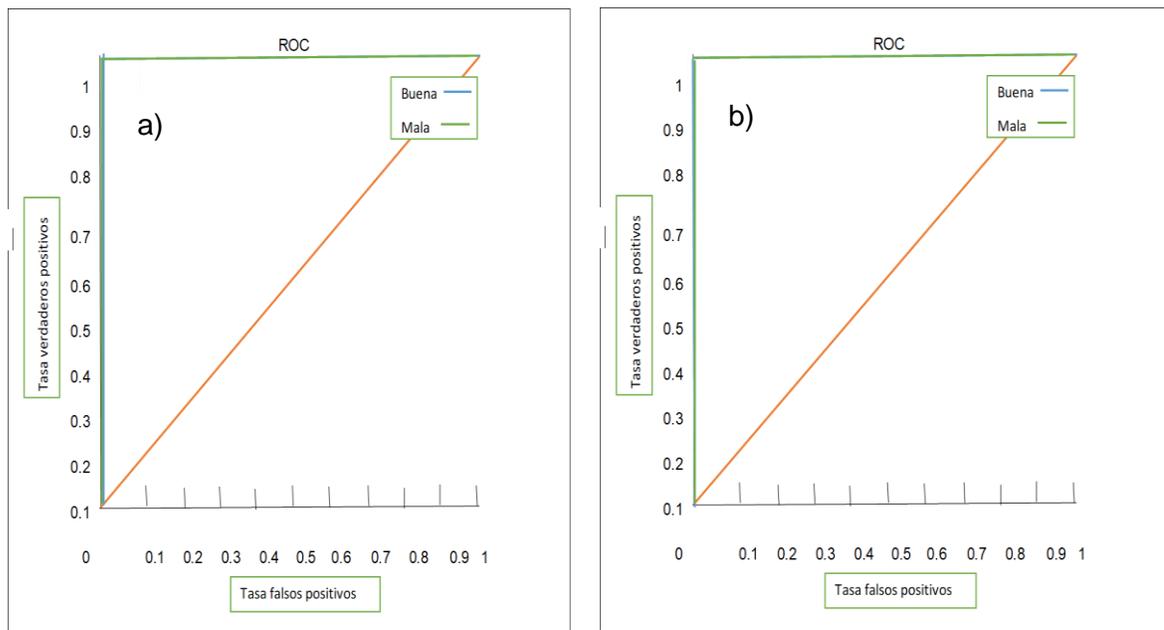
De acuerdo a los resultados obtenidos del análisis con la matriz de confusión para la vibración eje x y emisión acústica se observó que los resultados obtenidos para los espectrogramas analizados con la Googlenet y Squeezenet presentaron en sus métricas mejores desempeños. Lo anterior permite concluir que estos dos clasificadores son adecuados para clasificar el comportamiento de la válvula antirretorno.

### 4.5.3.2. Curvas ROC

Se empleó la curva ROC para la evaluación del desempeño de los clasificadores, por medio de la cual se identificó la relación entre los verdaderos positivos en comparación con los falsos positivos para vibración eje x y emisión acústica (figura 4-24).

Como se observa en las figuras mencionadas, se obtuvo una sensibilidad y especificidad del 100% en la relación entre los verdaderos positivos en comparación con los falsos positivos para ambas señales temporales y ambas redes profundas.

Con los entrenamientos supervisados se logró separar los diferentes grupos de características del comportamiento de la data, que se introduce en los algoritmos de entrenamiento profundo (Googlenet y Squeezenet), lo cual permitió definir los grupos objetivos analizados en esta investigación.



**Figura 4-24** Curva ROC para la vibración eje x (a) y emisión acústica (b)  
Fuente propia

De los análisis realizados para los entrenamientos supervisados se pudo identificar que las redes convolucionales Googlenet y Squeezenet permitieron determinar el comportamiento de operación de la válvula antirretorno basado en la eficiencia obtenida de sus métricas y determinar el estado de la válvula (buena o mala).

Partiendo de los resultados obtenidos en los comportamientos de las curvas ROC empleadas para analizar las dos estrategias de entrenamiento (no supervisados y supervisados), se puede definir que para esta investigación ambos métodos permitieron identificar las condiciones presentadas en los estados de las válvulas antirretorno.

## 5. CONCLUSIONES

Las redes neuronales propuestas en la investigación constituyen una importante herramienta para la predicción y diagnóstico del estado de las válvulas antirretorno. Estas redes convolucionales permitieron detectar el buen estado o no de la válvula ocasionado por fallas en la misma.

Las señales temporales de vibración eje x y emisión acústica permitieron observar diferencias en los comportamientos de la válvula buena y mala. Sin embargo, para técnica ultrasonido para el estudio de la válvula antirretorno no permitió identificar variaciones en la señal.

De acuerdo con los resultados obtenidos en la experimentación realizada se concluye, que los descriptores temporales seleccionados permitieron describir el comportamiento de los datos, obteniéndose que la vibración eje x y la emisión acústica mostraron el mejor desempeño de la válvula antirretorno.

Las representaciones gráficas de los escalogramas y espectrogramas de la vibración eje x y emisión acústica mostraron diferencias en las intensidades de energías asociadas al estado de la válvula, por lo que se concluye que estas herramientas podrían ser empleadas para diagnosticar fallos en válvulas antirretorno.

Se definió que para los entrenamientos no supervisados el mejor desempeño se presentó en las combinaciones realizadas entre tSN-E – Kmeans- Patternet para las señales de vibración eje x y emisión acústica.

Los entrenamientos no supervisados lograron separar los diferentes grupos de características del comportamiento de la data, lo cual permitió definir los grupos objetivos analizados en esta investigación.

De los resultados obtenidos se concluye que las redes de entrenamiento profundo Googlenet y Squeezenet presentaron el mejor desempeño para la clasificación de los datos para todas las señales temporales.

En esta investigación se determinó que los resultados obtenidos de la matriz de confusión y las curvas ROC empleadas para analizar las dos estrategias de entrenamiento (no supervisados y supervisados), permitieron identificar las condiciones presentadas en los estados de las válvulas antirretorno (buena o mala).

### *Recomendaciones para trabajos futuros*

Para obtener una mayor captura de datos para las predicciones se recomienda instalar el acelerómetro en la válvula antirretorno que logre tomar datos en tiempo real.

Se recomienda emplear otras combinaciones de los algoritmos de reducción de dimensionalidad y selección de características para evaluar su desempeño.

Instalar en la válvula antirretorno instrumentos de medición de frecuencia audible que permitan una mayor adquisición de datos en tiempo real.

El uso del celular como acelerómetro sirve como método experimental para toma de datos en las válvulas antirretornos, sin embargo, para procesos industriales se recomiendan acelerómetros que permitan la toma de datos en tiempo real y que su instalación sea fijada en el elemento a inspeccionar.

## BIBLIOGRAFÍA

- Aranda, Y. R., & Sotolongo, A. R. (2013). Integración de los algoritmos de minería de datos 1R, PRISM E ID3 A POSTGRESQL. *Journal of Information Systems and Technology Management*, *10*(2), 389–406. <https://doi.org/10.4301/s1807-17752013000200012>
- Ariza-López, F. J., Rodríguez-Avi, J., & Alba-Fernández, V. (2018). Control estricto de matrices de confusión por medio de distribuciones multinomiales. *GeoFocus Revista Internacional de Ciencia y Tecnología de La Información Geográfica*, (21), 215–226. <https://doi.org/10.21138/gf.591>
- Arroyo-Hernández, J. (2016). Métodos de reducción de dimensionalidad: Análisis comparativo de los métodos APC, ACPP y ACPK. *Uniciencia*, *30*(1), 115–122. <https://doi.org/10.15359/ru.30-1.7>
- Carvalho, T. P., Soares, F. A. A. M. N., Vita, R., Francisco, R. da P., Basto, J. P., & Alcalá, S. G. S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers and Industrial Engineering*, *137*(April), 106024. <https://doi.org/10.1016/j.cie.2019.106024>
- Cortés, J. A., A, F. A. M., & O, J. A. C. (2007). Del análisis de Fourier a las wavelets análisis de Fourier. *Scientia Et Technica*, (34), 151–156. Retrieved from <http://www.redalyc.org/articulo.oa?id=84934026>
- El-Zahab, S., Mohammed Abdelkader, E., & Zayed, T. (2018). An accelerometer-based leak detection system. *Mechanical Systems and Signal Processing*, *108*, 58–72. <https://doi.org/10.1016/j.ymsp.2018.02.030>
- Enríquez, J. M. (2020). *Diagnóstico multi-falla en cadena cinemática utilizando termografía infrarroja y análisis de componentes principales*. Universidad autónoma de Querétaro.
- Filipussi, D. A. (2018). Caracterización de daño por “b-value” de eventos de emisión

- acústica en ensayos de rotura de roca andesita. *Revista Materia*, 23(2).  
<https://doi.org/10.1590/s1517-707620180002.0404>
- Gómez, S. A. M. (2017). *Técnicas de mantenimiento predictivo. Metodología de aplicación en las organizaciones. UNIVERSIDAD CATÓLICA DE COLOMBIA.*
- Guillén Peña, M., Paredes, J. L., & Camacho, O. (2007). Un enfoque para la detección y diagnóstico de falls en la instrumentación de un proceso usando reconocimiento de patrones en el dominio Wavelet. *8º Congreso Iberoamericano de Ingeniería Mecánica*, 1–9.
- Huertas Mora, A. (2020). *Algoritmos de aprendizaje supervisado utilizando datos de monitoreo de condiciones: Un estudio para el pronóstico de fallas en máquinas.* Universidad Santo Tomás. Retrieved from <http://unidadinvestigacion.usta.edu.co>
- Ilić, U., Trojić, B., Lazić, V., & Filipovi, F. (2019). Classification Models of Machine Learning For Vibration Analysis of Induction Motor, (June). Retrieved from <https://www.researchgate.net/publication/348936779%0AClassification>
- Kaji, M., Parvizian, J., & van de Venn, H. W. (2020). Constructing a reliable health indicator for bearings using convolutional autoencoder and continuous wavelet transform. *Applied Sciences (Switzerland)*, 10(24), 1–21.  
<https://doi.org/10.3390/app10248948>
- Kim, J. T., Kim, H., & Park, W. M. (2017). Data analysis for valve leak detection of nuclear power plant safety critical components. *10th International Topical Meeting on Nuclear Plant Instrumentation, Control, and Human-Machine Interface Technologies, NPIC and HMIT 2017*, 3, 1742–1751.
- Maeda Gutiérrez, V. (2019). *Comparación de arquitecturas de redes neuronales convolucionales para la clasificación de enfermedades en tomate.* Universidad autónoma de Zacatecas.
- Magallanes, J. A. L., & Martín Sánchez Mtz. (1992). Emisión Acústica: método de inspección no destructivo para La evaluación de componentes soldados. Retrieved from [http://www.geocities.ws/pndmx/articulos/AE\\_soldadura\\_2001.pdf](http://www.geocities.ws/pndmx/articulos/AE_soldadura_2001.pdf)
- Matich, D. J. (2001). *Redes neuronales: conceptos básicos y aplicaciones.* Departamento de Ingeniería Química. Universidad Tecnológica Nacional. Retrieved from <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>
- Meland, E., Henriksen, V., Hennie, E., & Rasmussen, M. (2011). Spectral analysis of

- internally leaking shut-down valves. *Measurement: Journal of the International Measurement Confederation*, 44(6), 1059–1072.  
<https://doi.org/10.1016/j.measurement.2011.03.004>
- Montaño, J. J. (2002). *Redes neuronales artificiales aplicadas al análisis de datos. Network*. UNIVERSITAT DE LES ILLES BALEARS.
- Nieto, N., & Orozco, D. M. (2008). El uso de la transformada Wavelet discreta en la reconstrucción de señales senosoidales. *Scientia Et Technica ISSN:*, 1(38), 381–386. <https://doi.org/10.22517/23447214.3809>
- Ochoa, L. (2019). Evaluation of Classification Algorithms using Evaluación de Algoritmos de Clasificación utilizando Validación Cruzada. *Laccei International Multi-Conference for Engineering, Education, and Technology*, 24–26.  
<https://doi.org/10.18687/LACCEI2019.1.1.471>
- Olarte, W., & Botero, M. (2011). La detección de ultrasonido: una técnica empleada en el mantenimiento predictivo. *Scientia Et Technica*, 47, 230–233. Retrieved from <http://www.redalyc.org/articulo.oa?id=84921327035>
- Olarte, W., Botero, M., & Cañon, B. (2010). Técnicas de mantenimiento predictivo utilizadas en ea industria. *Scientia Et Technica*, 16(45), 223–226.  
<https://doi.org/10.22517/23447214.355>
- Ortega Triana, J. (2021). *Aprendizaje profundo para la detección automática de fisuras de hormigón usando redes neuronales convolucionales*. Universidad Politécnica de Valencia.
- Pacheco Córdova, E., Sánchez L, R., Cabrera, D., & Cerrada, M. (2018). Adquisición de señales de vibración y emisión acústica para el diagnóstico de severidad de fallos en maquinaria rotativa. *Revista Colombiana de Tecnologías de Avanzada*, 2, 87–94.
- Penkova Vassileva, M. (2007). Mantenimiento y análisis de vibraciones. *Ciencia y Sociedad*, 32(4), 668–678. <https://doi.org/10.22206/cys.2007.v32i4.pp668-678>
- Pérez, S. (2015). *Estimación de la curva ROC acumulativa / dinámica*. Universidad de Oviedo. Retrieved from <https://digibuo.uniovi.es/dspace/bitstream/handle/10651/32024/TFM>
- Quiñones Huatangari, L., Ochoa Toledo, L., Kemper Valverde, N., Gamarra Torres, O., Bazán Correa, J., & Delgado Soto, J. (2020). Red neuronal artificial para estimar un índice de calidad de agua. *Enfoque UTE*, 11(2), 109–120.  
<https://doi.org/10.29019/enfoque.v11n2.633>
- Romero R, L. A., Morales V, L., Osornio Ríos, R., Romero Troncoso, R., & Moríñigo S.,

- D. (2018). Detección de falla de rodamiento en una cadena cinemática vía emisión acústica. *Pistas Educativas*, 39(128), 1392–1406. Retrieved from <http://itcelaya.edu.mx/ojs/index.php/pistas>
- Rosa, M., Miles, L., & Perez, J. (2009). Manual de aplicaciones de herramientas y técnicas del mantenimiento Predictivo. *ACI Avances En Ciencias e Ingenierías*. San Salvador. Retrieved from [http://ri.ues.edu.sv/id/eprint/1742/1/Manual\\_de\\_aplicaciones\\_de\\_herramientas\\_y\\_técnicas\\_del\\_mantenimiento\\_Predictivo.pdf](http://ri.ues.edu.sv/id/eprint/1742/1/Manual_de_aplicaciones_de_herramientas_y_técnicas_del_mantenimiento_Predictivo.pdf)
- Santos De La Cruz, Eulogio; Cancino Vera, Néstor; Yenque Dedios, Julio; Ramírez Morales, David; Palomino Pérez, M. (2005). El ultrasonido y su aplicación. *Industrial Data*, 8(1), 25–28. Retrieved from <https://www.redalyc.org/articulo.oa?id=81680105>
- Selcuk, S. (2017). Predictive maintenance, its implementation and latest trends. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 231(9), 1670–1679. <https://doi.org/10.1177/0954405415601640>
- Shin, S. M., Kim, D. S., & Kang, H. G. (2018). Power-operated check valve in abnormal situations. *Nuclear Engineering and Design*, 330(December 2017), 28–35. <https://doi.org/10.1016/j.nucengdes.2018.01.017>
- Spilsbury, M. J., & Euceda, A. (2016). Transformada rápida de Fourier. *Revista De La Escuela De Física*, IV(2), 45–52. <https://doi.org/10.5377/ref.v4i2.8276>
- Tao, J., Liu, Y., & Yang, D. (2016). Bearing Fault Diagnosis Based on Deep Belief Network and Multisensor Information Fusion. *Shock and Vibration*, 2016, 1–9. <https://doi.org/10.1155/2016/9306205>
- Tejada Layme, G., & Gonzales Chama, R. (2020). *Arquitectura de red Neuronal convolucional para diagnóstico de cáncer de piel*. Universidad tecnológica del Perú.
- Torres, F., Royo, J., & Rabanaque, G. (2015). Análisis de vibraciones e interpretación de datos. *DIDYF Universidad de Zaragoza*. Retrieved from <http://www.guemisa.com/articul/pdf/vibraciones.pdf>
- Valencia S., A. (2019). *Sistema monitoreo de desgaste para cadenas de motocicletas*. Fundación universidad de los libertadores. Retrieved from [https://repository.libertadores.edu.co/bitstream/handle/11371/2866/Valencia\\_Adrián\\_2019.pdf?sequence=1&isAllowed=y](https://repository.libertadores.edu.co/bitstream/handle/11371/2866/Valencia_Adrián_2019.pdf?sequence=1&isAllowed=y)
- Velez-Langs, O. (2014). Feature reduction using a RBF network for classification of

- learning styles in first year engineering students. *Ingeniare. Revista Chilena de Ingeniería*, 22(1), 140–151. <https://doi.org/10.4067/s0718-33052014000100013>
- Venkata, S. K., & Rao, S. (2019). Fault detection of a flow control valve using vibration analysis and support vector machine. *Electronics (Switzerland)*, 8(10). <https://doi.org/10.3390/electronics8101062>
- Wang, Y. S., Liu, N. N., Guo, H., & Wang, X. L. (2020). An engine-fault-diagnosis system based on sound intensity analysis and wavelet packet pre-processing neural network. *Engineering Applications of Artificial Intelligence*, 94(333), 103765. <https://doi.org/10.1016/j.engappai.2020.103765>
- Yan, J., Heng-Hu, Y., Hong, Y., Feng, Z., Zhen, L., Ping, W., & Yan, Y. (2015). Nondestructive Detection of Valves Using Acoustic Emission Technique. *Advances in Materials Science and Engineering*, 2015, 9. <https://doi.org/10.1155/2015/749371>