



**UNIVERSIDAD POLITÉCNICA SALESIANA**  
**SEDE CUENCA**  
**CARRERA DE INGENIERÍA AUTOMOTRIZ**

**APLICACIÓN DE LA METODOLOGÍA DE PATRÓN DE PUNTOS PARA EL DIAGNÓSTICO  
DE FALLO DE ANULACIÓN DE FUNCIONAMIENTO DE UN CILINDRO EN UN MOTOR  
DE COMBUSTIÓN INTERNA**

Trabajo de titulación previo a la obtención del  
título de Ingeniero Automotriz

**AUTOR: ROBINSON XAVIER ROJAS ESPINOZA**

**TUTOR: ING. RAFAEL WILMER CONTRERAS URGILÉS, MSc.**

Cuenca - Ecuador

2024

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE  
TITULACIÓN**

Yo, Robinson Xavier Rojas Espinoza con documento de identificación N° 1105618555, manifestó que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Cuenca, 19 de junio del 2024

Atentamente,



---

Robinson Xavier Rojas Espinoza

1105618555

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE  
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Yo, Robinson Xavier Rojas Espinoza con documento de identificación N° 1105618555, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del Artículo académico: “Aplicación de la metodología de patrón de puntos para el diagnóstico de fallo de anulación de funcionamiento de un cilindro en un motor de combustión interna”, el cual ha sido desarrollado para optar por el título de: Ingeniero Automotriz, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, 19 de junio del 2024

Atentamente,



---

Robinson Xavier Rojas Espinoza

1105618555

## CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Rafael Wilmer Contreras Urgilés con documento de identificación N° 0104463328, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: APLICACIÓN DE LA METODOLOGÍA DE PATRÓN DE PUNTOS PARA EL DIAGNÓSTICO DE FALLO DE ANULACIÓN DE FUNCIONAMIENTO DE UN CILINDRO EN UN MOTOR DE COMBUSTIÓN INTERNA, realizado por Robinson Xavier Rojas Espinoza con documento de identificación N° 1105618555, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Cuenca, 19 de junio del 2024

Atentamente,



---

Ing. Rafael Wilmer Contreras Urgilés, MSc

0104463328

# APLICACIÓN DE LA METODOLOGÍA DE PATRÓN DE PUNTOS PARA EL DIAGNÓSTICO DE FALLO DE ANULACIÓN DE FUNCIONAMIENTO DE UN CILINDRO EN UN MOTOR DE COMBUSTIÓN INTERNA

## APPLICATION OF THE DOT PATTERN METHODOLOGY FOR DIAGNOSING FAILURE TO CANCEL OPERATION OF A CYLINDER IN AN INTERNAL COMBUSTION ENGINE

Robinson Xavier Rojas Espinoza<sup>1</sup>, Rafael Wilmer Contreras Urgilés<sup>2</sup>

### Resumen

Este trabajo de investigación detalla la aplicación de la metodología de patrón de puntos simetrizado (SDP) para el diagnóstico de fallos en cilindros de motores de combustión interna. La metodología se basa en la captación del sonido del motor en diferentes condiciones de fallo, como la anulación de un inyector y fallo de ignición, además del sonido del motor en buen estado. Estos datos se procesan mediante la transformada de Fourier para generar gráficas en el plano polar, en el dominio del tiempo y amplitud de la señal, obteniendo imágenes en forma de pétalos de rosa o copos de nieve. Se ajustan previamente los parámetros de intervalo en el tiempo y el coeficiente de amplificación en el algoritmo SDP para generar los patrones de puntos característicos para cada condición de funcionamiento. Debido a la dificultad de la visualización humana de rasgos significativos en las imágenes SDP y para minimizar el desgaste computacional, se emplean redes neuronales convolucionales (CNN) para identificar y clasificar los patrones. Tras diseñar la CNN, se obtuvo un 86.67% de validación en el entrenamiento y un 81.11% de precisión en los diagnósticos utilizando una matriz de datos no entrenada en la CNN. Esto demuestra que la técnica SDP puede diagnosticar con alta efectividad las condiciones de fallo en el motor.

**Palabras Clave:** Diagnóstico del motor, SDP, Motor, Metodología no invasiva.

### Abstract

This research paper details the application of the Symmetrized Dot Pattern (SDP) methodology for diagnosing faults in internal combustion engine cylinders. The methodology is based on capturing the sound of the engine under various fault conditions, such as injector deactivation and ignition failure, as well as the sound of the engine in good working condition. These data are processed using the Fourier transform to generate graphs in the polar plane, in the domain of time and signal amplitude, producing images in the form of rose petals or snowflakes. The parameters for time interval and amplification coefficient in the SDP algorithm are previously adjusted to generate characteristic dot patterns for each operating condition. Due to the difficulty of human visualization of significant features in the SDP images and to minimize computational wear, convolutional neural networks (CNN) are used to identify and classify the patterns. After designing the CNN, an 86.67% validation in training and an 81.11% accuracy in diagnostics using an untrained data set in the CNN were obtained. This demonstrates that the SDP technique can effectively diagnose engine fault conditions.

**Keywords:** Engine diagnosis, SDP, Engine, Non-invasive methodology.

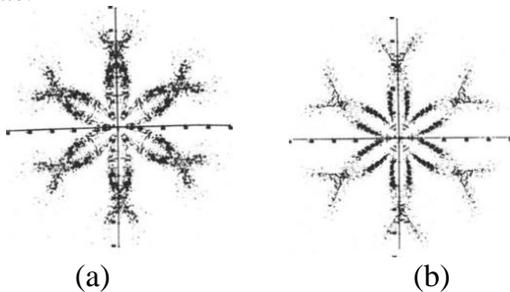
<sup>1</sup> Universidad Politécnica Salesiana, Cuenca – Ecuador. Autor para correspondencia: rrojase@est.ups.edu.ec

<sup>2</sup> Grupo de Investigación de Ingeniería del Transporte (GIIT), Carrera de Ingeniería Automotriz, Universidad Politécnica Salesiana, Cuenca – Ecuador. Autor para correspondencia: rcontreras@ups.edu.ec

# 1. Introducción

El método de análisis mediante patrón simetrizado de puntos, por sus siglas en inglés SPD (Symmetrized Dot Pattern) [1], es una metodología que extrae y analiza características de señales acústicas y vibratorias mediante su transformación al dominio de frecuencia, a través de la transformada de Fourier, generando imágenes polares en las cuales se visualizan los patrones de puntos simétricos [2, 3]. Debido a la adaptabilidad de las señales, y las revisiones de tipo bibliográfica como en la investigación de [4], su aplicación se ha extendido a diferentes áreas de estudio, en las que se destacan el área industrial, salud y automotriz.

En el área industrial, las primeras investigaciones se remontan al año de 1986, cuando surgieron dificultades en la detección de fallas en máquinas industriales mediante la audición humana. En la investigación de [1] estudiaron diferentes patrones de puntos para analizar las diferencias de las gráficas polares obtenidas de las señales acústicas. Mediante la audición humana, no se logró distinguir una diferencia significativa en las señales acústicas presentadas en Figura 1 (a) y (b), sin embargo, con la aplicación de la técnica SDP, obtuvieron patrones característicos, así como se evidencia en Figura 1 (a), que indica el patrón de puntos de un sonido grave, mientras que en la Figura 1 (b) se indica el patrón de puntos de un sonido agudo. Lo cual brindó solución a la identificación de diferentes señales acústicas.

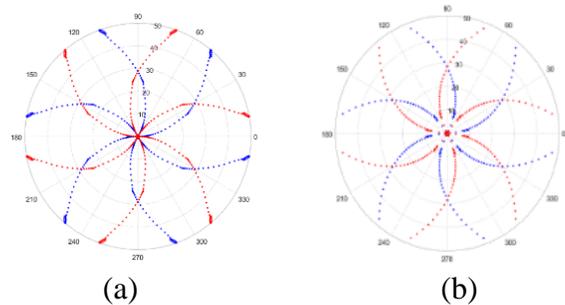


**Figura 1.** Patrones de puntos de señales acústicas. (a) Patrón de sonido grave. (b) Patrón de sonido agudo. [1]

Sin embargo, en la década de los 80 y 90 esta metodología se detuvo, debido a las limitaciones que tenían los equipos para el procesamiento de señales. En el 2000, con el avance y la implementación de nuevas y mejores tecnologías, la investigación de [2] retoma el diagnóstico de fallo aplicándolo en máquinas rotatorias, y en motores de combustión interna alternativos, como

en la investigación de [5], mediante el uso de técnicas no invasivas. Debido a ello los investigadores de [2] en su estudio han distinguido las señales acústicas entre rodamientos normales y defectuosos a través de la toma de datos de sonido mediante el método SDP. Además, con la implementación de un micrófono ubicado a 230 centímetros de los rodamientos, identificaron la señal acústica característica para un rodamiento defectuoso de uno en estado normal.

Ya en el año 2019 con el avance tecnológico y en la misma línea de las técnicas no invasivas, aplicado a máquinas con engranajes rectos, en la investigación de [3] transformaron la señal de vibración a través de la técnica SDP a una imagen de pétalo en coordenadas polares. Con ello generaron las imágenes que se muestran en la Figura 2 (a) de un engranaje en buen estado y en la Figura 2 (b) de un engranaje con grietas. Además, elaboraron un algoritmo que identificó condiciones de fallos en los engranajes mediante la visualización de estas imágenes. Debido a la limitación del ser humano para identificar con rapidez las diferencias entre los patrones característicos, se implementan las redes neuronales convolucionales, por sus siglas en inglés CNN (Convolutional Neural Network), que permitió y brindó solución al reconocimiento de los patrones de puntos con una mayor rapidez, además de automatizar el proceso, y mejorar la capacidad para identificar los patrones característicos.



**Figura 2.** Patrón de puntos en forma de pétalo. (a) Engranaje en buen estado. (b) Engranaje con grietas. [3]

En la misma línea de aplicación de las CNN, las investigaciones de [6, 7] aplicaron el método SDP para la visualización de las imágenes y las CNN para la identificación de los patrones en el diagnóstico de fallos de rodamientos. Esto les permitió reconocer con una precisión del 99%, el estado del rodamiento e identificar la posición relativa entre la ubicación del instrumento de la toma de datos y el rodamiento donde ocurrió el fallo.

En el transcurso del año 2019 la investigación de [8] aplico la técnica SPD para detectar los fallos de funcionamiento de un ventilador industrial que tiene un diámetro de entrada del impulsor de 56,8 cm, diámetro de salida del impulsor de 80 cm, además de 12 palas ubicadas a 45°. Debido a que se trabajaba con una gran cantidad de datos, con el fin de reducir la cantidad de datos inválidos en la toma y preservar aquellos que tenían diferencias, se aplicó el método de análisis de componentes principales, por sus siglas en ingles PCA (Principal Component Analysis), lo que permitió reducir la cantidad de 500 datos a 80 datos y detectar los fallos con el 98% de precisión.

En el mismo año, la investigación de [9] permitió identificar características de las imágenes de estado de vibración, transformando señales de vibración de un rotor en imágenes SDP. Además, con la implementación de las CNN, obtuvieron una precisión del 92% al 96.5% con respecto a la identificación de las fallas. Los mismos autores en la investigación de [9, 10] afianzan la información característica de las fallas de vibración de un rotor y obtiene un diagnóstico de fallo, mediante señales acústicas generadas por ordenadores.

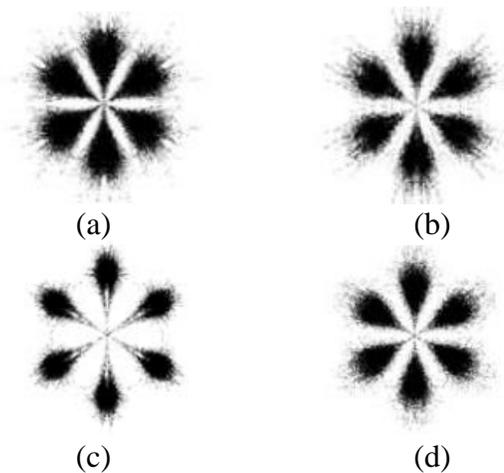
Para el año 2021, en la investigación de [11] con el fin de mejorar las imágenes del método SDP, utiliza una novedosa técnica conocido como distancia Manhattan, aplicada a la detección de fallos en rodamientos, cuya técnica es una métrica de distancia entre dos puntos en una cuadrícula ortogonal, lo que descompone la imagen SDP y permite distinguir aspectos más detallados de la imagen, con la cual se obtuvo una precisión en el diagnóstico de fallo del 97.5%. Con el fin de obtener mejores resultados, los mismos autores en la investigación de [12] incorpora la técnica de la distancia Chebyshev en el diagnóstico de fallos de rodamientos, que consiste en una métrica diferente a la distancia Manhattan ya que esta trabaja con la distancia máxima entre dos puntos en el espacio, siendo la máxima diferencia absoluta entre los dos puntos, con el cual se detallaron nuevas características de las imágenes SDP, y obtuvieron una precisión en el diagnóstico de fallo del 95.46%.

En este mismo año, la investigación de [4] con el fin de afianzar esta técnica en el área industrial, reúnen y resumen la revisión del estado del arte en cuanto al monitoreo y diagnóstico de métodos basados en señales vibratorias y acústicas. Con el fin de familiarizar a la

comunidad con el contenido teorico del procedimiento y concepto de la técnica del patrón de puntos.

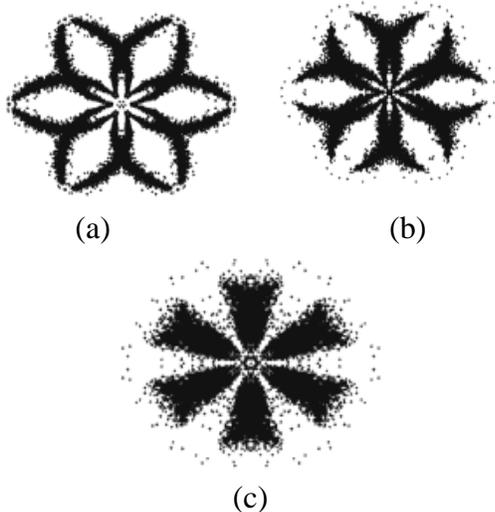
En el área de la salud, en el año 2020, en la investigación de [13] se utilizó la técnica de la auscultación como entrada de datos para la técnica SDP. Esta técnica es un procedimiento clínico en el cual se escucha y registra datos en base a las señales vibratorias de los latidos del corazón para la búsqueda de enfermedades. Con el registro de las señales graficaron mediante la técnica SDP. Además, utilizaron la técnica PCA, que simplifica la dimensionalidad de los datos recolectados, con lo que obtuvieron una precisión del 83.33% en el diagnóstico de enfermedades del corazón.

Con respecto al área automotriz, los investigadores de [5] utilizan la técnica SDP para identificar señales acústicas y de vibración, en condiciones de fallo en motores de combustión interna de 4 cilindros. Los patrones para estos motores se obtuvieron de acuerdo a condiciones de fallas supervisadas con una duración de 12 segundos por cada toma de las muestras. De las cuales en función a la velocidad del motor (revoluciones por minuto) y la condición de fallo, obtuvieron diferentes formas de copos de nieve, así como se evidencia en la Figura 3 (a) correspondiente a un fallo en el encendido por chispa a 750 rpm, mientras que en la Figura 3 (b) se evidencia el mismo fallo a 2000 rpm. Además, en la Figura 3 (c) se presenta la imagen correspondiente a una fuga de aire en el colector a 750 rpm, mientras que en la Figura 3 (d) se evidencia el mismo fallo, a 2000 rpm, demostrando así la variación del patrón conforme la variación del rpm.



**Figura 3.** Patrón de puntos en forma de copo de nieve. (a) Fallo encendido por chispa a 750 rpm. (b) Fallo encendido por chispa a 2000 rpm. (c) Fuga de aire en el colector a 750 rpm. (d) Fuga de aire en el colector a 2000 rpm. [5]

Con el fin de mejorar la investigación de [5], en el año 2011 los investigadores en [14] plantean la técnica SDP junto con el filtro de correlaciones de onda, por sus siglas en inglés WSCF (Wavelet Scattering Correlation Filter) que es una técnica utilizada para el procesamiento de señales con el fin de filtrar y eliminar el ruido de señales sin tratamiento. Con lo cual determinaron que la señal acústica puede verse afectada fácilmente por el ruido ambiental y es necesario el tratamiento de la señal. Con este tratamiento se pueden clasificar las imágenes SDP entre un motor en funcionamiento normal como en la Figura 4 (a), uno con un sonido anormal en el lado derecho del motor como en la Figura 4 (b) y uno con un sonido anormal en la caja de transmisión como en la Figura 4 (c). Debido a que la investigación se realizó en un motor mono cilíndrico, las tomas de muestras duraron 5 segundos cada una, disminuyendo el tiempo de toma con respecto a un motor de 4 cilindros.



**Figura 4.** Patrón de puntos. (a) Motor en funcionamiento normal. (b) Sonido anormal en el lado derecho del motor. (c) Sonido anormal en la caja de transmisión. [14]

Ya en el 2022, en la investigación de [15] con el método SDP y mediante el uso de las CNN, se identifica el ruido de un motor de un vehículo tradicional de uno eléctrico, presentando una validación de la CNN del 100%, demostrando una alta efectividad en la clasificación. Esto derivó en el incentivo de la industria a desarrollar esta metodología para el diagnóstico de fallas en motores.

Como se ha presentado en las investigaciones ya mencionadas, la técnica SDP ha mostrado una alta efectividad para el diagnóstico de fallos en máquinas rotatorias y en especial en motores de combustión

interna. Sin embargo, aún existen áreas que requieren perfeccionamiento y mayor exploración, especialmente en el contexto de la inducción de fallos específicos en motores poli cilíndricos de combustión interna a gasolina. En este estudio, se pretende no solo ampliar la base de datos existente, sino también abordar fallos la anulación de funcionamiento de un cilindro por fallo de ignición o por fallo de inyección de combustible. Esta metodología se divide en dos fases. En la primera fase, se desarrolla una base de datos de imágenes SDP para motores de 2000 cm<sup>3</sup> y 4 cilindros. En la segunda fase, se aplican redes neuronales convolucionales (CNN) con el objetivo de obtener una clasificación precisa de la condición de fallo del motor. Esta investigación no solo busca mejorar la precisión y confiabilidad del diagnóstico, sino también contribuir significativamente al desarrollo de técnicas no invasivas y avanzadas para la monitorización y mantenimiento de motores, ofreciendo nuevas perspectivas para futuras investigaciones.

## 2. Métodos y materiales

En esta sección se abordan los temas principales relacionados con: la metodología para el desarrollo de la investigación, unidad experimental, adquisición de datos, así como el algoritmo para la obtención de patrones de puntos a través de la transformada de Fourier, y el diseño del algoritmo de la red neuronal convolucional en Matlab para la obtención de los resultados con respecto a la clasificación de los patrones.

### 2.1. Metodología para el desarrollo de la investigación

Para el desarrollo de la investigación se empleó el proceso del flujograma presentado en la Figura 5.

En la primera fase del flujograma se emplea un enfoque inductivo con el propósito de identificar las variables de interés y preparar la unidad experimental. Esto implica la obtención del estado actual del conocimiento de revistas científicas de alto nivel, y documentos de grado obtenidos del repositorio institucional. Como resultado, se identificaron las expresiones matemáticas y el diseño de los algoritmos

necesarios para aplicar la metodología de análisis de patrones.

En la segunda fase del flujograma se ejecuta la metodología experimental. En la cual las condiciones de funcionamiento empleadas para llevar a cabo la experimentación se extrajeron de las investigaciones [5, 14]. Además, en esta fase se registra y analiza los datos como se detalla en la sección 2.5, con el objetivo de validar las muestras.

Para finalizar en la tercera fase del flujograma, se identifican los patrones de puntos relevantes, empleando una metodología deductiva para establecer el diagnóstico del motor de combustión interna, respecto de los fallos de un cilindro, ya sea por anulación de ignición o inyección de combustible.

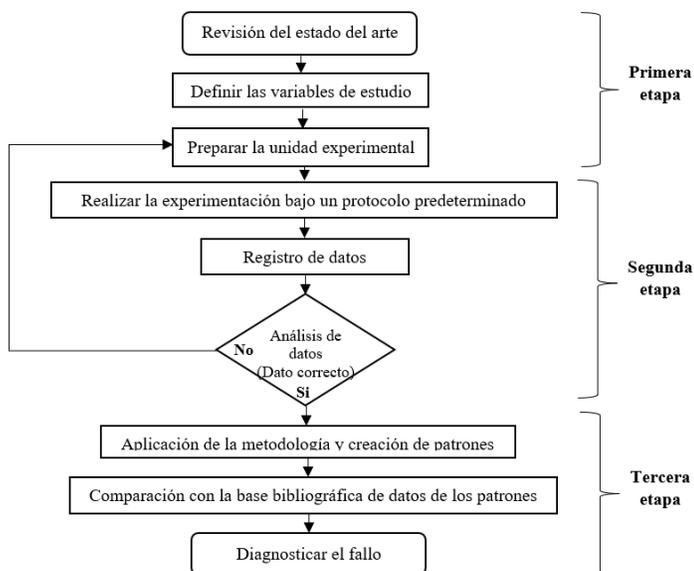


Figura 5. Metodología del desarrollo de la investigación.

Una vez establecida la metodología para el desarrollo de la investigación, se realiza la preparación e instrumentación de la unidad experimental.

## 2.2. Unidad experimental

Para la aplicación de esta investigación se seleccionó un motor a gasolina comúnmente aplicado en las investigaciones, como [16, 17], además de contar con las especificaciones técnicas de la Tabla 1.

Tabla 1. Especificaciones técnicas del motor de combustión interna.

Especificaciones técnicas del motor	
Potencia máxima	136 CV/ 100 kW

Par máximo	180 Nm
RPM potencia máxima	5800 rpm
RPM par máximo	4800 rpm
Numero de cilindros	4
Relación de compresión	10:1
Cilindrada	1.997 cm <sup>3</sup>
Disposición de cilindros	En línea
Consumo combustible	8.9 L/100 km

Con respecto a la instrumentación para el desarrollo de la técnica SDP se registra la señal acústica del motor, para ello se implementa un dispositivo de toma de señales acústicas, que para el desarrollo de esta investigación es un teléfono móvil que presenta sus especificaciones técnicas en la Tabla 2. Respecto de la ubicación, y como se representa en la Figura 6, el teléfono móvil se coloca a 30 centímetros de alto, tomando como referencia la tapa del radiador e inclinando el celular a 45 grados como se indica en la norma ISO 3745:2012 aplicada de la misma manera en la investigación de [16].

Tabla 2. Especificaciones técnicas del teléfono móvil.

Especificaciones técnicas del teléfono móvil	
Almacenamiento	128 GB
GPU	4 núcleos
CPU	6 núcleos (2 de rendimiento, 4 de eficiencia)
Chip	A15 Bionic
Temperatura de funcionamiento	0 a 35 °C
Batería	Iones de litio
Sistema operativo	iOS



Figura 6. Instrumentación para toma de muestras.

Una vez que la unidad experimental ha sido preparada e instrumentada, se procede a la adquisición de datos.

## 2.3. Adquisición de datos

Para el tratamiento de las señales acústicas se presenta el esquema de los elementos necesarios en la Figura 7.

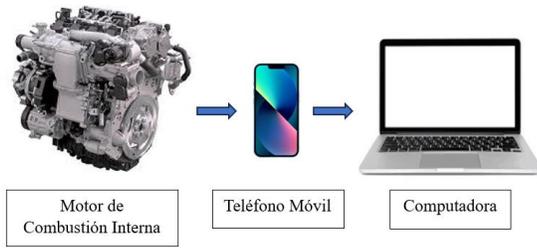


Figura 7. Esquema para adquisición de señales acústicas.

Para la obtención de las señales acústicas del motor en aceleración libre como en la investigación de [16], se sigue el flujograma de proceso presentado en la Figura 8.

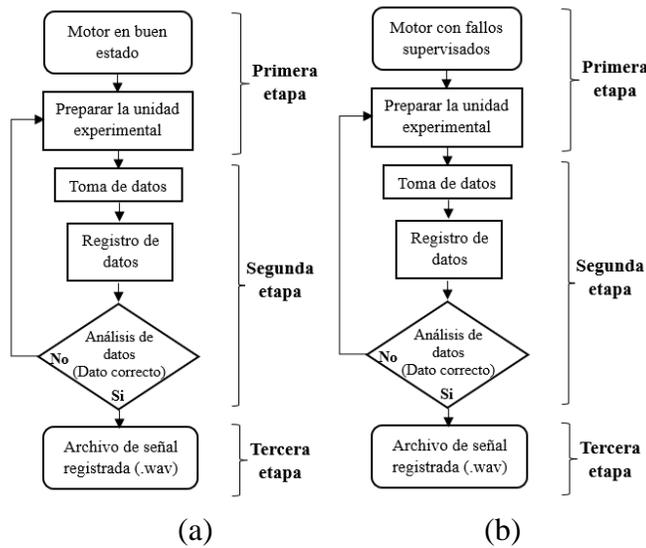


Figura 8. Flujograma de proceso para la adquisición de datos. (a) Motor en buen estado. (b) Motor con fallos inducidos.

En la primera etapa del flujograma se inicia con la verificación de la condición del motor, ya sea en buen estado de funcionamiento, o en condición de fallo supervisado. Respecto a los fallos, en la Tabla 3 se indican el total de 9 condiciones de funcionamiento comúnmente aplicadas, que se generan en la unidad experimental.

Tabla 3. Fallos supervisados en la unidad experimental.

Nº	Condición de funcionamiento	Estado
1	Motor en buen estado	Ok
2	Falla inyector 1	Falla supervisada
3	Falla inyector 2	Falla supervisada
4	Falla inyector 3	Falla supervisada
5	Falla inyector 4	Falla supervisada

6	Falla Bujía 1	Falla supervisada
7	Falla Bujía 2	Falla supervisada
8	Falla Bujía 3	Falla supervisada
9	Falla Bujía 4	Falla supervisada

Con respecto a la inducción de los fallos supervisados, para generar la falla de inyección, se desconectaron los inyectores de cada cilindro del motor, manteniendo tres cilindros en funcionamiento. Mientras que, para generar las fallas ignición, se retiró las bujías, y se disminuyó la calibración de la bujía a 0 mm, con el fin de anular la chispa en un cilindro, manteniendo tres cilindros en funcionamiento.

Posterior a ello se debe poner a punto las condiciones de funcionamiento requeridas para la toma de muestras, en la que el motor debe estar en temperatura óptima de funcionamiento, que en este caso es entre 90 °C a 98 °C, como se indica en las investigaciones de [17, 18]. Con la puesta a punto del motor, se coloca el teléfono móvil conforme a la norma especificada. Se procede a configurar la velocidad de fotogramas en 48 kHz, siendo más elevada que la velocidad de 2.5 kHz presentada en la investigación de [15], además se realiza las tomas de 12 segundos cada una, a diferencia de los 15 segundos que se plantean en la investigación de [4], en adición a ello, se debe de verificar que el electroventilador no se encuentre encendido.

En la segunda etapa del flujograma se realiza la grabación de las señales acústicas y el registro de las mismas. En la que una vez registrados los datos se los analiza con el fin de verificar que las muestras sean validas, en caso de no serlo se vuelve a preparar la unidad experimental y se continua con el proceso ya mencionado.

En la tercera etapa del flujograma se obtiene el archivo de audio en formato “wav”, el cual se añade a la base de datos para su posterior procesamiento con la técnica de patrón de puntos y la transformada de Fourier, obteniendo las imágenes SDP, para la implementación en la CNN.

Debido a que la investigación [14] indica que el ruido ambiental tiene influencia en las señales acústicas producidas por el motor de combustión interna, con el fin de cancelar el ruido ambiental, la toma de muestras del motor se realiza en la cámara semianecoica del laboratorio de las instalaciones de la Universidad

Con la adquisición de los datos ya desarrollada, se precede con el algoritmo para la obtención de los patrones de puntos.

## 2.5. Algoritmo para la obtención de patrones de puntos

Conforme a la elaboración del algoritmo, se realiza en dos etapas. En la primera etapa se implementan las ecuaciones (1), (2) y (3) de la investigación de [10] como funciones, donde las variables de las ecuaciones en el espacio de las coordenadas polares se representan en la Figura 9. Mientras que en la segunda etapa se realiza la selección del archivo de audio en formato “wav”, la asignación de los valores del parámetro de intervalo en el tiempo y el coeficiente de amplificación y la generación de las gráficas.

$$r(i) = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \quad (1)$$

$$\theta(i) = \theta + \frac{x_{i+l} - x_{\min}}{x_{\max} - x_{\min}} \xi, \quad (2)$$

$$\varphi(i) = \theta + \frac{x_{i+l} - x_{\min}}{x_{\max} - x_{\min}} \xi, \quad (3)$$

En donde:

$r(i)$  = radio de las coordenadas polares.

$\theta(i)$  = ángulo de deflexión en sentido antihorario en el plano de simetría de coordenadas polares.

$\varphi(i)$  = ángulo de deflexión en sentido horario en el plano de simetría de coordenadas polares.

$x_{\max}$  = amplitud máxima de la señal.

$x_{\min}$  = amplitud mínima de la señal.

$l$  = parámetro de intervalo en el tiempo.

$\xi$  = coeficiente de amplificación.

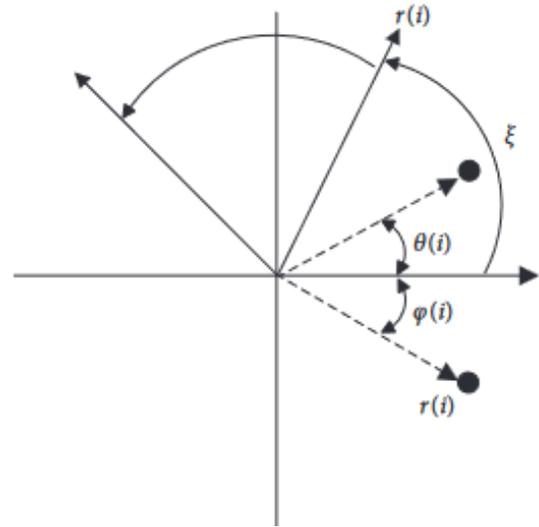


Figura 9. Variables en el plano polar. [10]

Para la implementación del algoritmo, se definió los valores para  $l = 80$ , y  $\xi = 30$ , tomando como base la investigación de [15], en la que se generaron las imágenes SDP con diferentes combinaciones de constantes en el parámetro de intervalo en el tiempo y el coeficiente de amplificación. Con ello se determinó los coeficientes a utilizar para la presente investigación, con el fin de garantizar imágenes SDP que presenten patrones distribuidos en el plano polar.

En la Figura 10 se presenta un esquema del proceso para la obtención de los patrones de puntos.

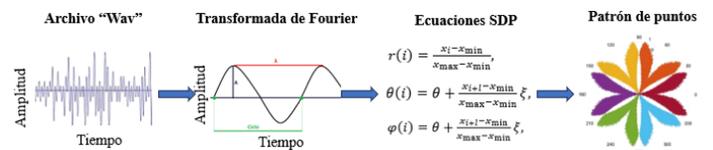
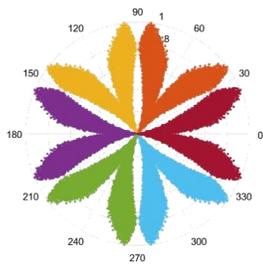
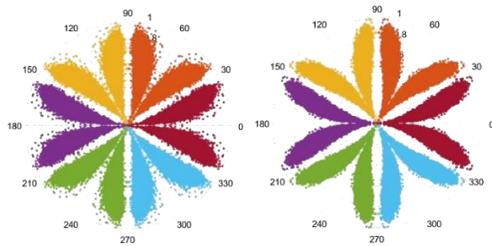


Figura 10. Esquema del proceso para la obtención de patrones de puntos

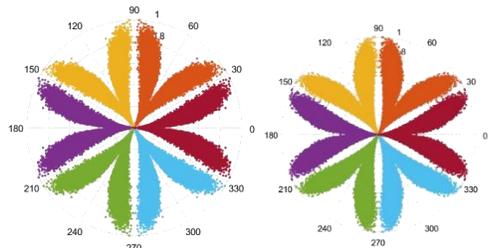
En la Figura 11, se presentan las gráficas SDP obtenidas correspondientes a la condición de buen estado del motor, lo que genera la referencia para la comparación de los patrones en la investigación. En la Figura 12 se presentan las gráficas SDP correspondientes al fallo por anulación de inyector en los 4 cilindros del motor. Mientras que en la Figura 13 se presentan las gráficas SDP correspondientes al fallo por anulación de chispa en los 4 cilindros del motor



**Figura 11.** Patrones de puntos de motor en buen estado.

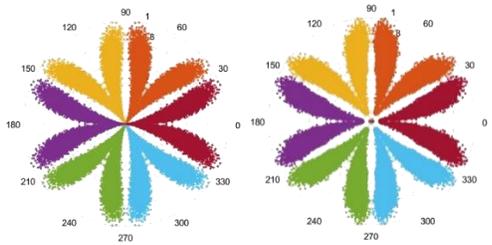


(a) (b)

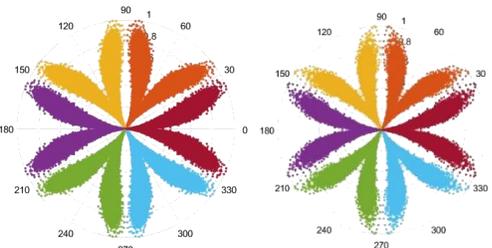


(c) (d)

**Figura 12.** Patrones de puntos de fallo de anulación de inyector. (a) Inyector 1. (b) Inyector 2. (c) Inyector 3. (d) Inyector 4.



(a) (b)



(c) (d)

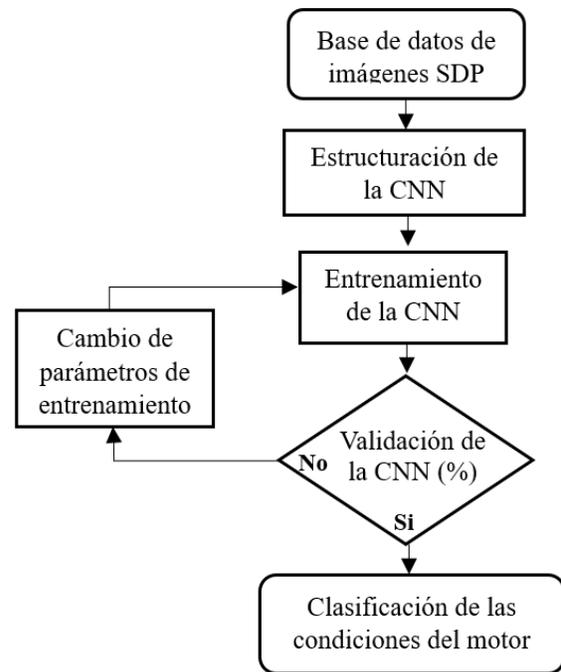
**Figura 13.** Patrones de puntos de fallo de anulación de chispa. (a) Bujía 1. (b) Bujía 2. (c) Bujía 3. (d) Bujía 4.

Debido a que, con la visualización humana, las imágenes no presentan distinciones significativas, se implementa el uso de CNN. Por lo que, con el fin de obtener una amplia base de datos para su procesamiento posterior en la CNN, se obtuvieron 50 imágenes SDP por cada condición de funcionamiento. Además, se obtuvieron 10 imágenes SDP adicionales por cada condición de funcionamiento, con el fin de establecer una base de datos de verificación del diagnóstico. Por lo que se obtuvieron un total de 540 imágenes SDP.

Establecida la base de datos de las imágenes SDP, con la obtención de los patrones de puntos, se desarrolló la red neuronal convolucional.

## 2.6. Diseño del algoritmo de la red neuronal convolucional en Matlab

Para el proceso de creación se implementó el procedimiento presentado en el flujograma de la Figura 14.



**Figura 14.** Flujo de proceso para creación de la CNN.

Para la elaboración del algoritmo de la CNN, se inicia con la lectura de la base de datos de las imágenes SDP, posterior a ello se normaliza el tamaño de las imágenes de entrada a 224 x 224 píxeles con el objetivo de que la CNN identifique de mejor manera los patrones en las imágenes SDP. A continuación, se procedió a la creación de la arquitectura de la CNN, como se presenta en la Figura 15.

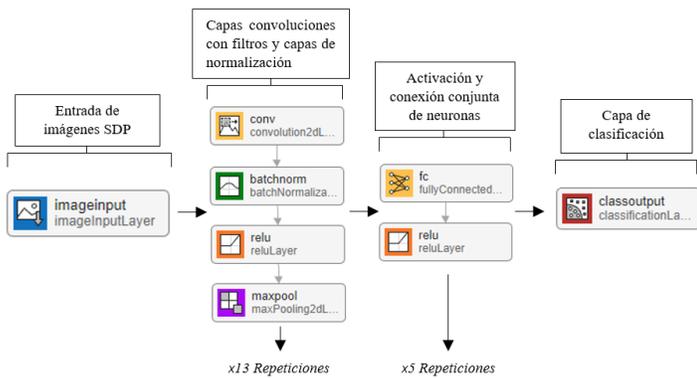


Figura 15. Arquitectura de la CNN.

Como se observa en la Figura 15, se genera la entrada y parametriza el tamaño de las imágenes SDP, con la función `imageInputLayer`. Continuando con la arquitectura se estructura una secuencia de capas convolucionales conformadas por la función `Convolution2dLayer` para imágenes en 2D, mientras que con la función `batchNormalizar` se normaliza las matrices conformadas por las imágenes SDP en las capas convolucionales, y completando la secuencia con la función `reLuLayer` y `MaxPooling2dLayer`, repitiendo la misma secuencia 13 veces con el fin de encontrar diferencias detalladas en las imágenes SDP.

Una vez completada la secuencia, se utiliza las funciones `FullyConnectedLayer` y `reLuLayer` con el fin de activar y conectar las neuronas de las capas convoluciones, estableciendo 9 neuronas, que es la cantidad de clasificaciones planteadas en la investigación.

Para concluir con el desarrollo de la arquitectura se integra la función `ClassificationLayer`, que se encarga de realizar la clasificación, de acuerdo al número de neuronas establecidas.

Una vez desarrollado el algoritmo de la CNN, se procede a la obtención de los resultados de validación de entrenamiento.

### 3. Resultados y Discusión

Para el entrenamiento de la CNN se configuran los siguientes parámetros: tipo de entrenamiento, número de épocas y la frecuencia de validación como en la investigación de [15]. Los cuales se fueron regulando conforme se obtenían los porcentajes de validación de

la CNN, ya que como en el proceso de entrenamiento presentado en la Figura 16, y con la configuración de parámetros seleccionando el tipo de entrenamiento “adam”, número de épocas = 60 y la frecuencia de validación = 30, inicialmente se obtuvo una validación de 58.75%.

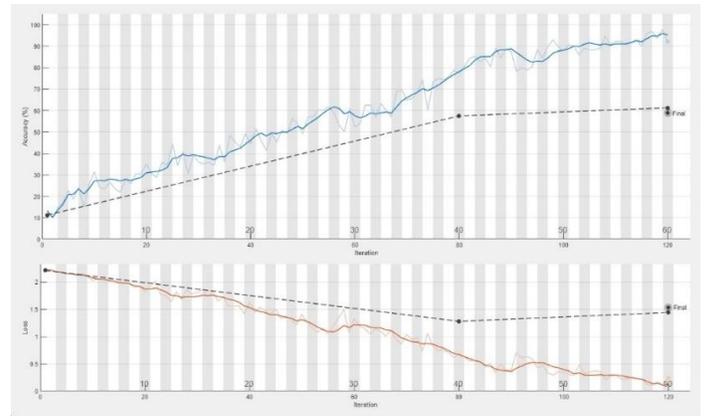


Figura 16. Entrenamiento de la CNN con parámetros iniciales.

Debido a los bajos porcentajes de validación se repitió el proceso de configuración, con lo cual se estableció los parámetros, seleccionando el tipo de entrenamiento “adam”, número de épocas = 70 y la frecuencia de validación = 80. Con lo cual se obtuvo el proceso de entrenamiento presentado en la Figura 17 con un porcentaje de validación de 86.67% de la CNN, que es similar al porcentaje de 83.33% obtenido en la investigación de [13].

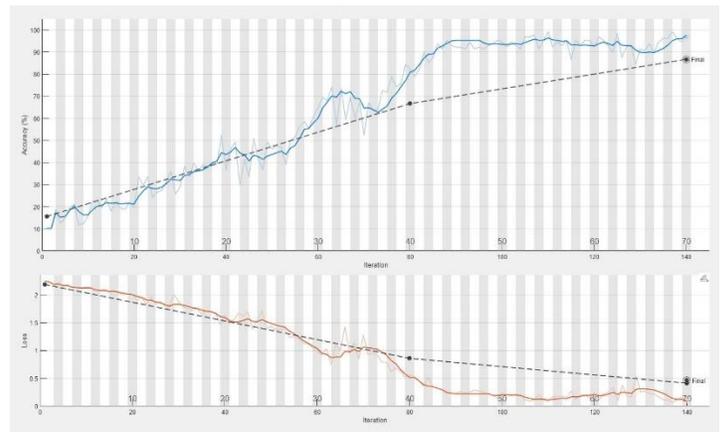


Figura 17. Entrenamiento de la CNN con parámetros optimizados.

Tras optimizar los parámetros de entrenamiento de la red neuronal convolucional (CNN), se obtuvo la matriz de confusión que se muestra en la Figura 18. En esta matriz se observa un bajo número de errores en la predicción de fallos en general. Sin embargo, hubo dificultades específicas con dos tipos de fallos: se

registraron tres errores al predecir fallos en el cilindro 1 del motor, causados por la anulación del inyector, y tres errores al predecir fallos en el cilindro 3, debido a una bujía cerrada. Estos fueron los fallos con mayor dificultad de predicción.

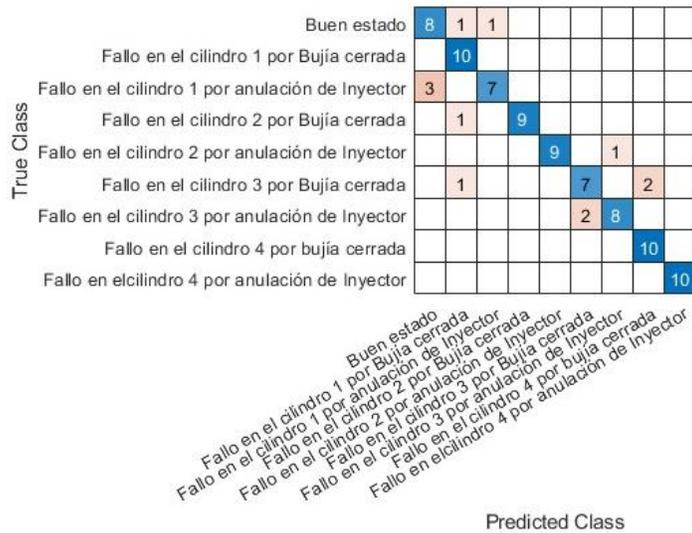


Figura 18. Matriz de confusión de la CNN.

Con el fin de comprobar el funcionamiento del sistema de diagnóstico, se ingresó la base de datos de verificación, la cual no se entrenó en la CNN y se obtuvo los resultados de la Tabla 4.

Tabla 4. Comprobación del sistema de diagnóstico.

Comprobación del sistema de diagnóstico		
Condición	N° Diagnósticos	
	Correctos	Incorrectos
Buen estado	8	2
Fallo inyector 1	9	1
Fallo inyector 2	7	3
Fallo inyector 3	9	1
Fallo inyector 4	9	1
Fallo bujía 1	7	3
Fallo bujía 2	7	3
Fallo bujía 3	8	2
Fallo bujía 4	9	1

Con la implementación de la base de datos de imágenes SDP no ingresada en la CNN se identificó los fallos de anulación de un cilindro. Para el fallo en la anulación del inyector, se obtuvo un porcentaje de efectividad en el diagnóstico del 90% para el inyector 1, 70% del inyector 2, 90% del inyector 3 y 90% del inyector 4. Mientras que, para los fallos de ignición, se obtuvo una efectividad de diagnóstico de 70% de la bujía 1, 70% de la bujía 2, 80% de la bujía 3 y 90% de

la bujía 4. Además, se obtuvo una efectividad de diagnóstico del 80% cuando el motor se encuentra en buen estado de funcionamiento.

Se evidencia que existe un número de 73 diagnósticos correctos de los 90 realizados, lo que representa al 81.11% de total. Esto muestra una diferencia del 5.56% con respecto a la validación del entrenamiento de la CNN.

## 4. Conclusiones

Se constata la efectividad de la metodología de patrón de puntos SDP y la implementación de redes neuronales convolucionales (CNN) en el proceso de clasificación de los patrones, lo que permitió alcanzar un porcentaje de validación del 86.67%, demostrando la eficacia de esta técnica en el diagnóstico de fallos en motores de combustión interna.

Se elaboró una ampliación de las bases de datos establecidas en las investigaciones presentadas en la sección 1, ya que el motor muestreado cuenta con las especificaciones técnicas de la Tabla 1, siendo diferente de las demás investigaciones. Además, se configuró el parámetro de intervalo en el tiempo = 80, y el coeficiente de amplificación = 30.

Se determinó que la adquisición de datos en la cámara semianecoica garantiza la calidad acústica de las muestras, al cancelar el ruido ambiental, evitando distorsiones acústicas con el fin de posteriormente obtener las imágenes SDP y realizar el correcto diagnóstico de las condiciones de funcionamiento presentadas.

## Referencias

- [1] Y. t. H. N. Y. Clifford A. Pickover IBM Thomas J. Watson Research Center, «On the use of symmetrized dot patterns for the visual characterization of speech wave forms and other sampled data,» *Computer Science Department*, p. 6, 1986.
- [2] A. T. A. T. S. KATSUHIKO SHIBATA, «FAULT DIAGNOSIS OF ROTATING MACHINERY THROUGH VISUALISATION OF SOUND

- SIGNALS,» 2000 Academic Press, p. 13, 1999.
- [3] P. V. M. Aneesh D. Diwakar, *Symmetrised dot pattern technique for fault diagnosis in a spur gear assembly using vibration signals*, Tamil Nadu, India: IOP Conference Series: Materials Science and Engineering, 2019.
- [4] D. K. J. B. J. Kriston, «Application of vibro-acoustic methods in failure diagnostics,» *Journal of Physics: Conference Series*, 2021.
- [5] C.-Q. C. Jian-Da Wu, «Fault diagnosis of internal combustion engines using visual dot patterns of acoustic and vibration signals,» *ELSEVIER*, p. 10, 2005.
- [6] J. X. R. Y. Hui Wang, «Bearing Fault Diagnosis Based on Visual Symmetrized Dot Pattern and CNNs,» *Sipailou*, vol. 2, 2019.
- [7] J. X. R. Y. R. X. G. Hui Wang, «A New Intelligent Bearing Fault Diagnosis Method Using SDP Representation and SE-CNN,» p. 12, 2019.
- [8] M. Q. H. L. Xiaogang Xu, «Real-time stall detection of centrifugal fan based on symmetrized dot pattern analysis and image matching,» *Measurement*, pp. 437-446, 26 03 2019.
- [9] D. H. P. Z. Z. H. ., Y. Y. W. Z. Q. Y. Xiaoxun Zhu, «Rotor fault diagnosis using a convolutional neural network with,» *ELSEVIER*, 2019.
- [10] J. Z. D. H. Z. H. Xiaoxun Zhu, «An SDP Characteristic Information Fusion-Based CNN Vibration Fault Diagnosis Method,» *Hindawi Shock and Vibration*, vol. 2019, p. 14, 2019.
- [11] S. L. Y. W. X. W. Yongjian Sun, «Fault diagnosis of rolling bearing based on empirical mode decomposition and improved manhattan distance in symmetrized dot pattern image,» *Mechanical Systems and Signal Processing*, vol. 159, 2021.
- [12] S. L. X. W. Yongjian Sun, «Bearing fault diagnosis based on EMD and improved Chebyshev distance in SDP image,» *Measurement*, vol. 176, 2021.
- [13] R. S. A. S. Monali More, «AUTOMATIC AUSCULTATION USING VISUAL DOT PATTERN,» *Seybold Report*, 09 2020.
- [14] F. T. Yang Cheng, «Abnormal Noise Diagnosis of Internal Combustion Engine Using,» *Applied Mechanics and Materials Vol. 141*, 2011.
- [15] W.-J. L. K.-C. Y. Jian-DaWu, «Pattern, Acoustic Signal Classification Using Symmetrized Dot and Convolutional Neural Network,» *Machines*, 25 01 2022.
- [16] I. 3745:2012, «Acoustics — Determination of sound power levels and sound energy levels of noise sources using sound pressure — Precision methods for anechoic rooms and hemi-anechoic rooms,» International Organization for Standardization, 2012.
- [17] R. I. C. Siavichay, *DISEÑO DE UN ALGORITMO DE VISUALIZACIÓN PARA EL DIAGNÓSTICO DE FALLAS EN MOTORES DE ENCENDIDO PROVOCADO MEDIANTE LA UTILIZACIÓN DE LA TRANSFORMADA DE WAVELET*, Cuenca: Universidad Politecnica Salesiana, 2018.
- [18] W. Contreras Urgeles, J. Maldonado Ortega y R. Leon Japa, «Application of feed-forward backpropagation neural network for the diagnosis of mechanical failures in engines provoked ignition,» *INGENIUS N.º21*, n° 32-40, 2019.