



Procedimiento para la detección y clasificación de fallos en motores de combustión interna utilizando las señales de presión en la admisión y vibraciones mecánicas.

Daniel Felipe Salazar Ramírez

Trabajo de investigación presentado para optar al título de Magíster en Ingeniería
Mecánica

Asesor

Ricardo Moreno Sánchez, Doctor (PhD) en Ingeniería

Universidad de Antioquia
Facultad de Ingeniería
Maestría en Ingeniería Mecánica
Medellín, Antioquia, Colombia
2023

Cita	(Salazar Ramírez, 2024)
Referencia	Salazar Ramírez, D. (2024). Procedimiento para la detección y clasificación de fallos en motores de combustión interna utilizando las señales de presión en la admisión y vibraciones mecánicas. [Tesis de maestría].
Estilo APA 7 (2020)	Universidad de Antioquia, Medellín, Colombia.



Maestría en Ingeniería Mecánica.

Grupo de Investigación Diseño Mecánico.

Centro de Investigación Ambientales y de Ingeniería (CIA).



Centro de documentación de Ingeniería (CENDOI)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

AGRADECIMIENTOS

Es imposible nombrar a todas las personas que hicieron parte de este proceso, el cual me llevó a momentos en los que sentí que perdía el norte más de una vez, sin embargo, nunca estuve solo. Los más importantes, mi familia, que siempre me apoyó y estuvo pendiente de mí, que nunca me dejó claudicar, son y siempre serán, mi fuente más grande de inspiración, mi motor. A mi asesor, Ricardo, por su acompañamiento y constante respaldo. A todos y cada uno de los amigos, compañeros, profesores y personal administrativo que me acompañaron durante este proceso, jamás tendré palabras suficientes de agradecimiento por todo el apoyo.

Quiero agradecer especialmente a Daniel Felipe Tobón, a Ingry Natalia Gómez y a Juan Gustavo Diossa porque no solo me acompañaron académicamente sino emocionalmente, les debo gran parte de esto a ustedes.

A Johan, Romero y Cata, compañeros y amigos entrañables que me regaló este proceso, que siempre estuvieron pendientes de mí, me ayudaron e hicieron este camino mucho más llevadero.

“Qué gran libro se podría escribir con lo que se sabe. : - Otro mucho mayor se escribiría con lo que no se sabe! ”.

[La isla misteriosa] — Julio Verne.

CONTENIDO

AGRADECIMIENTOS	2
CONTENIDO.....	4
ÍNDICE DE ILUSTRACIONES	6
ÍNDICE DE TABLAS	7
RESUMEN	8
ABSTRACT.....	9
1. INTRODUCCIÓN	10
1.1. Contexto.....	10
1.2. Objetivos	12
1.2.1. General	12
1.2.2. Específicos	12
2. MARCO TEÓRICO	13
2.1. Funcionamiento del MCI:	15
2.2. Análisis de falla por medio de vibraciones mecánicas	19
2.3. Análisis de falla por medio de señales de presión en la admisión.....	20
2.4. Señales, filtrado y procesamiento	21
2.4.1. Características en el dominio del tiempo	21
2.4.2. Características en el dominio de la frecuencia.....	23
2.4.3. Métodos de filtrado de señales.....	25
2.5. Diagnóstico.....	29
2.6. OBD (On Board Diagnostics).....	30
2.7. Redes Neuronales	33
2.7.1. Modelo de neurona artificial:	35
2.7.2. Perceptrón simple:.....	37
2.7.3. Perceptrón multicapa.....	39
2.7.4. Redes neuronales convolucionales	39
2.8. Análisis de varianza: ANOVA	41
3. ESTADO DEL ARTE.....	44
4. METODOLOGÍA Y RESULTADOS.....	49
4.1. Banco de ensayos	49

4.2.	Cadena de adquisición de datos	50
4.3.	Diseño experimental	52
4.4.	Análisis de resultados	56
4.4.1.	Análisis de señales:	57
4.4.2.	Asentamiento de válvulas:	57
4.4.3.	Cambio en la relación de compresión dentro del cilindro	62
4.4.4.	Soporte de motor:.....	63
4.5.	Selección de variables de alimentación	66
4.5.1.	Análisis estadístico de variables	68
4.5.1.1.	Matriz de correlación:.....	68
4.6.	Análisis de varianza (Test alternativo):	70
4.7.	Red neuronal	75
4.7.1.	Validación de la red.....	78
4.8.	Estadística	78
4.9.	Matriz de confusión	78
5.	CONCLUSIONES.....	81
6.	REFERENCIAS	83

ÍNDICE DE ILUSTRACIONES

Ilustración 1. 4 tiempos de un motor de combustión interna.	17
Ilustración 2. Señal de presión en la admisión de un motor de 4 cilindros.....	18
Ilustración 3. Esquema de funcionamiento de los sensores piezoeléctricos.	20
Ilustración 4. Valores RMS y Peak.....	22
Ilustración 5. Señal de un acelerómetro en el dominio del tiempo	26
Ilustración 6. Señal transformada en el dominio de la frecuencia.....	26
Ilustración 7. Señal en el dominio de la frecuencia filtrada.	27
Ilustración 8. modelo de neurona natural.....	34
Ilustración 9. Perceptrón simple.....	38
Ilustración 10. Esquema de MLP.....	39
Ilustración 11. Proceso de convolución	40
Ilustración 12. Montaje experimental	49
Ilustración 13. Posiciones de las válvulas.	53
Ilustración 14. Esquema de montaje del soporte de motor (caucho rígido).....	54
Ilustración 15. Rigidez del caucho usado para simular fallo en el soporte.	55
Ilustración 16. Superposición de gráficas temporales con siembras en válvulas.....	59
Ilustración 17. Gráficas de frecuencia de la señal de presión	60
Ilustración 18. Gráficas de frecuencia de la señal de aceleración de la vibración	62
Ilustración 19. Gráficas en el dominio del tiempo y de la frecuencia de las señales de presión y aceleración de la vibración	63
Ilustración 20. Gráficas en el dominio del tiempo de las señales de presión y aceleración de la vibración con siembras en soporte del motor.....	64
Ilustración 21. Gráficas en frecuencia de las señales de presión con siembras en soporte.	65
Ilustración 22. Gráficas en frecuencia de las señales de aceleración de la vibración con siembras en soporte.	66
Ilustración 23. Matriz de correlación entre las variables de entrada y las características de respuesta	69
Ilustración 24. Código para la generación de la Red neuronal FNN.....	77
Ilustración 25. Código para generar la matriz de confusión.....	79
Ilustración 26. Matrices de confusión.	79

ÍNDICE DE TABLAS

Tabla 1. Tipos de análisis de fallos en máquinas recíprocas	14
Tabla 2. Características en el dominio del tiempo y momentos estadísticos	23
Tabla 3. Tipos de fallas y características espectrales para el diagnóstico.	30
Tabla 4. Paralelo entre el cerebro humano y un computador. [19]	33
Tabla 5. Funciones de activación.	37
Tabla 6. Equipos empleados para la adquisición de datos.	50
Tabla 7. Especificaciones de los acelerómetros.	51
Tabla 8. Especificaciones del sensor de presión.	52
Tabla 9. Configuración de combinaciones de fallos	56
Tabla 10. Resultados de la prueba Kruskal-Wallis	72

RESUMEN

En este proyecto se obtiene un procedimiento que permite hacer un diagnóstico de la condición de diferentes elementos que se encuentran en los motores de combustión interna, esto a partir de análisis de vibraciones mecánicas y de la evaluación de las señales de presión en el múltiple de admisión, haciendo uso de parámetros de pre-procesamiento de las señales y redes neuronales como clasificadoras del estado del motor. El proyecto tuvo un enfoque experimental y para esto, se usó un motor CFR (*Cooperative Fuel Research*), al cual se le indujeron diversos fallos controlados, llevando a cabo un diseño experimental multifactorial, se lograron identificar 3 tipos diferentes de fallas.

Para el desarrollo experimental de este proyecto, se usaron acelerómetros de tipo piezoeléctricos ubicados en el bloque del motor, así como un sensor de presión piezoresistivo acoplado al múltiple de admisión. Las señales de estos sensores fueron registradas con un sistema de adquisición de datos. Se hizo un análisis gráfico de las señales y se usó la transformada rápida de Fourier (FFT) para descomponer las señales y determinar las componentes que sirvieron de insumo para alimentar y entrenar la red neuronal que se encarga de clasificar y diagnosticar los daños en los diferentes componentes del motor.

Palabras clave: Diagnóstico de motor, Vibraciones mecánicas, Presión en el múltiple de admisión, Redes neuronales.

ABSTRACT

This project, develops a procedure that allows monitoring the condition of different elements found in internal combustion engines, based on mechanical vibration analysis and the evaluation of the pressure signals in the intake manifold, making use of pre-processing parameters of the signals and neural networks as classifiers of the engine condition. The project presents an experimental approach. for that purpose, a CFR (Combustion Fuel Research) engine was used. Controlled faults were introduced, carrying out a multifactorial experimental design, 3 different types of damage were identified with 2 levels of progression of each damage.

For the experimental development of this project, piezoelectric accelerometers located in the engine block and a piezoresistive pressure sensor coupled to the intake manifold were used, connected with a data acquisition system to collect the information. Graphical analysis of the signals was made, and the Fast Fourier Transform (FFT) was used to decompose the signals and determine the components that served as input to feed and train the neural network that is responsible for classifying and diagnosing the damages.

Keywords: *Engine diagnosis, Mechanical vibrations, Intake manifold pressure, Neural networks.*

1. INTRODUCCIÓN

1.1. Contexto

Un motor de combustión interna (MCI) es una máquina que básicamente transforma la energía química de un combustible en energía mecánica rotacional, la cual es usada para generar movimiento o impulsar diversos tipos de sistemas más complejos. Es entonces, una máquina altamente difundida en el mundo, puesto que es el corazón que mueve la mayoría de los vehículos que se encuentran circulando en la actualidad.

La condición del MCI no es una preocupación menor, dada la naturaleza de su funcionamiento, al ser una máquina rotativa, está sujeta a condiciones de trabajo relacionadas con alta presión, temperatura y fricción, lo que posibilita la aparición de problemas tales como desgastes, desajustes, diversos tipos de averías en sus componentes, etc. Tradicionalmente, la detección de estas fallas de tipo mecánico se realiza desarmando el motor y verificando las condiciones de sus componentes, lo que trae consigo, tiempos de parada largos y costos elevados de mantenimiento [1].

La confiabilidad de los MCI se ha convertido entonces en una parte esencial para muchas industrias, tales como las de transporte y de generación de energía, entre otras. Por tanto, es de vital importancia el monitoreo de su funcionamiento, para garantizar un buen desempeño. Debido a la dificultad que conlleva la verificación de los componentes internos de éstos, el desarrollo de herramientas inteligentes de clasificación de fallos se convierte en un avance importante a nivel tecnológico, para garantizar su buen funcionamiento y la intervención en los mismos antes de llegar a averías graves. Además, estas herramientas tienen un efecto económico significativo debido a la posibilidad que brinda de disminuir los costos de mantenimiento. Cuando ocurren fallas internas en los componentes de un motor, pueden darse desde disminuciones en la producción, hasta problemas que afecten gravemente los equipos, llegando incluso a poner en riesgo la seguridad de las personas que se encuentran a su alrededor [2, 3].

Alrededor del 90% de las fallas estructurales que se dan en los MCI tienen relación con las vibraciones mecánicas, esto debido a la fuerza en desequilibrio causada por los diferentes elementos rotatorios y la excitación del combustible. A esto, se le debe sumar, que cualquier tipo de avería en alguno de estos elementos, tiene un efecto considerable en las vibraciones mecánicas, alterando cada vez más las oscilaciones, lo que puede generar daños aún mayores [4].

Los análisis usados para verificar la condición de un motor de combustión interna se pueden agrupar, a grandes rasgos, en función de dos tipos de métodos: los métodos basados en modelos y los basados en características.

Los métodos basados en modelos hacen uso de *software* o modelos computacionales, en los cuales se comparan variaciones en los parámetros para predecir errores relacionados a las posibles fallas. Este tipo de métodos se presentan como una forma efectiva y rápida para realizar un diagnóstico acertado de la condición del motor. Dentro de esta clase de métodos existen modelos como ARMA (*Autoregressive and moving average*) el cual tiene

una base estadística, o como las CNN (*Convolutional neural networks*), las cuales son aplicaciones de *Deep learning*, entre otros.

Los métodos basados en las características son métodos un poco más tradicionales. Inician normalmente con una toma de datos o captura de señales vibratorias, acústicas, térmicas o eléctricas, para luego realizar los procesos necesarios para extraer la información que permita determinar las posibles fallas. Las características se pueden extraer en dominio de tiempo, de frecuencia, de espacio o de tiempo-frecuencia.

Los análisis de vibraciones y de señales de presión en la admisión son herramientas de diagnóstico de la condición de una máquina rotativa que se encuentran catalogados como métodos basados en las características. Éstos se centran en la identificación de patrones dentro de los diferentes sistemas que componen la misma, así como en el análisis de las variaciones en esos espectros de energía o patrones para identificar los diferentes tipos de fallas, tales como desalineaciones, desbalanceos, desajustes, fallas o fracturas en componentes, etc.

A pesar de los avances tecnológicos que nos ofrece la actualidad, los métodos de diagnóstico usados comúnmente aún plantean retos importantes respecto a su aplicación, en algunos casos por el tiempo requerido, como es el caso del análisis de aceite, el cual requiere que las muestras sean llevadas a un laboratorio especializado para su evaluación. En otros casos, como la inspección visual, es necesario destapar el motor y realizar una revisión detallada, resultando éste, un proceso invasivo. Para los análisis de las señales vibratorias y de espectros, el principal problema es la intensidad de las vibraciones producidas por el proceso de combustión. Es por esto, que el presente trabajo plantea una alternativa interesante que, simplifica el diagnóstico al evitar el ruido de la combustión y puede arrojar resultados de diagnóstico en tiempos cortos gracias al uso de las redes neuronales.

Aunque esta metodología se está probando en un motor monocilíndrico, luego se podría implementar en un motor de varios cilindros realizando la respectiva experimentación para detectar los patrones vibratorios y de presión y realizar el entrenamiento de la red neuronal.

1.2. Objetivos

1.2.1. General

Desarrollar un procedimiento no invasivo para la detección y clasificación de fallos en motores de combustión interna por medio del análisis de señales de presión en la admisión y vibraciones mecánicas.

1.2.2. Específicos

- ✓ Realizar la caracterización de un motor de combustión interna, funcionando con sus componentes calibrados según las tolerancias de montaje del fabricante (manuales de reparación del fabricante) y sin averías, para determinar los patrones de señal vibratoria y de presión en el múltiple de admisión en condiciones adecuadas de funcionamiento.
- ✓ Evaluar el efecto estadísticamente significativo sobre la señal vibratoria y la señal de la presión en el múltiple de admisión de los siguientes factores: Avería de soporte del motor, tasa de compresión dentro de la cámara y nivel de asentamiento de válvulas de admisión y escape, por medio de un diseño experimental multifactorial.
- ✓ Determinar parámetros de pre-procesamiento de las señales vibratorias y de presión en el múltiple de admisión, adecuados para la detección de los fallos en el motor de combustión interna por medio de la evaluación de la correcta clasificación de los fallos con redes neuronales y análisis de varianza.
- ✓ Proponer un sistema para la clasificación y análisis de los fallos que permita realizar un diagnóstico confiable y evitar falsas alarmas, utilizando la metodología de matriz de confusión.
- ✓ Proponer y validar la efectividad de un procedimiento no invasivo para la detección y clasificación de al menos 3 de los siguientes fallos: soporte de motor averiado, asentamiento de válvula de admisión incorrecto, asentamiento de válvula de escape incorrecto, caída en la tasa de compresión dentro de la cámara.

2. MARCO TEÓRICO

Muchas empresas, en busca de mantener su productividad, implementan programas de mantenimiento predictivo, esto con el fin de verificar la condición de sus equipos y minimizar las fallas graves y las paradas inesperadas en la producción. Las máquinas reciprocantes hacen parte de los equipos que acaparan buena parte del interés en este aspecto.

Las máquinas reciprocantes están definidas como aquellas que hacen uso de un émbolo o un pistón para generar un movimiento de vaivén, esto con el fin de desarrollar una tarea determinada. Este es el caso de los motores de combustión que se usan en carros, barcos y algunos tipos de aviones, además de las bombas de pistón y algunos compresores alternativos, entre otros. Usualmente son máquinas con buena eficiencia, pero, altos niveles de ruido y vibración [5].

El análisis de fallos de este tipo de máquinas se puede realizar mediante diferentes tipos de procedimientos, como los descritos a continuación en la Tabla 1

Tipo de análisis	Descripción	Ventajas	Limitaciones
Análisis de Vibraciones	se miden las señales vibratorias de la máquina a analizar, y se observa el comportamiento de estas, haciendo uso de características tales como el valor RMS, el valor pico y de un historial del funcionamiento de la máquina misma.	<ul style="list-style-type: none"> No es invasivo. Rápido montaje. Sirve para identificar fallas en componentes mecánicos. 	<ul style="list-style-type: none"> En muchos casos es necesario contar con un histórico. Susceptible al ruido producido por la combustión.
Señales de presión en la admisión	se basa en el análisis del comportamiento de la presión para determinar las posibles afectaciones en el consumo de combustible, la eficiencia volumétrica y el comportamiento interno del motor.	<ul style="list-style-type: none"> No es invasivo. Permite detectar fallas generadas por fugas u obstrucciones 	<ul style="list-style-type: none"> Es limitado respecto a la clasificación de fallas que se pueden detectar efectivamente.
Análisis de ruido	Es un método que recurre al análisis del sonido generado por la máquina, con el fin de detectar algunas anomalías en elementos tales como las válvulas.	<ul style="list-style-type: none"> No es invasivo Permite detectar fallas en elementos internos sin necesidad de destapar el motor 	<ul style="list-style-type: none"> Requiere un ambiente controlado para evitar que ruidos externos intervengan en la lectura

Análisis de aceite	Se toma una muestra del aceite y se analizan la calidad y composición de este, con el fin de detectar corrosión o la presencia de partículas o sedimentos en el mismo.	<ul style="list-style-type: none"> • Ayuda a optimizar los ciclos de cambio de aceite. • Permite detectar fugas o desgastes en algunos componentes. 	<ul style="list-style-type: none"> • Es invasivo • Requiere que la muestra sea llevada a un laboratorio especializado para el análisis
Inspección visual	Es el método tradicional por excelencia, donde un experto efectúa una revisión visual de los componentes	<ul style="list-style-type: none"> • Sirve para la detección de fisuras, desajustes, suciedad nociva, etc. 	<ul style="list-style-type: none"> • frecuentemente, se debe destapar el motor, por lo que puede ser invasivo • Requiere mucho tiempo
Análisis de espectros	Se hace un tratamiento de la señal para analizar el comportamiento del equipo desde las frecuencias y amplitudes generadas por sus componentes, con el fin de detectar patrones anómalos, armónicos y resonancias	<ul style="list-style-type: none"> • No es invasivo • Es posible detectar desajustes, desbalanceos y averías en componentes mecánicos 	<ul style="list-style-type: none"> • En muchos casos es necesario contar con un histórico. • Susceptible al ruido producido por la combustión.

Tabla 1. Tipos de análisis de fallos en máquinas reciprocantes

Todas estas herramientas son importantes y tienen aplicaciones diversas en el diagnóstico de este tipo de máquinas [6, 7].

En el presente estudio, se combinan simultáneamente los análisis por medio de vibraciones mecánicas, de señales de presión en la admisión y el análisis de espectros. Esta combinación no se encuentra reportada en la literatura. Se eligen este tipo de análisis teniendo en cuenta la facilidad que tiene la instalación de los acelerómetros necesarios para medir las vibraciones y, que los vehículos impulsados por MCI ya cuentan con acelerómetros (para detección de knock) y con sensores de y presión en la admisión, de los cuales es posible tomar la señal para hacer la evaluación. Es necesario entonces, hacer una introducción al tema para entender los conceptos básicos que hacen parte de éstos y los fenómenos que permiten que este tipo de análisis sean efectivos para determinar la condición de las máquinas reciprocantes.

La vibración es la respuesta de una estructura o un mecanismo (sistema) a la acción de una fuerza externa y consiste en movimientos repetitivos que se dan al tratar de retornar a una posición de reposo, la misma en la que se encuentra cuando no hay fuerzas aplicadas sobre ésta.

Todas las unidades que se presentan a continuación en esta sección se encuentran en el sistema internacional de unidades (SI).

Como concepto, podemos hablar de 3 características inherentes a estas estructuras o mecanismos que se oponen a la vibración, estas son:

Masa: su unidad de medida es el kilogramo (kg) y representa la inercia que posee un cuerpo que trata de conservar su estado de quietud o movimiento.

Rigidez: Se refiere a la fuerza requerida para deflectar un objeto cierta distancia, sus unidades están dadas en N/m.

Amortiguamiento: Representa la capacidad que tiene el mecanismo o la estructura para disipar energía. El coeficiente de amortiguamiento es la constante de proporcionalidad entre la fuerza que realiza el amortiguador a la velocidad de movimiento del sistema, se mide en N/(m/s).

El comportamiento del sistema sometido a esas fuerzas externas estará entonces relacionado a estas características. En caso de que el sistema se encuentre en condiciones normales, sin fallas, el movimiento vibratorio será regular, cíclico, sin grandes cambios. Sin embargo, si una falla aparece, y las vibraciones generadas por ésta son lo suficientemente grandes para superar el efecto de las características mencionadas, se generarán perturbaciones en el patrón vibratorio que permitirán detectar dicha falla [6].

Existen algunas características físicas que se pueden medir en un cuerpo que se encuentra vibrando, tales como:

- **Desplazamiento:** El desplazamiento, hace referencia a la distancia recorrida desde un punto extremo de la parte que vibra hasta el siguiente punto extremo, es una medida dada en milésimas de milímetro (Micrón).
- **Velocidad:** Se refiere a el cambio de la posición con respecto al tiempo de un punto de la parte que se encuentra vibrando. Normalmente se mide en mm/s.
- **Aceleración:** es una medida dada comúnmente como un múltiplo de la aceleración gravitacional (g), la aceleración como concepto se refiere a la tasa de cambio de la velocidad en función del tiempo. En un sistema que está vibrando, la aceleración y la velocidad varían todo el tiempo dependiendo del punto en el que se encuentre de la oscilación. Sin embargo, en los puntos extremos, cuando la velocidad se hace 0, la aceleración alcanza su valor máximo, y éste puede ser tomado como un número característico de la vibración de un sistema [6, 7].

En casos como el de los MCI, es importante tener en cuenta algunas cosas antes de abordar el problema del análisis de fallas por medio de vibraciones mecánicas o el análisis de espectro, tales como su funcionamiento y por qué vibra.

2.1. Funcionamiento del MCI:

El movimiento inicial del MCI se da gracias a la acción de un motor eléctrico o de arrastre, el cual es alimentado por una batería, este tiene la potencia suficiente para poner en rotación el cigüeñal, el cual se encarga de darle movimiento a los pistones. Después de romper el estado de reposo del sistema, se da inicio a los cuatro tiempos que permiten el funcionamiento a través de la combustión del combustible.

Cuatro tiempos (ver Ilustración 1):

- Primer tiempo: Admisión, el pistón pasa de la posición de reposo superior a la posición de reposo inferior, durante este proceso, la válvula de admisión se encuentra abierta y la válvula de escape se encuentra cerrada, por lo cual se da el ingreso del aire. En algunos de los motores de encendido provocado con inyección multipunto, en medio de este tiempo, se inyecta el combustible necesario para lograr el dosado requerido en el proceso de combustión interna del motor, para los demás, este proceso se lleva a cabo durante el proceso de compresión.
- Segundo tiempo: Compresión, durante este proceso, se cierra la válvula de admisión y se mantiene cerrada la válvula de escape, el pistón pasa de la posición de reposo inferior a la posición de reposos superior, generando un aumento en la presión y en la temperatura de la mezcla de combustible y aire en la cámara del cilindro. Si el motor es de encendido provocado, generalmente, el proceso termina con una chispa, generada por una bujía, dando inicio al proceso de combustión, en caso de un retraso, esta chispa se dará en medio del proceso de expansión. Si el motor es de encendido por compresión, el combustible hará ignición por si solo gracias al aumento de la presión.
- Tercer tiempo: Combustión y expansión, en esta etapa, al generarse la combustión en la cámara del cilindro, se da una reacción que cambia la composición de las sustancias que se encuentran envueltas en el proceso, pasando la mezcla de aire y combustible a convertirse en productos de combustión. Durante este tiempo, las válvulas se mantienen cerradas, generando una alta presión que empuja al pistón al punto de reposo inferior, lo que disminuye nuevamente la presión y la temperatura dentro de la cámara debido a la expansión.
- Cuarto tiempo: Escape, en este tiempo, se abre la válvula de escape, y, debido a la presión remanente en la cámara y al movimiento del pistón, el cual sigue desplazándose gracias a la inercia del cigüeñal, gran parte de los gases que quedan son expulsados hasta el instante en el que el pistón llega al punto de reposo superior, permitiendo únicamente que permanezca un volumen equivalente al espacio que queda en la cámara. Al final del proceso de escape, la válvula de admisión se abre mientras la válvula de escape empieza a cerrarse, en este instante, el pequeño volumen de gases producidos por el proceso anterior es generalmente desplazado por el aire fresco que entra mientras termina de cerrarse la válvula de escape, quedando el sistema en la posición necesaria para empezar de nuevo el ciclo. En condiciones normales de operación, el ciclo de cuatro tiempos busca que la presión en la admisión sea mayor que en el escape para evitar que los gases producto de la combustión permanezcan en la cámara para el comienzo del nuevo ciclo.




Ilustración 1. 4 tiempos de un motor de combustión interna. Tomado de:
<https://jenikirbyhistory.getarchive.net/media/stroke-psf-fd2876>

Estos cuatro tiempos se dan individualmente en cada cilindro, siguiendo un orden sincrónico para permitir el mejor aprovechamiento de la energía generada por la reacción de combustión.

Para un correcto proceso de combustión, los vehículos cuentan con un sensor MAP (*Manifold Absolute Pressure*), el cual se encarga de enviar una señal a la ECU (*Engine Control Unit*), la cual, a partir de esta información, sumada a la de otros sensores como el de flujo de aire en la admisión (MAF), temperatura en la admisión, posición cigüeñal, posición del árbol de levas, rpm, porcentaje de oxígeno en el escape y apertura de la mariposa, toma decisiones acerca de la cantidad de combustible a inyectar y el momento correcto para hacerlo, esto con el fin de obtener un buen dosado estequiométrico en la cámara.

En la Ilustración 2 se puede observar el proceso de admisión de aire en un motor de 4 cilindros de la siguiente forma:

1. Apertura de la válvula de admisión de cilindro 4.
2. Cierre de la válvula de escape del cilindro 4.
3. Apertura de la válvula de admisión del cilindro 2.
4. Punto muerto superior, TDC, punto en donde la válvula admisión está en medio del proceso de apertura y la de escape está en medio del proceso de cierre.
5. Cierre de la válvula de escape del cilindro 2.
6. Apertura de la válvula de admisión de cilindro 1.
7. Cierre de la válvula de escape del cilindro 1.
8. Apertura de la válvula de admisión de cilindro 3.
9. Cierre de la válvula de escape del cilindro 3.
10. Pulso o señal para iniciar la inyección de combustible del cilindro 1.

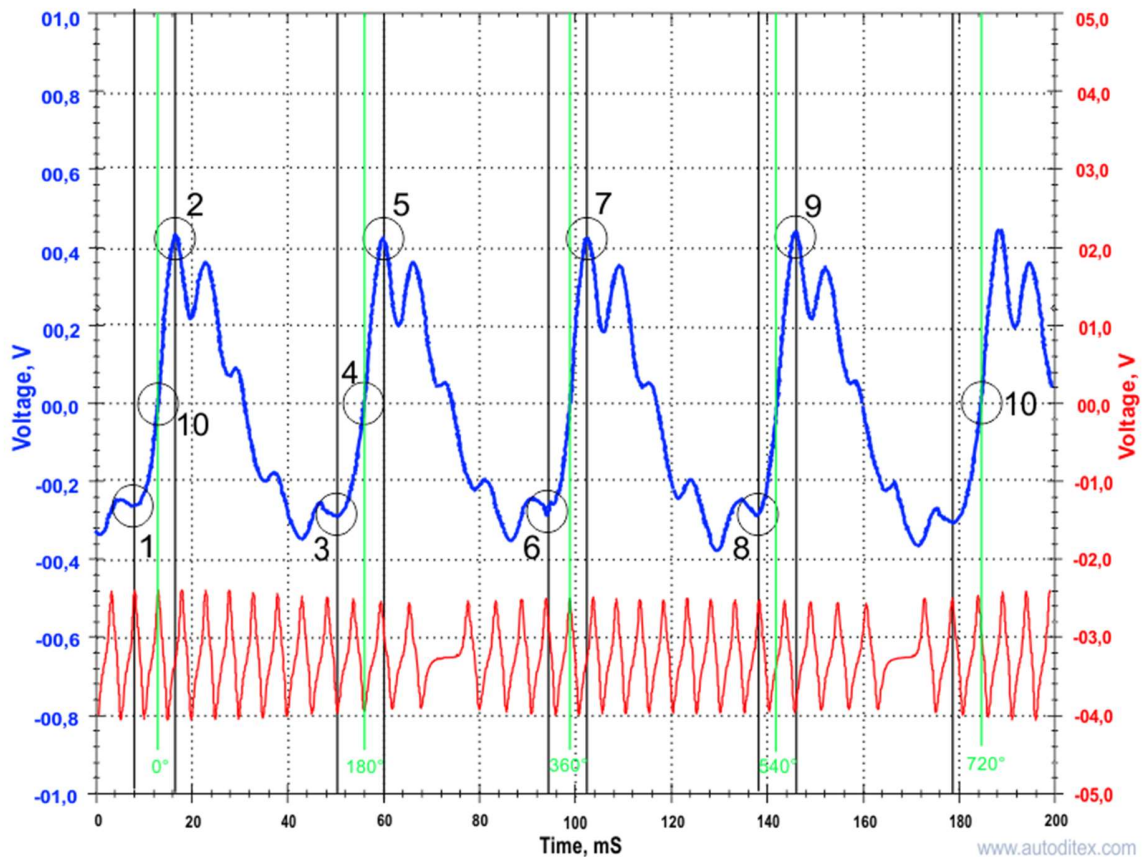


Ilustración 2. Señal de presión en la admisión de un motor de 4 cilindros. Tomado de :
<https://autoditex.com/page/pressure-pulse-sensor-73-1.html>

Como se puede apreciar en la imagen, es importante recalcar que el proceso de los 4 tiempos se completa en 2 revoluciones completas del motor (720°). Para el caso del presente trabajo, se realizaron los estudios en un motor CFR (*Cooperative Fuel Research*), motor para pruebas de laboratorio, monocilíndrico, con relación de compresión variable, que se cuenta instrumentado para mediciones como se describirá posteriormente. Debido a esto, siempre que el motor se encuentre en buenas condiciones, en el espectro deberá aparecer solo un pico de señal de presión cada 2 revoluciones por ser un motor con un solo pistón, lo que se verificará en el análisis de resultados.

Vibraciones en el MCI

Las vibraciones que se dan en un MCI se dividen en 2 grandes grupos principalmente, el primero, está dado por el proceso de combustión en sí, debido a que, como se describió anteriormente, este proceso implica altas presiones y temperaturas, a las cuales se asocian procesos que podríamos denominar como “explosiones controladas” que son las encargadas de aportar la energía necesaria para el funcionamiento del motor. El segundo grupo, se da por la construcción misma de los componentes del motor, básicamente tiene que ver con, el golpeteo que se genera en los elementos conectados a los elementos

giratorios del MCI, tal como sucede con los pistones dentro de la cámara de combustión, o en las válvulas cuando golpean al abrir y cerrar constantemente, entre otros, o con la oscilación de las masas que generan desbalances propios de las geometrías de los elementos, tales como en el caso del cigüeñal [8].

Las vibraciones generadas por el proceso de combustión suelen ser mayores que las que se dan por los elementos que se encuentran oscilando por el funcionamiento del motor, lo que representa un problema importante a la hora de realizar un análisis de falla por medio de vibraciones. Debido a esto, es necesario buscar aproximaciones que permitan bien sea separar o limpiar las señales que se puedan recabar en el proceso de medición. En el desarrollo de este proyecto, se presentará una alternativa en el procedimiento de muestreo para evitar la contaminación de la señal debido al ruido de la combustión.

2.2. Análisis de falla por medio de vibraciones mecánicas

Un sistema que se encuentra vibrando puede fallar debido a que la acción cíclica generada puede llevar componentes al punto de fatiga del material. Las vibraciones son también una causa común de desajustes, ruidos y desgastes en los componentes, y, aunque es algo imposible de evitar, es necesario tratar de mantenerlas dentro de unos límites que permitan el correcto funcionamiento del sistema, dado que su efecto tiende a incrementarse si no se toman medidas en el corto plazo [4].

El análisis de falla por medio de vibraciones mecánicas es un método que se usa principalmente para la detección de problemas o fallas en máquinas rotativas. Tiene la ventaja de que no interfiere con el funcionamiento normal de la máquina y de que permite determinar, en algunos casos, el nivel de gravedad del problema, lo que facilita la toma de decisiones relacionadas con el mantenimiento del equipo. Esto se logra a partir de la identificación de señales que indican cuando un elemento en particular está presentando patrones vibratorios irregulares, de acuerdo con estándares que se tienen del mismo equipo funcionando en condiciones normales, o, a interpretaciones que se hacen de la señal obtenida y su relación con los componentes que se encuentran rotando [9].

La medición se hace por medio de sensores y su uso depende de la frecuencia de la falla que se requiera analizar. Los sensores pueden ser de desplazamiento (vibrómetros /sensores de proximidad), los cuales son efectivos para la detección de fallas en bajas frecuencias (por debajo de los 10 Hz), transductores de velocidad cumplen a cabalidad con la detección cuando se trata de frecuencias intermedias (un rango entre 10 Hz- 1000 Hz) o acelerómetros, cuyo rango de trabajo es bastante amplio (usualmente entre 2 Hz y 10.000 Hz) [10].

Los acelerómetros son los sensores de mayor uso, debido al alto rango de frecuencias que se pueden analizar. Éstos, usualmente están hechos de un material piezoeléctrico, circonato de plomo, un tipo de cristal que, al sufrir una deformación, debido a los cambios en su estructura, genera una corriente eléctrica (Ilustración 3), la cual se envía a una tarjeta de adquisición de datos y de ahí a un computador, en donde se obtiene una relación de la aceleración con respecto al tiempo. Los acelerómetros pueden estar diseñados para

trabajar por esfuerzo cortante o por compresión, siendo la primera más común, debido a sus buenos resultados para usos generales, dejando la disposición a compresión para aplicaciones más específicas (por ejemplo, pruebas de choque e impacto) [11, 12].

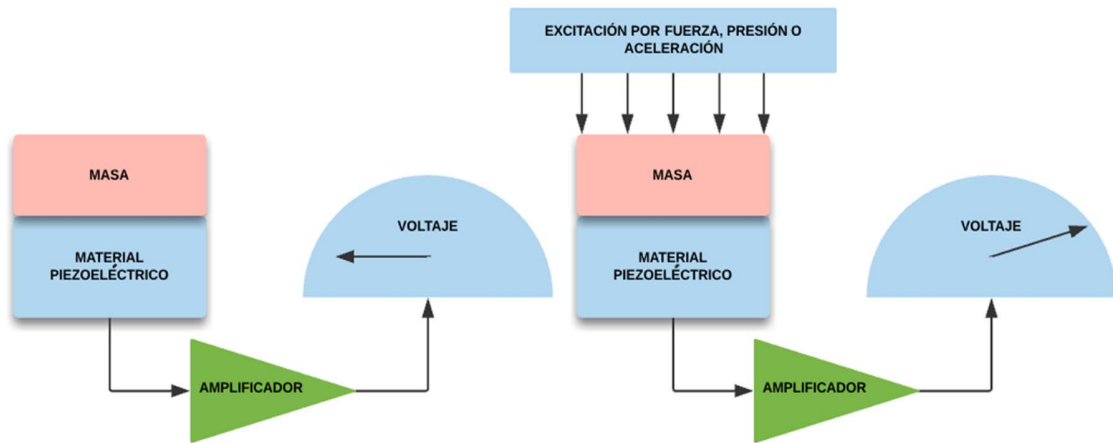


Ilustración 3. Esquema de funcionamiento de los sensores piezoeléctricos.

Los sistemas de adquisición de datos recaban una señal discreta, esto se debe a que guardan la información de la amplitud de la onda en determinados instantes. Con el fin de realizar una correcta reconstrucción de la señal, se debe determinar la frecuencia de muestreo de los sensores. Para este fin se usa el teorema de Nyquist, el cual indica que dicha frecuencia debe ser al menos el doble de la frecuencia máxima de interés [6]. Luego, esta información se procesa y se descompone a través de diversos algoritmos, usados para obtener valores característicos que permitan diferenciar e identificar a qué condiciones de funcionamiento pertenece cada señal. Los algoritmos más comúnmente usados para el procesamiento de la información, dependiendo de la naturaleza de la señal y las necesidades específicas en cuanto a carga computacional y tiempo de procesamiento, son la transformada discreta de Fourier (DFT), la transformada rápida de Fourier (FFT) y la transformada continua de Wavelet (CWT) [13]. Sin embargo, existen otros métodos de análisis propuestos para determinadas aplicaciones en busca de optimizar, sobre todo, la carga computacional.

2.3. Análisis de falla por medio de señales de presión en la admisión.

Como se mencionó anteriormente, el motor tiene un sensor MAP (*Manifold Absolute Pressure*) ubicado en la admisión de aire el cual es uno de los principales encargados de recabar la información necesaria para determinar la cantidad de combustible a inyectar para el proceso de combustión. Este sensor, es de tipo piezoeléctrico, y toma principalmente la señal de presión que muestra los cambios en el nivel de vacío generado en el múltiple de admisión, permitiendo estimar la densidad del aire y junto con el MAF

(medidor de flujo de aire) pueden estimar el combustible requerido para obtener un dosado adecuado.

Antes de iniciar el proceso de combustión, mientras el motor de arranque acciona el cigüeñal, es posible considerar un régimen de giro estable debido a la naturaleza del movimiento. Teniendo esto en cuenta, se puede verificar a través de un sensor si existen cambios en el vacío generado en el proceso de admisión antes de iniciar el proceso de combustión. Estos cambios registrados pueden deberse a diferentes motivos, tales como fugas en mangueras o empaques en la admisión, un mal asentamiento de válvulas, etc.

Debido a lo anterior, cabe la posibilidad de detectar fallos en algunos de estos elementos que hacen parte del sistema de admisión de aire para el proceso de combustión.

En teoría, si las válvulas de admisión están presentando el funcionamiento adecuado, el sensor MAP, obtendrá una señal de presión de vacío dentro de los límites esperados. Si la señal presenta un comportamiento fuera de parámetros, es un claro indicio de problemas en el motor. Es importante entender que el problema puede presentarse en el sensor, pero de no ser así, después de verificar la buena condición de éste, es posible usar esta información para realizar un diagnóstico de la condición de algunos componentes del motor.

2.4. Señales, filtrado y procesamiento

Existen en la actualidad, diversos métodos para recabar información correspondiente al estado o la condición de las máquinas rotativas, entre éstas, de los motores. El uso de sensores de diferentes tipos permite la extracción de señales que se pueden usar para determinar sus características de operación. En el caso particular de la señal vibratoria obtenida a través del uso de acelerómetros ubicados en el bloque de un motor de combustión interna, ésta, viene acompañada de una cantidad importante de ruido, y señales de diversas fuentes, por lo que no se puede hacer una lectura directa, a partir de la señal cruda obtenida.

La extracción de las características es un componente crítico en la efectividad de este tipo de análisis. Cuando una señal se encuentra contaminada por ruido, está puede estar desajustada para el diagnóstico, por lo que se pueden generar lecturas o interpretaciones erróneas. Existen entonces, diversos métodos o técnicas, usados para extraer estas características vibratorias o firmas, sin los cuales, éstas podrían pasar inadvertidas.

2.4.1. Características en el dominio del tiempo

Las técnicas basadas en el dominio de tiempo usan señales crudas, señales filtradas, estocásticas y métodos basados en modelos. Sin embargo, estas son limitadas para la detección de fallas tempranas.

A pesar de esto, existen algunas características generales de las señales, dadas en el dominio del tiempo, que se pueden usar para detectar algunos tipos de fallas. Para entenderlas se deben conocer algunos conceptos relacionados (ver Ilustración 4).




Ilustración 4. Valores RMS y Peak. Tomado de: <https://www.electronics-lab.com/article/average-rms-voltage/>

A continuación, se presentan estas características en el dominio del tiempo, sus ventajas y desventajas, así como los momentos estadísticos de las señales. Ver Tabla 2.

Características	Fórmula	Descripción	Ventaja	Desventaja
Valor RMS	$\sqrt{\frac{1}{T} \int_0^T x^2(t) dt}$	Se refiere al valor efectivo de la intensidad de una onda, en el caso de este tipo de análisis, es una forma de medir el contenido de energía de la vibración.	Buena herramienta para detectar desbalanceos.	No resulta efectivo si se pretende realizar la detección temprana de fallas.
Valor Peak	$\max(x(t))$	Es el valor máximo de amplitud que toma una onda con referencia al "0".	Permite identificar cual es el valor extremo al que alcanza a llegar la señal vibratoria.	Por si solo, el valor Peak no permite hacer la identificación de una falla.
Peak to Peak	$\max(x(t)) - \min(x(t))$	Es la diferencia entre el valor Peak positivo y el valor Peak negativo	Nos sirve para identificar la magnitud real de la vibración.	Por si solo, el valor Peak to Peak no permite hacer la identificación de una falla.
Crest Factor (CF)	$\frac{\text{Peak to Peak}}{\text{RMS}}$	Es un factor, que al relacionar el valor peak to peak con el valor RMS, da una idea de la forma de la onda.	Es un buen indicador de fallos en puntos localizados, como la rotura de un diente o en la pista externa de un rodamiento.	Es susceptible a los cambios en carga o velocidad, así que por si solo, puede dar falsas alarmas.

Momentos estadísticos				
Media	$M1 = \sum_{i=1}^n x_i$	Se refiere al valor promedio de la señal.	Los momentos estadísticos permiten determinar la presencia de problemas debido a las desviaciones que se presentan respecto a la media.	Por si solos, los momentos estadísticos tienen limitaciones para detección temprana de fallos.
Varianza	$M2 = \frac{\sum_{i=1}^n (M1 - x_i)^2}{n}$	es una medida que indica la media de los cuadrados de las desviaciones de la señal con respecto a su media.		
Skewness	$M3 = \frac{\frac{\sum_{i=1}^n (M1 - x_i)^3}{n}}{\left[\frac{\sum_{i=1}^n (M1 - x_i)^2}{n-1} \right]^{3/2}}$	Es una representación de la asimetría de la señal, indica si existen valores atípicos en la distribución de los datos.		
Kurtosis	$M4 = \frac{\frac{\sum_{i=1}^n (M1 - x_i)^4}{n}}{\left[\frac{\sum_{i=1}^n (M1 - x_i)^2}{n-1} \right]^2} - 3$	Es una característica de la señal que indica qué tan concentrados están los datos respecto a una medida central, lo que permite tener una idea de su distribución.		

Tabla 2. Características en el dominio del tiempo y momentos estadísticos de las señales

2.4.2. Características en el dominio de la frecuencia

Las técnicas basadas en el dominio de frecuencia son, por lo general, más efectivas para la detección de fallas.

- **Trasformada de Fourier (FT):** se refiere a una serie de operaciones matemáticas usadas para pasar una señal en el dominio de tiempo al dominio de frecuencia, o viceversa. Estas operaciones descomponen la señal obtenida en una serie de señales sinusoidales con frecuencias, amplitudes y fases específicas, e identifican la contribución de cada frecuencia en la señal original.

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi f t} dt$$

La FT se usa frecuentemente en el análisis de señales estacionarias. Sin embargo, si la señal es no estacionaria, se deben usar otras técnicas para obtener resultados adecuados. Se debe tener en cuenta que la FT requiere el cálculo de integrales que asumen la continuidad de la señal en todo instante de tiempo.

- **Transformada Discreta de Fourier (DFT):** En la práctica, es más común encontrarse con señales discretas, no continuas. La DFT es una técnica usada para el análisis de señales discretas, esto se debe a que los datos adquiridos por los sistemas de adquisición son tomados de capturas realizadas en un tiempo limitado y tienen pequeños baches.

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-\frac{j2\pi(k)(n)}{N}}$$

Donde:

N= Número de muestras

n= Enésima muestra original

k= k-ésimo término de la DFT

El procedimiento matemático implica la suma compleja de una serie de multiplicaciones complejas. En programación, se trata de un algoritmo no muy difícil de implementar. Sin embargo, la cantidad de operaciones requeridas puede llegar a ser tan grande que exija bastante tiempo y recursos computacionales [14].

- **Transformada rápida de Fourier (FFT):** Se trata de un algoritmo computacional desarrollado para calcular de manera más eficiente la DFT, ya que disminuye la cantidad de multiplicaciones y adiciones requeridas para desarrollar dicha transformación, logrando así que la carga computacional y por ende, el tiempo de procesamiento sea mucho menor que el requerido por otros algoritmos [15].

Autores como Jafarian, *et al*, proponen el uso de FFT para la extracción de las características vibratorias de las señales discretas.

En el caso de señales vibratorias no lineales, o de los sistemas dinámicamente variantes en el tiempo, se habla de señales no estacionarias, y para su análisis es necesario el uso de métodos donde se emplee el dominio de tiempo-frecuencia para el diagnóstico de fallas. Éstas técnicas han sido estudiadas para el análisis por vibraciones en aplicaciones específicas [2].

- **Transformada de Gabor:** La transformada de Gabor utiliza ventanas Gaussianas moduladas por una onda sinusoidal, esto permite realizar análisis tiempo-frecuencia para señales no estacionarias. Debido a que la ventana es de longitud fija, tiene una resolución en tiempo-frecuencia constante.
- **Transformada de Wavelet (WT):** Es un método de análisis en dominio del tiempo y de la frecuencia, a diferencia de la transformada de Fourier, que maneja señales sinusoidales, la transformada Wavelet representa las señales en escalas y tiempos, con una representación multiresolución de la señal. La ventaja de la transformada de Wavelet, es que se descompone la señal en ventanas variables, amplias para escalas altas (bajas frecuencias equivalentes), y estrechas para escalas bajas (altas frecuencias equivalentes), lo que mejora la resolución de ésta, de tal manera que se puede llevar a cabo un análisis en el dominio de tiempo-frecuencia.

La transformada de Wavelet puede descomponer una señal en varias bandas mediante el uso de las adaptaciones escaladas y desplazadas de la wavelet madre,

sin que éstas traslapen entre sí, las cuales, descompuestas, contienen toda la información de frecuencia de la señal original [16].

- **Transformada Continua de Wavelet (CWT):** Este método genera una serie de funciones a diferente escala (similar a una frecuencia equivalente) para abarcar las señales transitorias en diferentes intervalos de tiempo. Sin embargo, requiere una gran carga de tiempo computacional. En este proceso se compara la señal con versiones escaladas o desplazadas de una wavelet. El resultado de esta comparación es una función de dos variables, que puede ser de escala y valor complejo o de escala y valor real.
- **Transformada Discreta de Wavelet (DWT):** Esta contiene una transformada continua y una discreta de Wavelet. Para ésta, la señal se pasa por dos filtros digitales, el primero para tomar las características de alta frecuencia de la señal original (D_j) y el segundo para tomar las características de baja frecuencia (A_j). Luego de hacer el filtrado inicial, se repite el proceso con las señales resultantes una y otra vez, hasta hallar la condición final requerida [17, 18].

2.4.3. Métodos de filtrado de señales

Muchas veces las señales vibratorias obtenidas por los sensores vienen acompañadas de ruido debido a factores imposibles de evitar, dado que su fuente hace parte del proceso de funcionamiento normal del equipo. Entiéndase como ruido, cualquier perturbación en la señal que tenga una fuente diferente a la de interés, como es el caso de las señales vibratorias que se generan por el proceso de combustión, las cuales pueden interferir con el proceso de diagnóstico.

Existen algunos métodos para limpiar las señales, pero se deben usar con cautela, debido a que en el proceso se debe descomponer y recomponer la señal inicial luego de ser filtrada, lo cual puede llevar a la pérdida de información importante de la señal.

Existen filtros análogos y digitales, los cuales tienen la función, regularmente, de dejar pasar algunas bandas de frecuencia, bien sea de alta, de baja, una de un valor específico o todas excepto una particular.

Con el ánimo de dar una idea general al lector, se podría imaginar que se tiene una señal en función del tiempo, la cual se grafica con fracciones de segundo en las abscisas y valores de una variable como aceleración o presión en el eje de las ordenadas, obteniendo una imagen similar a la Ilustración 5.




Ilustración 5. Señal de un acelerómetro en el dominio del tiempo

Como se explicó previamente, la transformada de Fourier es un algoritmo matemático para convertir una señal que se encuentra en función del tiempo en una señal en función de la frecuencia. Al aplicar el algoritmo obtendríamos algo como lo que se aprecia en la Ilustración 6, en donde podemos observar que en el eje de las abscisas se encuentran valores de frecuencia y en el eje de las ordenadas un valor referente al peso de esa frecuencia.




Ilustración 6. Señal transformada en el dominio de la frecuencia.

Ahora bien, imagine que se tiene una señal de la misma longitud con un valor siempre de "1" en el eje de la abscisa en un intervalo específico de frecuencia y un valor de 0 en todo lo demás. Si se realiza el producto punto entre las dos señales, lo que se obtiene es una señal que muestra únicamente las características que se encuentran en el intervalo cuyo valor era igual a 1 en la señal creada, dado que todos los demás puntos se convierten en

“0”, por lo que podríamos obtener un acercamiento específico a lo que sucede en ese intervalo de frecuencia (Ilustración 7).




Ilustración 7. Señal en el dominio de la frecuencia filtrada.

Generalmente, programas como Matlab® tienen implementaciones sencillas para el filtrado de señales.

Los parámetros que se usan para éstas son:

x: esta será la señal que se desea filtrar.

fpass: se refiere a la frecuencia de corte del filtro que se quiere aplicar.

fs: Es la frecuencia de muestreo de la señal que se desea filtrar.

Filtro pasa baja: Se trata de un tipo de filtro que atenúa todas las señales que estén por encima de un valor predeterminado, haciendo que se pueda enfocar el análisis a señales de frecuencias por debajo de este valor.

Implementación:

```
y = lowpass(x, fpass, fs);
```

Filtro pasa alta: En este caso, el valor establecido se convierte en el límite inferior de interés, debido a esto, la atenuación se presentará en los valores que estén por debajo del límite, dejando pasar solo las frecuencias que encuentren por encima de esta frecuencia de interés.

Implementación:

```
y = highpass(x, fpass, fs);
```

Filtro pasa banda: Un filtro pasa banda es aquel en el que se establecen un límite inferior y un límite superior. La finalidad es atenuar la señal en las frecuencias por debajo del límite

inferior y por encima del superior, dejando únicamente una banda de frecuencias de interés intactas.

Implementación:

```
y = bandpass(x, [fpass1, fpass2], fs);
```

Wavelet denoising: Es un proceso basado en el uso de la transformada de Wavelet para eliminar el ruido de la señal obtenida. Consta de los siguientes pasos:

1. Se descompone la señal a través de DWT.
2. Se selecciona un umbral para cada nivel de descomposición y se aplica a cada coeficiente de D_j para remover el ruido concentrado en las altas frecuencias.
3. Se reconstruye la señal por medio de Wavelet, por cada nivel de descomposición, se reconstruyen los coeficientes de baja frecuencia y de alta frecuencia luego de extraer las señales que causan el ruido, teniendo en cuenta los umbrales determinados.

El método de modo de descomposición empírica (EMD): Es un algoritmo intuitivo, y un método adaptativo para descomponer señales en una serie de componentes estrechos de alta a baja frecuencia. Este proceso no necesita conocer de antemano las características de la señal. El papel fundamental de este método es la identificación empírica de los modos oscilatorios intrínsecos en una señal, a partir de sus características de escalas de tiempo, y descomponer la señal en funciones de modo intrínseco (IMF's). Para los valores reales de $x(t)$, un EMD estándar obtiene una serie de IMFs distribuidas de manera simétrica por encima y por debajo, en las cuales el número de cruces en 0 y el número de extremos difiere en un máximo de 1. Para extraer los IMFs, se realiza un proceso iterativo (cribado) de la siguiente forma:

1. Se identifican todos los extremos locales de $x(t)$
2. Se conectan los máximos locales a través de una línea (polilínea) de tendencia cúbica para obtener la envolvente superior $u(t)$ y se hace el mismo procedimiento con los mínimos locales para obtener la envolvente inferior $v(t)$ y se obtiene el valor promedio.

$$m_1(t) = [u(t) + v(t)]/2$$

3. Se resta este promedio ($m_1(t)$) de $x(t)$ para obtener el "modo oscilatorio" h_1
4. Si h_1 satisface las condiciones requeridas, se define $c_1(t) = h_1(t)$ como el primer IMF, de lo contrario, se reemplaza $x(t)$ por $h_1(t)$ y se repite el proceso desde el principio.

Este proceso se hace de manera iterativa al residuo, $r = x(t) - c_1$, para extraer otros IMFs.

Luego de aplicar *Wavelet denoising*, y tras realizar un procedimiento de descomposición empírica como el descrito anteriormente, Fengrong Bi, *et al.* encuentran que se puede limpiar la señal, identificando claramente los componentes determinados en la

experimentación, en este caso particular, características relacionadas con el knocking (autodetonación del combustible) [16].

2.5. Diagnóstico

Para realizar el diagnóstico de algunos tipos de falla en un MCI a partir de las señales de vibración y de presión en la admisión, existen algunos parámetros estandarizados que pueden ser de utilidad. Algunos de estos se presentan en la Tabla 3.

A partir de las perturbaciones observadas en las señales, se pueden determinar entonces algunas fallas. Sin embargo, es importante tener en cuenta que se requiere un conocimiento previo del sistema para hacer una lectura más precisa, por lo que lo más conveniente es realizar mediciones periódicas que permitan tener un histórico de funcionamiento del sistema, esto con el fin de detectar anomalías o patrones que puedan dar indicio de alguno de estos tipos de falla.

<i>Falla</i>	<i>Efecto</i>	<i>Posibles causas</i>	<i>Señal vibratoria</i>	<i>Señal de presión en la admisión</i>
Desajuste de válvulas	<i>Cae la presión en la cámara, disminuye la potencia del motor debido a que no se logra un buen dosado y por ende, la combustión no aprovecha al máximo la energía del combustible. En casos graves, el motor no encenderá.</i>	<i>El desajuste de las válvulas puede ser causado por desgastes en el asiento o en la misma válvula. Una respuesta similar se da si existe una grieta en su área de apoyo.</i>	<i>Temporales: Los valores característicos extraídos de las señales temporales, tales como RMS, valor pico, amplitud, etc., presentarán cambios en relación con el nivel de daño. Frecuencia: Se verá afectada la frecuencia 1X y armónicos 2X y 3X</i>	<i>Temporales: Los valores característicos extraídos de las señales temporales, tales como RMS, valor pico, amplitud, etc., presentarán cambios con relación al nivel de daño. Frecuencia: Se ve afectada la magnitud de la frecuencia.</i>
Holgura del pistón	<i>Cae la presión, disminuye la potencia del motor debido a que no se aprovecha al máximo la energía del combustible.</i>	<i>La holgura se puede dar por el desgaste en el anillo o en la camisa del pistón causados por una lubricación deficiente, o por el proceso natural de erosión, debido a que son superficies que trabajan bajo altas cargas de fricción.</i>	<i>Temporales: Los valores característicos extraídos de las señales temporales, tales como RMS, valor pico, amplitud, etc., presentarán cambios en relación con el nivel de daño. Frecuencia: Se verá afectada la frecuencia 1X y armónicos 2X y 3X</i>	<i>Temporales: El fenómeno ocurre en un espacio aislado del sensor, sin embargo se presenta una pequeña caída en la señal. Frecuencia: El fenómeno ocurre en un espacio aislado del sensor, sin embargo, la magnitud es un poco menor debido a que el vacío que se genera está por debajo del rango normal.</i>

<i>Falla</i>	<i>Efecto</i>	<i>Posibles causas</i>	<i>Señal vibratoria</i>	<i>Señal de presión en la admisión</i>
Desbalanceo	<i>Se mantiene la potencia del motor, se incrementan las vibraciones.</i>	<i>Problemas de montajes o desgastes en los puntos de apoyo del eje que rota.</i>	<i>Temporales: Los valores característicos extraídos de las señales temporales, tales como RMS, valor pico, amplitud, etc., presentarán cambios en relación con el nivel de desbalanceo. Frecuencia: Se verá afectada la frecuencia 1X.</i>	<i>Temporales: No tiene efecto sobre la señal de presión en la admisión. Frecuencia: No tiene efecto sobre la señal de presión.</i>
Desalineamiento	<i>Se mantiene Se mantiene la potencia del motor, se incrementan las vibraciones.</i>	<i>Problemas de fabricación, montaje, averías o desgastes desiguales por funcionamiento.</i>	<i>Temporales: Los valores característicos extraídos de las señales temporales, tales como RMS, valor pico, amplitud, etc., presentarán cambios en relación con el nivel de desalineamiento. Frecuencia: Se verán afectadas la frecuencia 1X y sus armónicos en 2X y 3X</i>	<i>Temporales: No tiene efecto sobre la señal de presión en la admisión. Frecuencia: No tiene efecto sobre la señal de presión.</i>

Tabla 3. Tipos de fallas y características espectrales para el diagnóstico.

2.6. OBD (On Board Diagnostics)

El OBD es un sistema de diagnóstico utilizado en la mayoría de los vehículos modernos, el cual funciona a partir de la integración de diversos sensores que envían señales a la ECU, la cual, en conjunto con el computador del vehículo, tiene la capacidad de detectar cuando algún componente o sistema está presentando algún tipo de fallo.

Cuando algún sensor detecta un comportamiento anormal, envía un código de alerta (DTC, *Diagnostic Trouble Code*) compuesto por una letra seguida de 4 o 5 números, el OBD se encarga de encender una señal de alerta en el tablero del vehículo, esto con el fin de informar que existe algún fallo en un sistema específico el cual deberá ser revisado en un taller.

El protocolo actual de códigos OBD II, está estructurado de la siguiente forma:

Letra:

- **P (Powertrain):** indica un problema en el tren de potencia del vehículo, esto quiere decir que la falla se encuentra en la transmisión automática o el motor.
- **B (Body):** Un DTC que inicie por la letra B, se usa para denominar un fallo en el cuerpo del vehículo, así que el problema se halla en la carrocería.
- **U:** La letra U se usa para indicar un problema del sistema de transmisión de datos del vehículo, lo que podría ser bastante grave debido a que un sistema entero podría desaparecer del sistema de diagnóstico.
- **C (Chassis):** Cuando el DTC inicia con esta letra, hace alusión al chasis, lo que podría indicar fallas relacionadas con la bolsa de aire, los frenos y o algún otro componente al chasis.

Primer número:

Este valor será "0" cuando se trate de un código universal, esto quiere decir que indica el mismo tipo de falla en cualquier vehículo. Si el número es "1", "2" o "3", el código es específico del fabricante del vehículo.

Segundo número:

Este número indica de forma específica donde se puede encontrar el error

- 1 o 2, medición de aire y combustible.
- 3, sistema de encendido.
- 4, control de emisiones adicional.
- 5, velocidad y regulación del ralentí.
- 6, ECU y señales de salida.
- 7 u 8, transmisión.
- 9, módulos de control y señales de entrada y salida por igual.

Tercer y cuarto números:

Estos números indican cual es el componente o sistema específicos del vehículo donde se podrá encontrar el fallo.

Códigos comunes y sus significados:

P0505: Problema en el sistema de control de ralentí.

P0562: Fallo relacionado con el sistema de voltaje de la batería del vehículo.

P0705: Problema con el interruptor de posición de la transmisión.

P0741: Fallo en el sistema de transmisión.

P0449: Problema en el sistema de control de emisiones EVAP.

P0507: Diferencia entre la velocidad esperada y la velocidad actual del motor.

P0443: Mal funcionamiento del circuito de la válvula de control de purga del sistema de control de emisiones evaporativas.

P0446: Problema en el sistema de ventilación EVAP.

P0500: Mal funcionamiento del sensor de velocidad.

P0401: Mal funcionamiento del flujo de recirculación de gases de escape.

Dentro de los códigos de falla, solo existen 2 que están relacionados con fallas de válvulas, sin embargo, se refieren a fallas en la válvula de recirculación de gases de escape (P0403 y P0405). Adicionalmente, los códigos relacionados con el sensor de presión en la admisión son:

- P0068: MAP/MAF - Throttle Position Correlation
- P0069: Manifold Absolute Pressure - Barometric Pressure Correlation
- P0105: MAP Circuit Malfunction
- P0106: MAP/Barometric Pressure Circuit Range/Performance Problem
- P0107: Manifold Absolute Pressure/Barometric Pressure Circuit Low Input
- P0108: MAP Pressure Circuit High Input
- P0109: MAP / Baro Pressure Circuit Intermittent
- P1106: MAP/BARO Pressure Circuit Range/Performance Problem
- P1107: Barometric Pressure Sensor Circuit Low Voltage

Por lo tanto, actualmente no se diagnostican directamente los problemas mecánicos en las válvulas del motor.

Aunque en la actualidad, en los motores de combustión interna, normalmente se utilizan acelerómetros y sensores de presión en la admisión, no se encontraron trabajos que utilicen procesamiento de señales de esos dos tipos de señales para detección y clasificación de fallos referentes a mal asentamiento de válvulas de admisión o escape y problemas de soportes de motor. En este trabajo se presenta una metodología para detectar los fallos mencionados por medio del procesamiento de las señales de vibración y presión en la admisión utilizando clasificadores con redes neuronales. Este procesamiento podría servir para en un futuro ser implementado en las ECUs de los vehículos.

2.7. Redes Neuronales

Desde los inicios de la computación moderna, muchos visionarios soñaron con la creación de computadoras inteligentes, capaces de replicar los procesos llevados a cabo por el cerebro de manera automática y eficiente. En teoría, se podría crear un algoritmo de programación lo suficientemente largo y complejo como para replicar paso a paso el funcionamiento del cerebro humano. Sin embargo, lo virtualmente imposible de esta tarea, está en la memoria que debería usarse para almacenar dicho algoritmo y la capacidad descomunal de procesamiento que debería tener un equipo que intentara procesar tal cantidad de información, lo que hace de ésta, algo aún lejano. En Tabla 4 se puede ver un comparativo entre el funcionamiento del cerebro humano y un computador.

En la década de 1940 se presenta un primer acercamiento a un modelo computacional basado en el funcionamiento de una neurona, lo que luego se convertiría en la base para desarrollar el perceptrón, presentado en la década de 1950. El perceptrón es el tipo de neurona que abrió la puerta a los sistemas de redes neuronales artificiales. Sin embargo, poco tiempo después de su aparición y al encontrar algunos problemas en la implementación de este sistema debido a su saturación, la mirada giró a la búsqueda del desarrollo de la inteligencia artificial.

	Cerebro	Computador
Velocidad de proceso	10^{-2} seg. (100 Hz)	10^{-9} seg. (1000 MHz)
Estilo de procesamiento	Paralela	Secuencial
Número de procesadores	10^{11} - 10^{14}	Pocos
Conexiones por procesador	10.000	Pocas
Almacenamiento del conocimiento	Distribuido	Direcciones fijas
Tolerancia a fallos	Amplia	Nula
Tipo de control del proceso	Autoorganizado	Centralizado

Tabla 4. Paralelo entre el cerebro humano y un computador. [19]

Años más tarde, con el desarrollo del perceptrón multicapa, las reservas que se tenían acerca de este tipo de modelos se disiparon, por lo que se empezaron a desarrollar de manera más consistente, convirtiéndose en unos de los modelos de aprendizaje asistido más usados en la actualidad, dada su capacidad de resolver problemas complejos a partir de algoritmos sencillos y que no requieren una capacidad descomunal de procesamiento.

Las redes neuronales artificiales son un tipo de aprendizaje de máquina (*machine learning*) bioinspirado, las cuales tratan de imitar el funcionamiento de una red neuronal biológica.

La neurona natural funciona como un pequeño procesador, sencillo, lento y poco fiable (a diferencia de los microprocesadores modernos). Sin embargo, contamos con unas cien mil millones de ellas, trabajando en paralelo. Una sola neurona puede no parecer ser la gran maravilla, pero cientos de miles de ellas trabajando en equipo son capaces de procesar una cantidad enorme de información y de resolver problemas a partir de un complejo sistema de activaciones y desactivaciones, lo que les permite autoorganizarse, aprender y adaptarse al entorno [19].

A pesar de existir diferencias enormes entre las redes neuronales biológicas y las artificiales, hay 3 principios fundamentales en su funcionamiento que son similares para ambos sistemas:

- Ambas tienen una unidad básica sencilla, capaz de llevar a cabo tareas simples.
- Usan varias de esas unidades básicas en paralelo para poder resolver problemas más complejos.
- Ambas involucran elementos no lineales, lo que le da mayor capacidad de modelamiento al sistema.

Cuando se habla de la neurona natural, ésta recibe información de las dendritas y la comunica a otras neuronas a través de los axones, además, dependiendo del tipo de estímulo recibido, esta toma la decisión de activarse o no.




Ilustración 8. modelo de neurona natural. Tomado de: <https://commons.wikimedia.org/wiki/File:Neuron.svg>

En un sistema neuronal biológico, entonces, las neuronas se agrupan en conjuntos de capas que tienen funcionalidad propia. La agrupación de varios de estos conjuntos es lo que compone un sistema global. Para emular esto, en los sistemas neuronales artificiales, se genera una estructura jerárquica parecida. La unidad base será la neurona artificial, el conjunto de estas se organiza por capas y varias de estas constituyen el sistema de red neuronal artificial. Este sistema, unido a las interfaces de entrada y salida, son entonces el sistema global del proceso.

El sistema neuronal artificial está compuesto por los siguientes elementos:

- Un conjunto de neuronas artificiales
- Un patrón de conectividad o arquitectura
- Una dinámica de activaciones
- Una regla de aprendizaje
- Un entorno de operación

En el caso del aprendizaje profundo (*Deep learning*), se han descrito las redes neuronales artificiales como un conjunto de técnicas de regresión paralela, no lineales, de varias capas, usadas para el procesamiento de señales, su agrupación y predicción [20]. Yendo más a fondo, las aplicaciones actuales de las redes neuronales se enfocan en la aproximación de funciones, la asociación de patrones, la agrupación, categorización y conceptualización de datos, el aprendizaje de parámetros estadísticos, y la extracción de conocimiento a través del análisis de los pesos, entre otros.

Generalmente, las redes neuronales artificiales se definen según los siguientes parámetros:

1. Tipo de neurona
2. Arquitectura: Se refiere a la organización de las conexiones entre las diferentes neuronas.
3. Algoritmo de aprendizaje: Por medio del cual se capacita a la red con ejemplos y se insertan las condiciones a la estructura.
4. Algoritmo de recuperación: Este se usa para enviar nuevos datos a la red previamente entrenada y calcular los resultados.

Las redes neuronales artificiales tradicionales han demostrado poseer una buena capacidad para extraer información no lineal de los datos, por lo que son una buena opción para su uso en las series de tiempo. Sin embargo, en los últimos años, se ha probado el uso de redes neuronales convolucionales, usualmente utilizadas para tareas como identificación facial y clasificación de audio, con excelentes resultados en la clasificación de series de tiempo.

2.7.1. Modelo de neurona artificial:

- **Variables de entrada:** Las variables de entrada de una red neuronal se agrupan en la capa de entrada, y están definidas como los datos que se ingresan a la red para ser procesados. Cada unidad representa un campo diferente en la capa de entrada.
- **Regla de propagación:** En una red neuronal artificial, la regla de propagación es la que permite determinar el valor del potencial postsináptico de la neurona, lo que afectará posteriormente la activación de las neuronas en la siguiente capa. Existen varias reglas de activación:

Lineal: consiste en una suma sopesada de las entradas. Básicamente, es el producto escalar de los vectores de entrada y los pesos. Si existe una buena relación lineal entre las variables dependientes e independientes, los resultados de la red neuronal tenderán a asemejarse a los de una regresión lineal.

Distancia euclídea: Este método trata de minimizar la distancia entre los vectores de entrada y los pesos sinápticos, lo que hace es calcular esta distancia como la raíz cuadrada de la suma de las diferencias al cuadrado entre cada dimensión de dos puntos. Es de uso común en las redes no supervisadas para ajustar el valor postsináptico.

Retropropagación: Es un método de entrenamiento de la red neuronal que luego de realizar el proceso dentro de las capas ocultas y arrojar un valor a la salida, calcula cuanto se desvían los valores obtenidos por la red del valor deseado y usa esta información para recalcular los pesos dentro de la o las capas ocultas. Es un modelo que disminuye la tasa de error y aumenta la fiabilidad.

- **Función de activación:** Esta función es la encargada de determinar el estado de activación de la neurona actual, esto a partir del potencial postsináptico y del estado de activación anterior. Este tipo de funciones introducen la no linealidad a las salidas de la red neuronal, lo que es similar al accionar de las neuronas naturales.

Existen funciones de activación de diversos tipos, como se puede observar en la Tabla 5, las más usadas son:

Función Escalón: Esta es una función de activación que se basa en umbrales. Si la entrada es cero o mayor, devuelve 1, de lo contrario, devuelve 0. No es diferenciable y su uso es poco frecuente.

Función sigmoideal: Es una función con forma de S que puede darle a cualquier entrada a un valor entre 0 y 1. Es diferenciable y se utiliza a menudo en la capa de salida de problemas de clasificación binaria.

Función tangente hiperbólica: Esta función es similar a la función sigmoideal, pero a cualquier entrada le arroja un valor entre -1 y 1. Es diferenciable y se utiliza comúnmente en la capa de salida de problemas de regresión.

Unidad Lineal Rectificada (ReLU): Esta es una función que es lineal para valores positivos y devuelve 0 para valores negativos. Aunque no es lineal, se utiliza a menudo en las capas ocultas de las redes neuronales profundas.

Función Softmax: Es un tipo de función sigmoideal usada para solucionar problemas de clasificación. Esta comprime las salidas para cada clase a valores entre 0 y 1. Es comúnmente usada en la capa de salida para calcular las probabilidades de pertenencia a cada una de las clases.

- **Función de salida:** Esta función entrega como resultado la salida global de la neurona en función de su estado de activación. Básicamente, la señal que sale

debe pasar por una función que determina cuando pasa un umbral, lo que activará el nodo que permite el paso a la siguiente capa [19, 21].

Name	Plot	Equation	Derivative (with respect to x)	Range
Identity		$f(x) = x$	$f'(x) = 1$	$(-\infty, \infty)$
Binary step		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x \neq 0 \\ ? & \text{for } x = 0 \end{cases}$	$\{0, 1\}$
Logistic (a.k.a. Sigmoid or Soft step)		$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$ ^[1]	$f'(x) = f(x)(1 - f(x))$	$(0, 1)$
TanH		$f(x) = \tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$	$f'(x) = 1 - f(x)^2$	$(-1, 1)$
ArcTan		$f(x) = \tan^{-1}(x)$	$f'(x) = \frac{1}{x^2 + 1}$	$(-\frac{\pi}{2}, \frac{\pi}{2})$
ElliotSig ^[9] I10 ^[11] Softsign ^[12] I13		$f(x) = \frac{x}{1 + x }$	$f'(x) = \frac{1}{(1 + x)^2}$	$(-1, 1)$
Inverse square root unit (ISRU) ^[14]		$f(x) = \frac{x}{\sqrt{1 + \alpha x^2}}$	$f'(x) = \left(\frac{1}{\sqrt{1 + \alpha x^2}}\right)^3$	$(-\frac{1}{\sqrt{\alpha}}, \frac{1}{\sqrt{\alpha}})$
Inverse square root linear unit (ISRLU) ^[14]		$f(x) = \begin{cases} \frac{x}{\sqrt{1 + \alpha x^2}} & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} \left(\frac{1}{\sqrt{1 + \alpha x^2}}\right)^3 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$(-\frac{1}{\sqrt{\alpha}}, \infty)$
Square Nonlinearity (SQNL) ^[11]		$f(x) = \begin{cases} 1 & : x > 2.0 \\ x - \frac{x^2}{4} & : 0 \leq x \leq 2.0 \\ x + \frac{x^2}{4} & : -2.0 \leq x < 0 \\ -1 & : x < -2.0 \end{cases}$	$f'(x) = 1 \mp \frac{x}{2}$	$(-1, 1)$
Rectified linear unit (ReLU) ^[15]		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$[0, \infty)$
Bipolar rectified linear unit (BReLU) ^[16]		$f(x_i) = \begin{cases} ReLU(x_i) & \text{if } i \bmod 2 = 0 \\ -ReLU(-x_i) & \text{if } i \bmod 2 \neq 0 \end{cases}$	$f'(x_i) = \begin{cases} ReLU'(x_i) & \text{if } i \bmod 2 = 0 \\ -ReLU'(-x_i) & \text{if } i \bmod 2 \neq 0 \end{cases}$	$(-\infty, \infty)$
Leaky rectified linear unit (Leaky ReLU) ^[17]		$f(x) = \begin{cases} 0.01x & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0.01 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$(-\infty, \infty)$
Parametric rectified linear unit (PReLU) ^[18]		$f(\alpha, x) = \begin{cases} \alpha x & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(\alpha, x) = \begin{cases} \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$(-\infty, \infty)$ ^[2]
Randomized leaky rectified linear unit (RReLU) ^[19]		$f(\alpha, x) = \begin{cases} \alpha x & \text{for } x < 0^{[3]} \\ x & \text{for } x \geq 0 \end{cases}$	$f'(\alpha, x) = \begin{cases} \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$(-\infty, \infty)$
Exponential linear unit (ELU) ^[20]		$f(\alpha, x) = \begin{cases} \alpha(e^x - 1) & \text{for } x \leq 0 \\ x & \text{for } x > 0 \end{cases}$	$f'(\alpha, x) = \begin{cases} f(\alpha, x) + \alpha & \text{for } x \leq 0 \\ 1 & \text{for } x > 0 \end{cases}$	知乎 @龙鹏

Tabla 5. Funciones de activación. Tomado de: v2-d095e383b41a74b1f195decf5135b38f_r.jpg (1080x1210) (zhimg.com)

2.7.2. Perceptrón simple:

Para emular los tres principios fundamentales de funcionamiento (Unidades básicas, trabajo en paralelo y uso de elementos no lineales), en *Deep learning* se hace uso de un algoritmo conocido como el perceptrón. Este modelo fue presentado por Rosenblatt a

finales de los años 50. Éste, está inspirado en las primeras etapas del procesamiento sensorial de los animales, en donde la información va pasando por diferentes capas que van realizando procesamientos cada vez más complejos. Este modelo solo consta de dos capas, una sensorial o de entradas (Inputs) , que harían el papel de las dendritas, y una de salida (Output) que, a su vez, cumpliría la funcionalidad del axón. En el interior del perceptrón, cada una de las entradas tiene asignado un peso (Weight), y la operación que se realiza al interior, es lo que denominamos una suma sopesada de las entradas, la cual, pasa luego por una función de activación de tipo escalón, que arroja un valor de 1 o 0 dependiendo del resultado de esta suma [22].

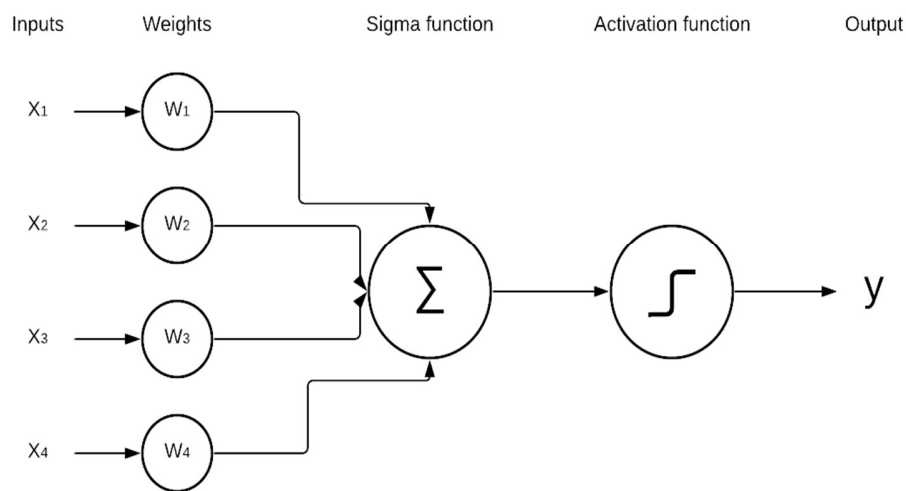


Ilustración 9. Perceptrón simple.

El modelo de perceptrón simple, dado que tiene un tipo de salida binaria, está diseñado para cumplir las funciones de clasificador o para la representación de funciones booleanas. El perceptrón simple, es importante históricamente debido a su capacidad de entrenamiento, esto debido a que el algoritmo de aprendizaje permite realizar el cálculo automático de los pesos sinápticos que sirven para realizar la clasificación a partir de ejemplos dados.

El perceptrón simple presenta una limitación importante debido a que solo puede clasificar funciones linealmente separables. La solución a este problema se encontró en la introducción de las capas ocultas, sin embargo, no se contaba con un procedimiento que permitiera obtener los pesos para estas múltiples capas, lo que logró superarse años más tarde con el descubrimiento de un algoritmo llamado *BackPropagation* (BP).

Algoritmo de aprendizaje del perceptrón

El algoritmo de aprendizaje presentado por Rosenblatt hace que los pesos sinápticos se calculen de manera automática para la clasificación de un conjunto de patrones etiquetados. En esencia se trata de un algoritmo de corrección de errores, el cual se encarga

de ajustar los pesos al comparar las diferencias entre las salidas obtenidas y las deseadas en el proceso de entrenamiento de la red.

Este proceso se realiza a partir de iteraciones, partiendo de un valor al azar y ajustando los pesos con cada corrida, esto hasta que los valores obtenidos concuerden con los deseados.

2.7.3. Perceptrón multicapa

Como se mencionó anteriormente, la solución a las limitaciones presentadas por el algoritmo de perceptrón simple se encontró en la inclusión de capas ocultas, esto se conoce como un perceptrón multicapa o MLP (Multi-Layer Perceptron). El MLP es un algoritmo que suele entrenarse haciendo uso de BP o de alguna de sus variantes. Es común que a este conjunto de arquitectura MLP con algoritmo de entrenamiento BP, sea denominado red de retropropagación o Red BP.

Desde los años 80 y con los avances de hardware y de poder de procesamiento en el campo la computación, la aplicación de las redes MLP se convirtió en una tarea relativamente sencilla para los computadores y se pudo demostrar, experimentalmente, su capacidad de representar mapeos complejos y de abordar problemas de clasificación de proporciones enormes, con lo que se hizo evidente su potencial de aplicación para la resolución de tareas complejas de una forma eficaz y simple.




Ilustración 10. Esquema de MLP

2.7.4. Redes neuronales convolucionales

Estas, toman su nombre de una operación matricial llamada convolución, y son usadas para el tratamiento de imágenes. La convolución consiste en la aplicación de un filtro en los campos receptivos de la matriz, cuyo efecto es la creación un mapa de características [3].

Un buen punto de partida consiste en la representación de una imagen en computación. Una imagen es una matriz de píxeles, codificados de acuerdo con su nivel de opacidad, bidimensional si se trata de una imagen a blanco y negro, y tridimensional si es una imagen a color (RGB – Rojo, verde y azul).

Para el proceso de filtrado se usa una matriz conocida como kernel, usualmente de 3x3, la cual se multiplica término a término con los elementos de una subregión del mismo tamaño, luego, se suman estos valores y pasan a ocupar una casilla en una nueva matriz resultante, más pequeña que la original. Luego de este proceso, se desplaza 1 columna hacia la derecha de la subregión original, para tomar otra igual y operar de nuevo. Al llegar al final de la serie de filas, se desplaza una fila por debajo de la subregión original y se repite el procedimiento. Esto será así hasta operar todas las subregiones posibles en la matriz original.

Matriz de píxeles * Filtro

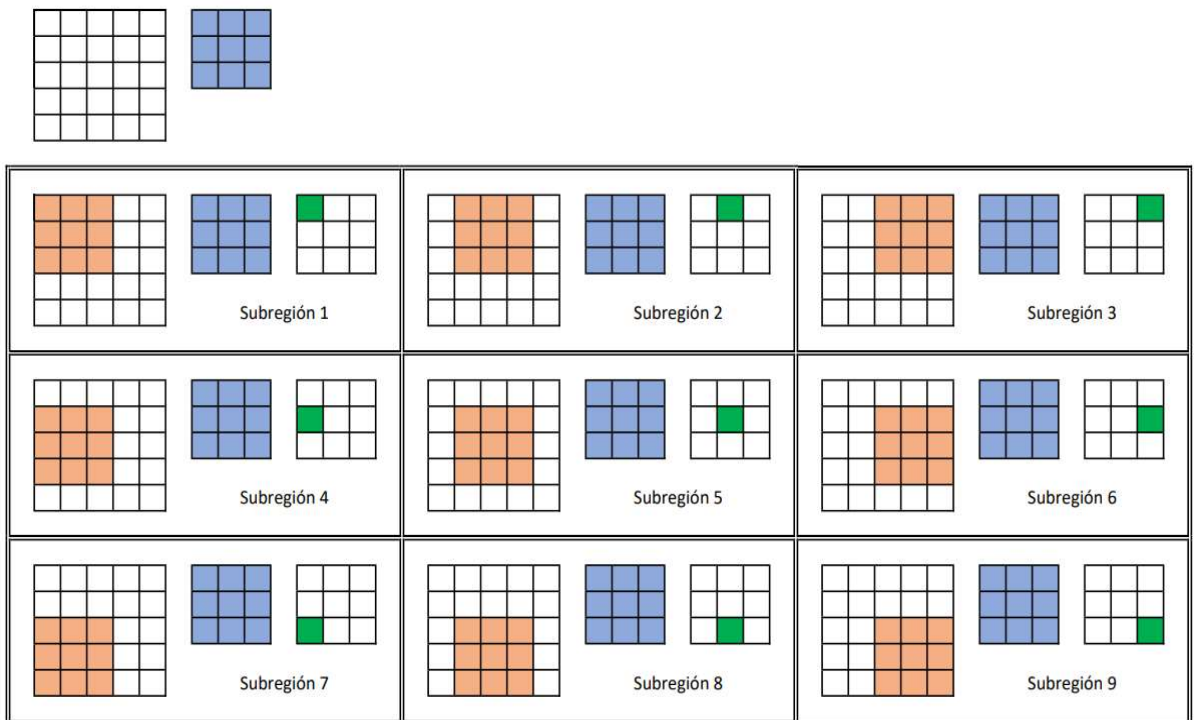


Ilustración 11. Proceso de convolución

Cada uno de los resultados de esta operación, indica el nivel de relación de la subregión analizada con el filtro aplicado.

En las primeras capas, los filtros aplicados permiten determinar líneas, contornos, formas, colores, etc. A medida que se va entrando en capas más profundas, se van aplicando nuevos filtros que permiten identificar patrones más específicos para determinar características particulares o complejas de las imágenes tratadas.

2.8. Análisis de varianza: ANOVA

El análisis de varianza se usa para evaluar el efecto estadísticamente significativo de los factores que hacen parte de un modelo. Esta técnica, realiza una separación de la variación total observada en cada una de las fuentes que contribuyen a la misma, determinando si esta se debe a los diferentes tratamientos o a los factores de error. Básicamente, se trata de determinar si los tratamientos que se le realizan a la variable medida generan un cambio mayor al error que puede haber en la medición, con esto, se puede inferir si es estadísticamente significativo o no.

El objetivo del análisis de varianza es probar la hipótesis de igualdad de los tratamientos con la media de la variable de respuesta que le corresponda. Esta hipótesis se conoce como H_0 . Si el planteamiento que se presenta en H_0 es verdadero, entendemos que no hay variación significativa en los datos. Si H_0 es falso, esta se rechaza y se acepta H_A , conocida como la hipótesis alternativa, lo cual indicaría que, si existen diferencias en los datos debido a los tratamientos, lo que hablaría de un efecto estadísticamente significativo. Las hipótesis de las que se habla se refieren a:

$$H_0: \tau_1 = \tau_2 = \dots = \tau_k = 0$$

$$H_A: \tau_i \neq 0 \text{ Para algún } i$$

Donde τ_i es un parámetro llamado el efecto del tratamiento. Ahora, para verificar cual de estas dos es aplicable al conjunto de datos, se realizan sumas de cuadrados de la siguiente forma:

$$SC_T = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{..})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}^2 - \frac{Y_{..}^2}{N}$$

Donde k representa el número de tratamientos, n_i , el número de observaciones, Y_{ij} es una variable aleatoria que se refiere a la observación ij -ésima y $\bar{Y}_{..}$ la variable aleatoria que representa la media de todas estas observaciones. $N = kn_i$

Luego de sumar y restar dentro del paréntesis la media del tratamiento y desarrollando el cuadrado, la suma cuadrada total (SC_T), que me indica la variación total de los datos, se puede presentar en 2 componentes de la siguiente forma:

$$SC_T = \sum_{i=1}^k n_i (\bar{Y}_i - \bar{Y}_{..})^2 + \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2$$

En donde la primera parte de la ecuación indica la suma de cuadrados de los tratamientos (SC_{TRAT}) y la segunda la suma de cuadrados del error (SC_E). Expresados de otra forma, tendremos que:

$$SC_T = SC_{TRAT} + SC_E$$

En base a la cantidad de observaciones, se puede determinar que SC_T tiene N-1 grados de libertad (*DOF* por su sigla en inglés), SC_{TRAT} tiene k-1 *DOF* y que SC_E tiene N-k *DOF*.

Ahora, las sumas de los cuadrados divididas entre sus grados de libertad son denominadas "*Cuadrados Medios*", estos pueden ser considerados como una forma de estimar la magnitud de su correspondiente fuente de variabilidad. Los valores que se esperan para estos valores son:

$$E(CM_E) = \sigma^2$$

$$E(CM_{TRAT}) = \sigma^2 + \frac{\sum_{i=1}^k n_i \tau_i^2}{N - k}$$

En estas ecuaciones se puede apreciar que si H_0 es verdadero, ambas serían equivalentes a la varianza (σ^2), lo que da pie a la construcción de un estadístico de prueba basado en la siguiente afirmación:

*SC_{TRAT}/σ^2 y SC_E/σ^2 son dos variables aleatorias independientes, que tienen distribución ji-cuadrada con k-1 y N-k *DOF* respectivamente*

Ahora, bajo el supuesto de que H_0 es verdadero, el estadístico $F_0 = \frac{CM_{TRAT}}{CM_E}$ sigue una distribución F con (k-1) *DOF* en su numerador y (N-k) *DOF* en su denominador.

Relacionando las ecuaciones de los cuadrados medios esperados ($E(CM_E)$ y $E(CM_{TRAT})$), con la ecuación del estadístico de prueba, se puede deducir que si F_0 es un valor muy grande, la hipótesis de que el efecto de los tratamientos no genera un cambio significativo, por lo que se asume que no hay una diferencia estadísticamente significativa. Por el contrario, si el valor es muy pequeño, esta hipótesis se contradice, con lo que se puede afirmar que efectivamente, los tratamientos tienen un efecto estadísticamente comprobable y significativo en las variables de respuesta.

Para efectos prácticos, se establece un valor α , que determina el nivel de significancia. H_0 se rechazará siempre que se cumpla que el valor-p, el cual está definido como el área bajo la distribución $F_{k-1, N-k}$ a la derecha del estadístico F_0 , sea menor que el valor α .

Es importante tener en cuenta que para que esta prueba sea válida, se debe cumplir, que la variable de respuesta se distribuya de manera normal, con varianza constante y que las mediciones son independientes entre sí. Cuando estos supuestos no se cumplen, se deben usar métodos alternativos, tales como la prueba Kruskal-Wallis, que es considerada como la alternativa no paramétrica de la ANOVA. A veces, a esta prueba se le denomina ANOVA unidireccional sobre rangos, ya que en la prueba se utilizan los rangos de los valores de los datos en lugar de los puntos de datos reales. Al ser no paramétrica, la prueba no asume que los datos provienen de una distribución particular [23, 24].

3. ESTADO DEL ARTE

Como se mencionó anteriormente, la condición del MCI ha sido una preocupación durante muchísimo tiempo, dado que, de ésta depende su buen desempeño [25]. Uno de los grandes problemas está centrado en la hermeticidad del motor, dado que existen componentes internos imposibles de diagnosticar a simple vista, por lo que se han desarrollado diversos métodos para tratar de identificar posibles fallas de forma temprana.

El análisis de vibraciones es considerado un excelente sistema de diagnóstico de condición de diferentes tipos de máquinas rotativas, esto, debido a que es un tipo de evaluación que tiene la ventaja de no ser invasivo y permite recabar datos aún con los equipos en operación [1, 26]. Durante muchos años se ha investigado con éxito la aplicación de este tipo de análisis para detectar anomalías en los patrones vibratorios de los diferentes equipos, bien sea a partir del seguimiento histórico del comportamiento, o por la aplicación de otros métodos que permitan detectar cuando estos cambios están representando algún factor de alerta o algún tipo de daño [26].

En 2017, J.A.Hernández-Muriel, *et al.* [13] usan una base de datos de vibración de un motor de combustión interna, de cuatro pistones, donde se recaban datos de acelerómetros magnéticos para verificar la vibración de los pistones, sensores de presión dentro de los cilindros para identificar las etapas de la combustión y sensores de proximidad para hallar el ángulo del cigüeñal. Experimentalmente, evalúan 3 mezclas diferentes de gasolina y etanol, con el encendido normal y simulando un fallo, y trabajando a 1500 rpm, 1700 rpm Y 2000 rpm. En este estudio proponen una estrategia de análisis de relevancia que usa un algoritmo de Ensemble *Empirical Mode Decomposition* para descomponer la señal, el cual estima parámetro multi-dominio desde representaciones en tiempo y frecuencia, y selecciona características basada en *Relief-F* (método estadístico de clasificación de problemas), calcula algunos parámetros en el dominio del tiempo y de la frecuencia y finalmente calcula un vector de índice de relevancia para cuantificar la contribución de cada una de las características multi-dominio para discriminar diferentes categorías de estimación de mezcla de combustible y diagnóstico de MCI. Obtuvo resultados cercanos al 98% de acierto clasificando las condiciones del motor a partir de las señales en una base de datos de MCI.

A su vez, Cheng Jie, *et al.* [27], descomponen las señales en una serie de átomos de frecuencia temporal mediante un algoritmo de *Matching Pursuit* (MP). La descomposición se hace según la propiedad energética de la señal residual. Todos los componentes de la señal pueden expresarse en el dominio tiempo-frecuencia, de tal manera que se convierte en un buen insumo para el posterior diagnóstico mecánico de fallo del motor de combustión interna. Para comprobar la efectividad del método, analizan las señales vibratorias en un motor diésel trabajando en 4 válvulas con diferentes niveles de holgura (admisión 0.5 mm y escape 0.5mm, admisión 0.5 mm y escape 0.05 mm, admisión 0.5 mm y escape 1 mm y por último, admisión 0.5 mm y escape 4 mm), la longitud de la señal es 20.000 y la frecuencia de análisis es de 25 kHz. Encuentran que su algoritmo además de disminuir

tiempo de cómputo mantiene una buena resolución en las señales para adquirir información fiable de ellas.

Este tipo de análisis se puede usar para crear aplicaciones basadas en el uso de redes neuronales para clasificar y detectar condiciones en elementos particulares, tales como la holgura de las válvulas de admisión y escape, o defectos en los pistones. Las redes neuronales artificiales han probado ser una herramienta poderosa para el diagnóstico de fallas, esto debido a su capacidad de clasificación incluso cuando la información no es muy completa o viene acompañada del ruido inherente al funcionamiento del motor [28].

Usualmente, se toma información de manera experimental y algunas veces a partir de simulaciones dinámicas de un sistema inicialmente en óptimas condiciones y luego se repite el procedimiento con defectos o averías controladas, se descompone la información a través de los algoritmos anteriormente mencionados, y finalmente, se usa la información recabada para alimentar redes neuronales artificiales, las cuales sirven como clasificadoras, y, cuando están bien entrenadas, evaluadoras fiables dada su alta precisión para el diagnóstico de las condiciones del sistema.

En el trabajo realizado por Jian Chen, et al. [29] Se usan diferentes tipos de redes neuronales artificiales para el diagnóstico automatizado de las fallas en los pistones. Analizan las señales vibratorias generadas por éstos, los pistones, en un motor a gasolina Toyota trabajando a 3 velocidades diferentes (1500 rpm, 2000 rpm y 3000 rpm), el cual está conectado a un dinamómetro para simular 3 condiciones de carga (50 Nm, 80 Nm, 110 Nm.) se recopilan los datos de las vibraciones generadas con el encendido normal y presentando un fallo en este (*misfire*), y con los pistones en condiciones de holgura normales (0.05 mm) y luego, aumentando ésta misma en uno de los pistones para generar golpeteo (0.15 mm para un golpeteo moderado y 0.30 mm para un golpeteo severo). Su mayor dificultad fue la necesidad de una cantidad alta de datos para entrenar la red para identificar fallas en diferentes condiciones de velocidad, carga, ubicación y nivel de falla. Se usaron 2 redes perceptrón multicapa (MLP) separadas para cada nivel de velocidad y con un rango de carga en la fase de detección y de clasificación de la gravedad de la avería, y redes neuronales probabilísticas (PNN) para la identificación del pistón que presentaba la falla, reportando 100% de acierto en cada una de las redes neuronales artificiales usadas.

Con el fin de alimentar, y/o validar la información arrojada por las diferentes redes neuronales, se han determinado diversas condiciones para hacer montajes experimentales para verificar ciertos tipos de fallas particulares en los MCI, buscando recopilar información confiable para garantizar una buena deducción de las condiciones de operación de los diferentes componentes del sistema.

Dolatabadi, et al. desarrollaron Modelos matemáticos para predecir el golpeteo de los pistones. Usando acelerómetros ubicados en lados opuestos entre sí del bloque del motor, sobre la línea del cigüeñal para detectar las vibraciones generadas por el golpeteo de los pistones en un motor CFR (*Cooperative Fuel Research*). Trabajaron 3 combinaciones de velocidad/carga: 3000 rpm y 27 Nm, 3500 rpm y 40 Nm y 4250 rpm y 42 Nm. En cada caso recopilaron información referente a golpes y posición del pistón. Luego usaron las señales capturadas por los acelerómetros, éstas fueron filtradas y se realizó un análisis de wavelet

para estudiar los eventos. Antes de procesar la información, determinaron las frecuencias que iban a ser usadas para el análisis, encontrando que comúnmente se usan intervalos entre 450 Hz y 3500 Hz. Con la información recabada, determinaron cuales de los modelos tenían una fiabilidad mayor en el caso de que hubiese bajas revoluciones o altas revoluciones en el motor [30].

Por su parte, Jian Chen y Randall [31] proponen un modelo cinético/cinemático y uno de lubricación, los cuales se pueden relacionar en un ciclo cerrado, para simular lo que sucede cuando existe holgura y exceso de lubricación en el cojinete de la base del pistón. Analizaron y contrastaron los resultados de sus modelos con la información recabada de las señales vibratorias de un motor Toyota de 4 cilindros trabajando a 3000 rpm y conectado a un dinamómetro para simular torques de 50 Nm, 80 Nm y 110 Nm. Tomaron mediciones en condiciones normales del motor y luego dividieron la experimentación en dos fases, para lo cual generaron holguras de 0.2 mm y 0.4 mm (la holgura normal es 0.1 mm) en el cojinete de la base de la biela para analizar el comportamiento en cada una de estas condiciones.

Dichos autores determinaron, además, que el rango de la frecuencia de las fallas de dicho rodamiento se encontraba en su mayoría en una frecuencia por debajo de los 6400 Hz, hallando luego que un rango entre 400 Hz y 4400 Hz era apropiada para la evaluación de las fallas en éste en ambas fases. Lograron determinar que los modelos se acoplan bien a lo hallado experimentalmente, dado que la amplitud de la señal en condiciones normales es bastante baja en comparación con la que se daba en la fase 1, por lo que la identificación de eventos se hace bastante evidente, además, aunque los valores recopilados experimentalmente en la fase 2 son un poco más altos que los modelados, la diferencia con los de la etapa 1 son tan grandes, que aun así, son una buena aproximación para determinar los eventos y la gravedad de los mismos

Jian-Da Wu et al. [32] usaron un sensor de presión y un sistema de adquisición de datos para obtener los resultados tras experimentar en un motor de inyección Ford tipo L, de 4 cilindros y 1.6-L, luego, analizaron y clasificaron las señales usando transformadas de wavelet (CWT) y un par de redes neuronales (RBFN, *radial basis function network*, y GRNN, *generalized regression neural network*). En el análisis de la señal, estas pudieron ser descompuestas en 9 niveles por wavelet, y posteriormente usadas para entrenar las redes para detectar fallas. Para el estudio usaron 5 condiciones de falla y 5 velocidades de rotación. Las 5 condiciones del motor fueron, análisis en condiciones normales, falla en un inyector, falla en 2 inyectores, fuga de aire en a admisión y entrada obstruida. Las 5 velocidades fueron: ralentí (800 rpm), 1000 rpm, 1500 rpm, 2000 rpm y 3000 rpm. Como resultado obtuvieron que ambas redes neuronales tuvieron un nivel de acierto en el reconocimiento de fallas alto (99%), sin embargo, el GRNN requirió de un tiempo de reconocimiento mucho menor (0,46 vs 7,4 segundos)

Un año mas tarde, Jian-Da Wu y Cheng-Kai Huang [33] analizaron la información obtenida por un sensor de presión en el mismo motor en ralentí (800 rpm), 1000 rpm, 1500 rpm y 3000 rpm, trabajando en 5 condiciones de operación (condiciones normales, presentando fallas en un inyector, presentando fallas en dos inyectores, con fugas de aire y con obstrucción en la admisión), experimento similar al anterior, sin embargo en este caso

usaron la distribución Wigner Ville para definir la autocorrelación dependiente del tiempo y generar diagramas relacionados con las diferentes señales de presión en el múltiple de admisión y alimentaron diferentes redes neuronales (RBFN y GRNN) para comparar su desempeño en el diagnóstico de fallas del motor. Encontraron que, tras analizar los resultados, la red neuronal de regresión generalizada también presenta un mayor nivel de acierto en la clasificación de fallas, además de tomar menos tiempo para su reconocimiento.

Existen otros autores que trabajaron con sensores de presión, sin embargo, en la mayoría de los casos, estos fueron adaptados para funcionar dentro de la cámara de combustión con el fin de tener información más detallada de los procesos que ocurrían en su interior estando en buen funcionamiento o cuando se presentaban determinados tipos de fallas. Es importante aclarar, que este tipo de sensores requieren una alta inversión económica debido a que son costosos y requieren de modificaciones en el motor para poder ser posicionados [25].

En la Universidad Tecnológica de Pereira, Torres M. D. et al. [26] usaron un acelerómetro en el bloque en sentido vertical, un sensor de presión ubicado en la posición de la bujía y un sensor inductivo con una rueda fónica para la determinación de la posición del eje en cada instante, con el fin de montar un sistema de monitoreo de condición de un motor diesel monocilíndrico, la información recabada por medio del acelerómetro fue procesada a partir de FFT. Por medio de este procedimiento pudieron detectar un caso en el que el combustible se encontraba en una condición inferior a la óptima. Además, a partir de las mismas señales vibratorias y usando un proceso de regresión rígida de kernel, reconstruyen la curva de presión dentro del cilindro y usan los otros dos sensores, el de presión y el de posición, para verificar la precisión de la curva obtenida, con resultados bastante similares.

Un estudio realizado por Shi et al. [34] Investigó el golpeteo dentro de la cámara y la liberación de calor usando sensores de presión montados en un recubrimiento especial para soportar estos, junto con cuatro bujías laterales. El objetivo era identificar las ubicaciones individuales de chispa y medición. Además, se usó un sistema de medición de emisiones de escape. A la información recabada se le aplicaron técnicas de regresión lineal y se aplicaron funciones de Weibe para estimar la energía liberada por la ignición en cada ciclo, permitiendo relacionar esta con el golpeteo generado en cada ciclo de trabajo.

Para el caso particular de este estudio, las fallas propuestas para ser detectadas se refieren a las solturas o fracturas en soportes de motor y el mal asentamiento de las válvulas de admisión y escape, temas abordados por diferentes métodos con anterioridad, nunca en conjunto, además, son fallas que no están catalogadas en el sistema de diagnóstico del vehículo (OBD), con lo que cobra una relevancia aún mayor.

Por ejemplo, Haiqiang et al. [35] realizan estudios de fallas en soportes de motor haciendo uso de análisis de elementos finitos, análisis de morfología de falla y test de materiales para determinar que agentes precipitan la falla en este tipo de componentes y proponen una optimización de la estructura desde el análisis de elementos finitos con la que obtienen un incremento del 20 % en el esfuerzo máximo.

Autores como Chaoming et al. [36] usan el análisis de vibraciones para detectar un asentamiento anormal de las válvulas, para esto, se modificó el espacio entre el balancín y la varilla de la válvula, con lo que se pretendió simular un desgaste del par móvil del mecanismo. Esto significó un cambio en el emparejamiento y un espacio fuera de los rangos normales. Las señales obtenidas fueron tratadas por medio de diversos métodos, como el algoritmo de descomposición y reconstrucción de ondas locales, la CWT y métodos de análisis de imágenes, con los cuales extrajeron las características vibratorias de la señal en el asiento de la válvula. Este método probó ser efectivo para evaluar este tipo de fallos.

En 2018 Iwona Komorska y Zbigniew Wólczyński [37] propusieron un método para identificar fallas en el vehículo haciendo uso de los sensores que vienen instalados por defecto. Realizaron mediciones induciendo bloqueos en el flujo de aire del lado del filtro, un cambio característico en el ángulo de la mariposa y una fuga de aire en la admisión, luego usaron las diferencias detectadas por los sensores MAP, MAF y el sensor de posición de la mariposa con sensores virtuales basados en modelos, con lo que lograron detectar estados normales y estados de falla en el vehículo. Un punto interesante de este estudio es que se detectaron fallas que no fueron percibidas por el OBD. En el artículo no se presentan valores numéricos que permitan contrastar los resultados, sin embargo, hacen referencia a que el sensor de flujo de aire instalado en el vehículo no aporta información relevante para la detección de fallos cuando trabaja a un régimen de giro por debajo de las 2000 RPM.

Es de vital importancia mencionar que existen muchos documentos relacionados con el diagnóstico de máquinas, haciendo uso de los métodos y técnicas usados en este trabajo, sin embargo, en la búsqueda de información realizada, no fue posible encontrar algún artículo que usara la combinación de señales de presión en la admisión en conjunto con las señales vibratorias en el bloque del motor para hacer este tipo de caracterización de fallos.

Es interesante el hecho de que estos tipos de sensores son de uso común en los MCI, lo que da pie a la búsqueda de procedimientos que puedan permitir el uso de éstos para generar diagnósticos que permitan conocer la condición de algunos componentes del motor.

Este trabajo representa un primer paso encaminado a el uso de sistemas internos del vehículo y redes neuronales para la detección de fallas diferentes a las ya configuradas en el sistema de alarmas del motor.

4. METODOLOGÍA Y RESULTADOS

4.1. Banco de ensayos

El montaje experimental, como se puede observar en la Ilustración 12, se realiza en un motor CFR (1). Este es un motor de laboratorio que se usa generalmente para evaluar la calidad de combustibles y aditivos, pero que cuenta con una arquitectura particular que permite realizar modificaciones en algunos parámetros de forma sencilla, en comparación con otro tipo de motores. El CFR cuenta con un solo pistón (2), el cual tiene la posibilidad de ajustarse para variar la relación de compresión, una ventaja a la hora de realizar ensayos que simulen distintos motores con diferentes relaciones de compresión. Para realizar las mediciones de vibraciones, se ubican acelerómetros piezoeléctricos (3) en el bloque que contiene al pistón, sobre los ejes X, Y y Z (ver posiciones en (2)), conectados a un módulo de adquisición de datos NI9234 (4). La señal de presión se mide por medio de un sensor de presión (5) ubicado en la admisión, conectado a un módulo de adquisición de datos NI9215 (4). Las señales medidas, durante 5 segundos, se envían a un computador para su posterior procesamiento. El motor se enciende únicamente haciendo uso del motor de arrastre, esto con el fin de no involucrar el ruido producido por el proceso de combustión, es de aclarar, que este proceso se puede replicar de una forma simple en un vehículo, simplemente desconectando el cable que permite el paso de electricidad a la(s) bobina(s), evitando así que se genere la chispa que produzca ignición en el motor.




Ilustración 12. Montaje experimental: (1) Motor CFR, (2) Esquema de direcciones según posición del pistón, (3) Acelerómetros, (4) Tarjetas de adquisición de datos, (5) Sensor de presión, (6) Computador

4.2. Cadena de adquisición de datos

Para efectuar las mediciones de las vibraciones mecánicas se utilizarán los siguientes equipos, que son propiedad de la Universidad de Antioquia, en la cadena de adquisición de datos:

	a. Chasis NI cDAQ 9172
	b. Módulo NI 9234
	c. Módulo NI 9215
	d. Acelerómetros.
	e. Sensor de presión MPX 2010 dp

Tabla 6. Equipos empleados para la adquisición de datos.

En la Tabla 6 Tabla 6. Equipos empleados para la adquisición de datos. Se pueden observar los equipos usados en el sistema de adquisición de datos:

El chasis NI cDAQ-9172 (a) contiene 8 puertos para conectar módulos de entrada o salida de señales. El Chasis tiene conexión *plug and play* de alta velocidad USB, y puede operar en ambientes en rangos de temperatura entre 0-55°C. Al chasis se le conecta un módulo NI 9234 con cuatro canales para poder conectar 3 acelerómetros.

El módulo NI 9234 (b) tiene una resolución de 24bit, filtros *anti-aliasing* y las entradas análogas reciben señales entre $\pm 5V$. La frecuencia de muestreo puede llegar hasta 51.2 kS/s. Los filtros *anti-aliasing* se ajustan automáticamente según la frecuencia de muestreo configurada. Este módulo permite realizar muestreos simultáneos.

El módulo NI 9215 (c) tiene 4 canales de entrada analógica para muestreos simultáneos, cuenta con una resolución de 16 bits y contiene una barrera de doble aislamiento de canal a tierra para garantizar seguridad e inmunidad al ruido. La frecuencia de muestreo puede llegar hasta 100 kS/s. En el caso de este estudio, la frecuencia usada para el muestreo fue de 10240 Hz

Los acelerómetros piezoeléctricos identificados con la letra (d) en la Tabla 6, tienen las especificaciones mostradas en la Tabla 7.

Especificaciones	Acelerómetros CTC
Modelo	AC 150-2C
Sensibilidad (mV/g)	100
Rango de medida (g)	± 50
Rango de frecuencias (Hz)	1-10.000
Frecuencia de resonancia (Hz)	23.000

Tabla 7. Especificaciones de los acelerómetros.

En la Tabla 6, el sensor de presión MPX 2010 dp (e) es un transductor piezoresistivo de silicio de alta precisión, que sirve para medir presión de aire. Cuenta con una salida de voltaje análogo lineal que varía proporcionalmente con la presión aplicada.

En la Tabla 8 se pueden apreciar algunas de las especificaciones del sensor de presión.

Especificaciones	Sensor de presión
Modelo	MPX 2010 dp
Sensibilidad (mV/kPa)	2.5
Rango de medida (kPa)	0-10
Tiempo de respuesta (ms)	1
Voltaje de alimentación (V)	0 - 16

Tabla 8. Especificaciones del sensor de presión.

4.3. Diseño experimental

Inicialmente se plantea un diseño experimental con el fin de analizar 4 posibles fallos en 2 niveles cada uno. Para esto, se proponen 16 montajes experimentales para simular diferentes combinaciones de los posibles fallos a detectar. De cada uno de estos montajes se midió la información de 40 corridas o réplicas, de 5 segundos cada una, esto con el fin de tener suficientes insumos para hacer el análisis y más adelante, alimentar una red neuronal. Cabe aclarar, que las pruebas se corren por bloques, dado que cada configuración de combinación de fallos requiere un tiempo considerable, por lo que no es posible aleatorizar las muestras. En la Tabla 9 (página 55) la cual será mencionada nuevamente más adelante, se pueden apreciar las diferentes configuraciones en el orden de experimentación.

Las posiciones a las que se refiere cada caso son:

Válvulas: Cuando se habla de una posición ajustada, supone el asiento normal de las válvulas. En el motor CFR, El asiento es forzado gracias a la acción de un muelle que trabaja a compresión. Este se comprime en sincronía con la posición del cigüeñal que corresponde al tiempo indicado para que se abra. Para realizar esta acción, una leva desplaza verticalmente un eje roscado que termina en un casquete esférico unido a una palanca pivotada que conecta con el muelle. La posición de contacto entre el casquete y la palanca se configura por medio de un sistema de tuerca-contratuerca. En la posición ajustada de las válvulas, la tuerca está en contacto con el sistema que contiene al casquete justo en el punto en que el resorte se encuentra en posición de cierre de válvula, sin ningún tipo de juego, dado que esto generaría un golpeteo entre la palanca y los demás sistemas, propiciando así, una pequeña tardanza en la apertura de la válvula y una apertura solo parcial de la misma.




Ilustración 13. Posiciones de las válvulas. (a) Ajustada, (b) 1 vuelta.

1 vuelta, se refiere a la posición de desajuste del sistema tuerca-contratuerca, dando una vuelta por encima de la posición de asiento correcto o ajustado, el desajuste generado al dar una vuelta es equivalente al paso de la rosca, 0.7 mm.

El desajuste de válvulas o mal asentamiento de éstas es un problema medianamente común en los MCI. Una válvula desajustada disminuye el desempeño, la confiabilidad y la eficiencia, esto debido a que se puede generar un cambio en el dosado estequiométrico por la fuga presentada, lo que repercute en la calidad de la combustión, generando humo y residuos por encima de los niveles de funcionamiento normal. Además, esto puede aumentar el consumo de combustible e incluso el desgaste de algunos componentes por el golpeteo generado. Las posibles causas de desajuste en válvulas van ligados a desgastes, solduras mecánicas o un mal asiento por bloqueos o suciedad.

Distancia entre el pistón y la culata: Los valores que referencian la distancia entre el pistón y la culata están dados en un nonio en milésimas de pulgada, ajustable en el motor CFR, el cual se modifica por la acción de una manivela. Según el catálogo, cuando el nonio se encuentra en la posición 5,75, representa una relación de compresión de 5.15. Ésta posición se toma, entonces, como una referencia para las mediciones de control.

Cuando el nonio marca 6 en su posición, la relación de compresión cae hasta 5,05. Una tasa de compresión menor en la cámara de combustión puede tener diferentes causas que son comunes en los MCI, tales como un desgaste en los anillos (sellos), en el pistón, fisuras en la culata o incluso un mal asentamiento de válvulas. Se considera este como un parámetro interesante para tratar de diferenciar la falla por mal asentamiento de válvulas de las otras posibles fallas que generen una caída de presión en la cámara.

Las consecuencias de la caída de la relación de compresión en un MCI pueden ser una reacción en cadena, desde la pérdida de potencia debido a que no se libera la misma cantidad de energía en la cámara de combustión, hasta el consumo excesivo de combustible

para tratar de suplir la pérdida de potencia, el aumento de las emisiones contaminantes y los desgastes en los componentes.

Soporte del motor: Cuando los motores manejan una alta potencia, o están sometidos a condiciones particulares de alto esfuerzo, pueden ocurrir daños en el soporte del mismo. Los daños más comunes en el soporte del motor se dan por excesivas vibraciones, desgastes, fatiga, o materiales de baja calidad en su fabricación. El daño en el soporte del motor es un desencadenante de problemas más graves, debido a que las vibraciones generales del equipo tenderán a subir, afectando el desempeño total del mismo.




Ilustración 14. Esquema de montaje del soporte de motor (caucho rígido).

Para simular una soltura en el soporte del motor, se toma la decisión de poner un caucho entre dos de los apoyos de éste, y fijar las tuercas que anclan el motor al piso con el mismo torque en sus cuatro puntos de apoyo. El caucho, al ser un material mucho menos rígido que el concreto, nos permite simular una condición de leve daño en el soporte del motor, ya que debe presentar un patrón vibratorio diferente, esto debido a que el caucho se está comportando como un resorte.

En la Ilustración 15, podemos observar la curva generada por el ensayo de compresión en el caucho. La pendiente de esta curva nos indica el valor de rigidez del material, el cual corresponde a 16.616 N/mm

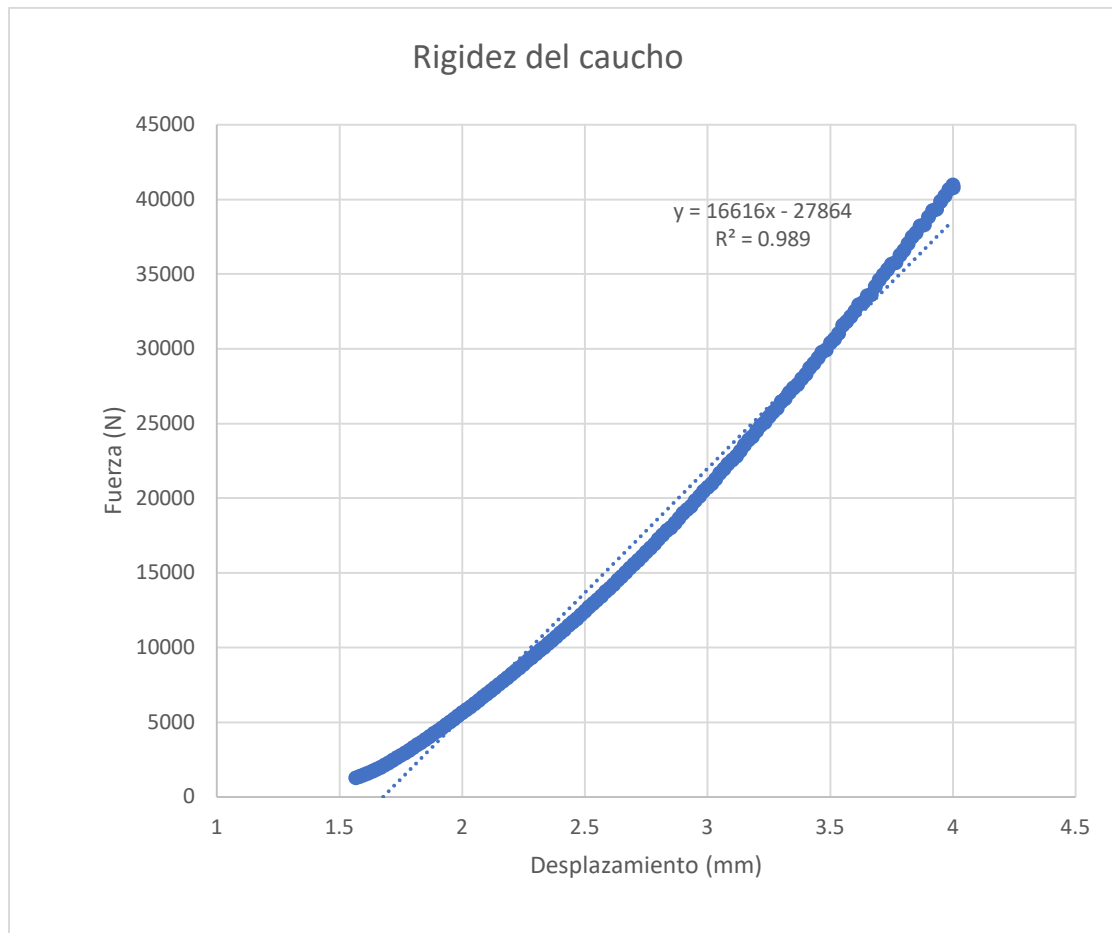


Ilustración 15. Rigidez del caucho usado para simular fallo en el soporte. Ensayo de compresión bajo la norma ASTM D575

En la Tabla 9, se presentan las diferentes corridas experimentales realizadas con la combinación de fallos que se simuló en cada una de ellas. Preparar el banco de pruebas para realizar cada una de estas combinaciones es un proceso complejo y engorroso, además toma un tiempo considerable, por lo que realizar mediciones de forma aleatoria se convierte en algo inviable. Basados en lo anteriormente mencionado, se decide el orden de las configuraciones que se muestran a continuación. Esta tabla será el insumo para evaluar por métodos de análisis de señales, gráficos y en frecuencia, y luego por métodos estadísticos, los cuales proporcionarán la información que se usará más adelante para alimentar la red neuronal.

FECHA	PRUEBA	VÁLVULA DE ADMISIÓN	VÁLVULA DE ESCAPE	DISTANCIA ENTRE EL PISTÓN Y LA CULATA	ESTADO DEL SOPORTE
10/09/22	P1	AJUSTADA	AJUSTADA	5,75	CAUCHO
	P2	AJUSTADA	AJUSTADA	6	CAUCHO
	P3	1 VUELTA	AJUSTADA	6	CAUCHO
	P4	1 VUELTA	AJUSTADA	5,75	CAUCHO
12/09/22	P5	1 VUELTA	1 VUELTA	5,75	CAUCHO
	P6	AJUSTADA	1 VUELTA	5,75	CAUCHO
	P7	AJUSTADA	1 VUELTA	6	CAUCHO
	P8	1 VUELTA	1 VUELTA	6	CAUCHO
26/09/22	P9	1 VUELTA	1 VUELTA	6	AJUSTADO
	P10	1 VUELTA	1 VUELTA	5,75	AJUSTADO
	P11	AJUSTADA	1 VUELTA	5,75	AJUSTADO
28/09/22	P12	AJUSTADA	1 VUELTA	6	AJUSTADO
30/09/22	P13	AJUSTADA	AJUSTADA	6	AJUSTADO
	P14	AJUSTADA	AJUSTADA	5,75	AJUSTADO
	P15	1 VUELTA	AJUSTADA	5,75	AJUSTADO
	P16	1 VUELTA	AJUSTADA	6	AJUSTADO

Tabla 9. Configuración de combinaciones de fallos

4.4. Análisis de resultados

Para el análisis de resultados se proponen diferentes tratamientos encaminados a determinar cuáles de estos fallos son detectables, que parámetros cambian con las diferentes configuraciones propuestas, y qué tan útiles pueden ser estos parámetros para la generación de un clasificador de fallos por medio de una red neuronal.

Se realiza un análisis gráfico de las señales en el dominio del tiempo y en el dominio de la frecuencia en cada caso. Además, se plantean diferentes parámetros para alimentar la red neuronal. Basados en estas observaciones, se hace una matriz de correlaciones para verificar la utilidad de estos parámetros para explicar las respuestas en cada uno de los

elementos, y se crea y entrena una red neuronal para determinar su utilidad en la clasificación de los fallos determinados.

4.4.1. Análisis de señales:

Las gráficas presentadas en los siguientes apartes se realizaron usando mV en la escala de los valores de presión, esto debido a que la escala permite un acople visualmente muy claro respecto a las unidades de aceleración. El rango de presiones que maneja el motor CFR fue medido entre 0 y 2.5 pulgadas de H₂O en succión.

4.4.2. Asentamiento de válvulas:

Con el fin de determinar si es posible la identificación efectiva de fallas de asentamiento en las válvulas de admisión y escape, se plantearon diferentes tratamientos para las señales que ayudaran a vislumbrar los diferentes efectos producidos por la siembra de fallas.




Análisis gráfico de señales en el dominio del tiempo:

Para este procedimiento se sincronizaron las señales brutas medidas por los acelerómetros y por el sensor de presión, obteniendo gráficas como las que se observan en la Ilustración 16. En éstas, la señal en color naranja representa el comportamiento de la aceleración y la señal en color azul, el comportamiento de la presión, ambas en el dominio del tiempo. Valga notar que existen ciertas condiciones iniciales que se cumplen siempre y cuando las válvulas se encuentren en una buena posición de asentamiento:

Dado que el sensor de presión se encuentra en la admisión, siempre que haya un buen asentamiento de esta válvula, el sensor queda aislado de la cámara de combustión, en las etapas de compresión, expansión y escape.

Los acelerómetros deben mostrar un pico en el momento de cierre de válvulas, esto debido al golpe que supone el contacto de la válvula con el bloque del motor en ese instante.

En la parte (a) de la figura, se puede observar lo que llamaríamos una posición de referencia, en donde se puede notar claramente el instante en que se cierra la válvula de escape (punto E) lo que da inicio al proceso de admisión, en donde la succión de aire provocada por el pistón genera el pico de vacío relativo (presión manométrica negativa) que se puede observar en la señal de presión (punto S). Se puede notar luego la aparición del pico en la señal de aceleración generado por el golpe que se da al cerrar la válvula de admisión (punto A). Luego de esto, aparece una zona en la que no hay señal alguna, dado que el sistema se encuentra perfectamente aislado de la cámara de combustión al estar las válvulas cerradas, por lo que no hay flujo de aire, y por tal motivo la admisión consigue nuevamente el valor de la presión atmosférica. Esto no permite lectura en la señal de presión y no existe un componente que esté generando golpeteos, esto hasta el punto en que el ciclo vuelve a empezar.






Ilustración 16. Superposición de gráficas temporales con siembras en válvulas. (a) ambas válvulas ajustadas, (b) válvula de admisión desajustada, (c) Válvula de escape desajustada, (d) Ambas válvulas desajustadas.

En la parte (b), se logra observar que luego del cierre de la válvula de escape “E”, los picos de la señal de presión “S” se mantienen, lo que se debe al hecho de que, en el momento de realizarse el proceso de succión, la válvula de escape se encuentra bien ajustada, sin embargo, existe un cambio notable en ambas señales, dado que después de esto, el cierre de la válvula de admisión no es marcado en la señal de aceleración “A”, lo que indica que ésta no ajusta bien, y existe un filtrado de aire en el momento en el que el pistón estaría haciendo el proceso de expansión, generando un nuevo pico de succión de aire en la señal de presión (punto F).

En la parte (c), podemos notar que no hay una señal clara en aceleración que indique el cierre de la válvula de escape “E”, además, hay una inminente caída en el pico de presión “S”, debido a que el sensor está ubicado en la admisión, pero al haber una luz en el escape, al generarse el proceso de succión, se filtran gases del escape para llenar la cámara, por lo que se reduce el flujo desde la admisión y por tal motivo se ve un pico menor en la señal de presión en la admisión. Luego de este proceso, se observa claramente la señal de cierre de la válvula de admisión “A” y se aísla el sistema, lo que no permite que el sensor de presión pueda capturar más información hasta el proceso de cierre de la válvula de escape, donde comienza nuevamente el ciclo.

Por último, en la parte (d), podemos observar un comportamiento de las señales de presión “S” y “F” similares a los presentados en el caso de la parte (b), acompañado de un cambio notable en las señales de aceleración, ya que no se observan picos claros que indiquen el cierre de alguna de las válvulas “E” y “A”.

A través de estas observaciones podemos determinar que existen algunos parámetros de las señales temporales que pueden ser interesantes para la alimentación de una red

neuronal que clasifique fallos. Los valores RMS de ambas señales tienen comportamientos diferentes en cada una de ellas, igual que los factores de cresta, debido al cambio en la forma y en los valores pico, dadas las caídas notables en las diferentes señales.

Análisis de señales en el dominio de la frecuencia

Para realizar el análisis en el dominio de la frecuencia, se debe tener en cuenta que la velocidad de rotación del motor es bastante estable y corresponde a 890 RPM, lo que equivale a una frecuencia de 14.83 Hz. Está será nuestra frecuencia 1X. Esto quiere decir que el proceso de evaluación del motor es estacionario.

Presión:

En la Ilustración 17 podemos observar las gráficas de frecuencia de las señales de presión captadas por el sensor, obtenidas a partir de una transformada rápida de Fourier. Este tipo de tratamiento también muestra comportamientos diferentes para cada caso particular. Es de notar el hecho de que existe una señal clara en 0.5X debido a que la apertura de las válvulas se da 1 vez cada 2 revoluciones, en consecuencia, se tienen además medios armónicos, 1.5X, 2.5X, etc.

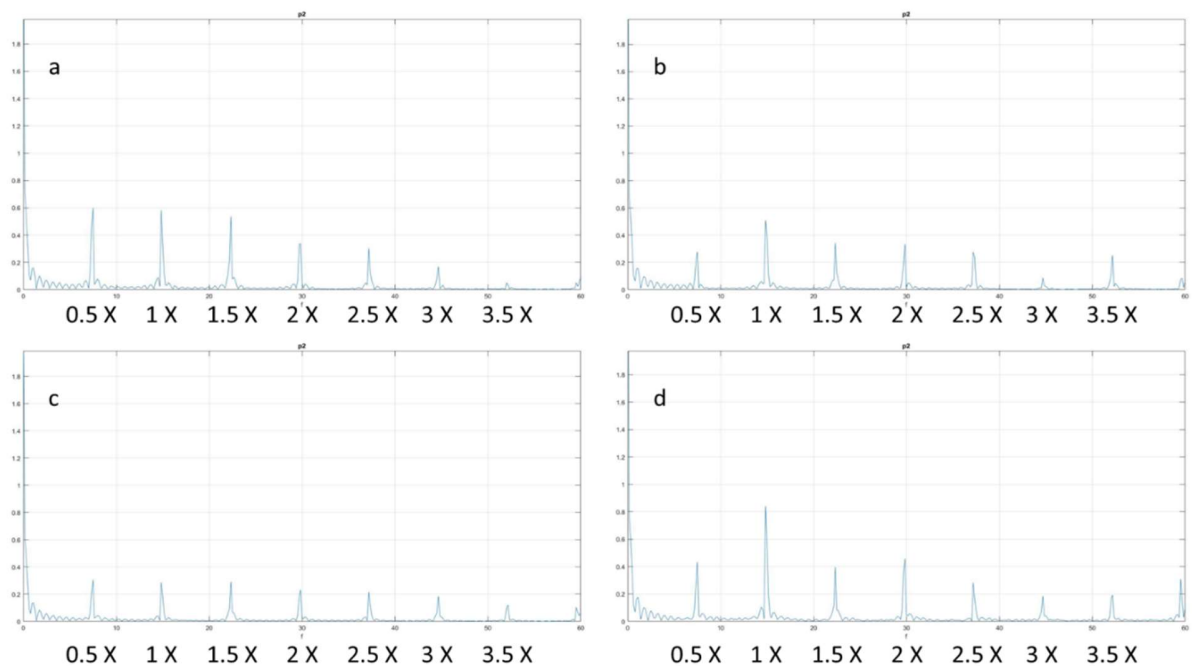


Ilustración 17. Gráficas de frecuencia de la señal de presión (a) ambas válvulas ajustadas, (b) válvula de admisión desajustada, (c) Válvula de escape desajustada, (d) Ambas válvulas desajustadas.

En la parte (a) podemos observar que las magnitudes que corresponden a las frecuencias 0.5X y 1X son muy similares en magnitud, lo que se da cuando ambas válvulas están bien asentadas. En la parte (b) podemos observar una caída grande en la magnitud de la señal en 0.5 X con respecto al caso anterior. En el caso de la señal 1 X, también existe

una pequeña caída que puede ser o no estadísticamente significativa, lo cual podremos observar más adelante cuando se haga la revisión del análisis estadístico. En la parte (c), se observa una clara caída en las magnitudes de las señales en 0.5 X y 1 X con respecto a lo observado en la parte (a), algo que concuerda con las imágenes observadas en las señales temporales, en donde, en el mismo caso de estudio, observamos las que la señal de presión es considerablemente más pequeña que en los demás casos. En la parte (d), se puede observar que la magnitud señal en 0.5 X es baja con respecto al caso de un buen asentamiento, sin embargo, la magnitud de la señal en 1 X es notablemente más grande que en cualquier otro caso, esto se debe la suma de las señales de presión que se obtienen por cada revolución es mayor.

A raíz de la información obtenida de las gráficas en dominio de la frecuencia de la señal de presión, podemos asumir, por ahora, que los valores RMS de la señal de presión filtrada en valores cercanos a las frecuencias 0.5X, 1X, 1.5X y 2X, tienen la posibilidad de ser insumos valiosos para la alimentación de una red neuronal que clasifique los fallos de asentamiento de válvulas.

Aceleración de la vibración:

En la Ilustración 18, se pueden observar las gráficas de frecuencia de la señal de aceleración de la vibración, en éstas se aprecian ciertos comportamientos relacionados con los daños de asentamiento de válvulas.

En la parte (a), La magnitud de la señal en las frecuencias 1X y 2X, son notablemente superiores a las obtenidas en cualquier otra de las disposiciones del motor, lo que puede estar relacionado con que es la configuración en donde se detecta un golpe mayor con el cierre de válvulas. La magnitud de la frecuencia de la señal en 0.5X, a pesar de ser bastante pequeña, es muy superior a la encontrada en los demás casos. La magnitud de la señal en las frecuencias 1.5X y 2.5X es bastante más grande que en cualquiera de las demás configuraciones.

En las partes (b), (c) y (d), la magnitud de la frecuencia en 0.5X es muy baja y en algunos de los casos, casi nula, lo que indica que la componente de la señal de aceleración que se obtiene debido al cierre de válvulas es bastante pequeña en relación con otras perturbaciones, esto es comprensible dado que, al haber un mal asentamiento, no se obtiene un golpeteo que genere una señal clara, justo como se apreció en las gráficas temporales. La magnitud de la frecuencia en 1X, es similar en los casos en los que al menos una de las válvulas no está bien asentada, sin embargo, la magnitud de la señal 2X, presenta cambios considerables en cada caso, siendo el menos notable el que se da cuando la falla se presenta en el asentamiento de la válvula de admisión, continuando con la falla en asentamiento en la válvula de escape y presentando la caída más grande cuando ambas válvulas se encuentran desajustadas.

La magnitud de las señales en la frecuencia 1.5X presenta comportamientos disimiles en todos los casos y muestra lo que parecen ser, bandas laterales, sin embargo, es necesario

hacer un análisis puntual a través de filtros para poder determinar qué tan grandes son estos cambios de forma certera.

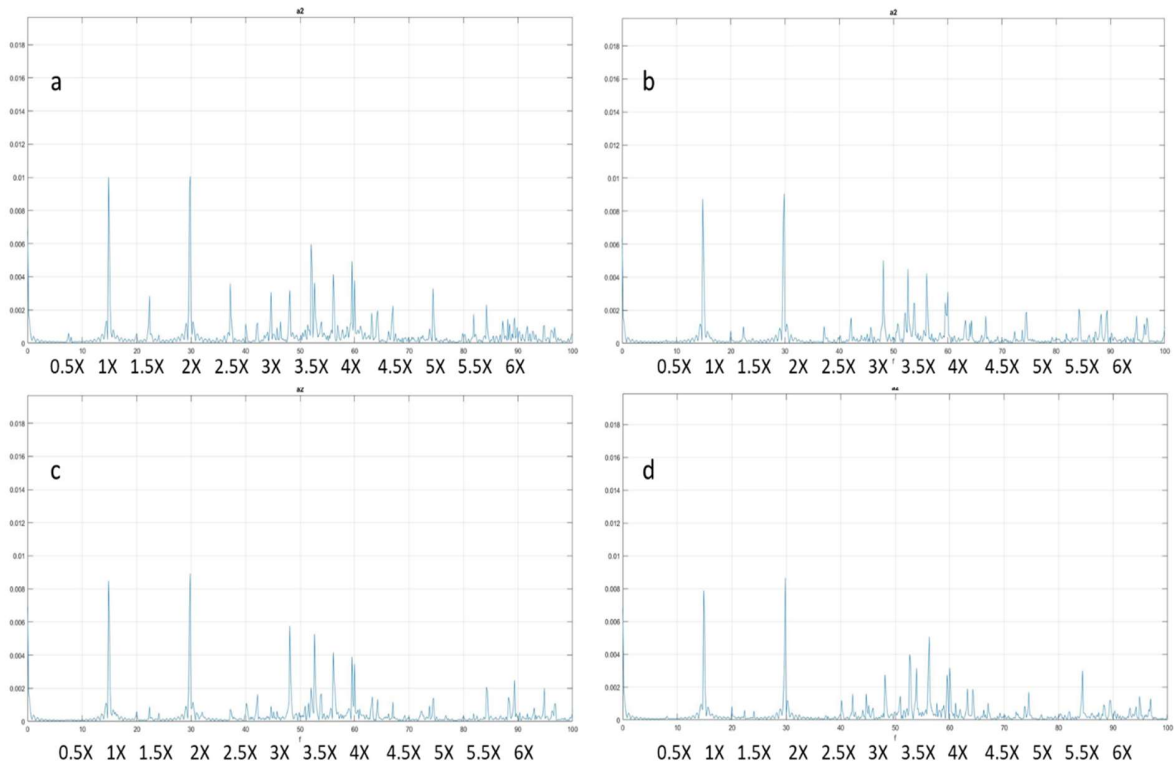


Ilustración 18. Gráficas de frecuencia de la señal de aceleración de la vibración (a) ambas válvulas ajustadas, (b) válvula de admisión desajustada, (c) Válvula de escape desajustada, (d) Ambas válvulas desajustadas.

4.4.3. Cambio en la relación de compresión dentro del cilindro

Analizando la superposición de las señales temporales tanto en presión como en aceleración de la vibración, presentadas en la Ilustración 19, no se perciben cambios ni de magnitud ni de forma que permitan detectar alguna perturbación. Esto era de esperarse, dado que, en el proceso de compresión, la válvula de admisión está cerrada, lo que aísla el sensor encargado de medir la presión, además, no hay cambios en los patrones de movimiento, lo que no permite detectar alguna perturbación diferente a través del acelerómetro.

En las imágenes que se encuentran en el dominio de la frecuencia, podemos observar que tampoco se aprecian cambios significativos, lo que respalda la observación realizada a las imágenes en el dominio del tiempo. Dado esto, es posible decir que este tipo de análisis no es el adecuado para detectar caídas en la relación de compresión dentro del cilindro en casos incipientes. Más adelante se podrían realizar nuevas exploraciones en este tema buscando analizar cambios más drásticos para buscar un mínimo detectable.

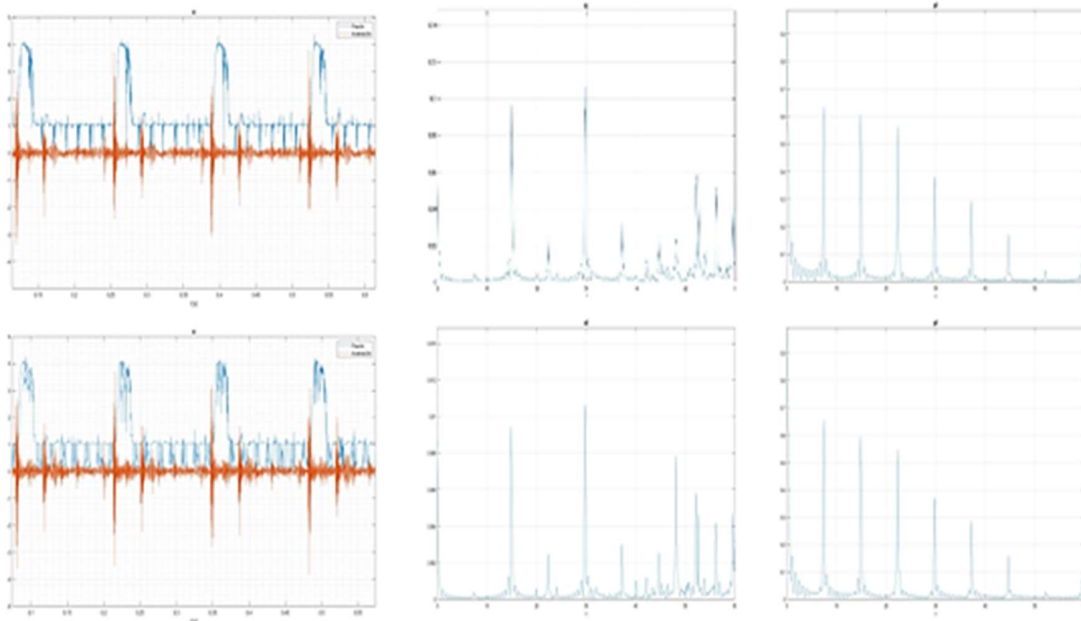


Ilustración 19. Gráficas en el dominio del tiempo y de la frecuencia de las señales de presión y aceleración de la vibración (a) superposición de temporales con RC=5.15 (b) Frecuencias en aceleración con RC= 5.15 (c) Frecuencias en presión con TC= 5.15 (d) superposición de temporales

4.4.4. Soporte de motor:

En la Ilustración 20 podemos observar lo que le sucede a las señales temporales cuando existe un desajuste en el soporte del motor. En las partes (a) y (b), como era de esperarse, no existe afectación alguna en la señal obtenida por el sensor de presión. Sin embargo, en la componente de aceleración, podemos notar que las señales presentan un comportamiento diferente, con una magnitud mayor, algo que se verificará más adelante con análisis estadísticos.

Lo observado en las señales temporales, se ve respaldado en las señales en frecuencia, en la Ilustración 21, en las partes (a) y (b), se puede determinar que la magnitud de las frecuencias en presión es similar, debido a que este tipo de daños o fallas no repercute en la admisión, pero, en la Ilustración 22, hay un cambio notable de la magnitud de la frecuencia en las componentes 1X, 2X y 4X cuando se comparan las partes (a) y (b), lo que indica que el acelerómetro está captando una perturbación en la señal. Se observa, como se esperaba, un cambio en la amplitud de la 1X, debido a un cambio en el anclaje. También se observan cambios en algunos armónicos, a los que se le harán seguimiento posteriormente.




Ilustración 20. Gráficas en el dominio del tiempo de las señales de presión y aceleración de la vibración con siembras en soporte del motor (a) superposición de temporales sin caucho (b) superposición de temporales con caucho.




Ilustración 21. Gráficas en frecuencia de las señales de presión con siembras en soporte. a) Señal en frecuencia sin caucho b) Señal en frecuencia con caucho




Ilustración 22. Gráficas en frecuencia de las señales de aceleración de la vibración con siembras en soporte. a) Señal en frecuencia sin caucho b) Señal en frecuencia con caucho

4.5. Selección de variables de alimentación

Basado en las observaciones obtenidas a partir del análisis gráfico, se determinó el uso de las siguientes variables como posibles insumos para alimentar una red neuronal que se pueda encargar de detectar los patrones que permitan identificar uno o varios de los fallos combinados.

Variables Temporales:

Valores RMS de aceleración de la vibración y de presión: Al ser un parámetro que da cuenta de la energía contenida en la vibración, se deberá ver afectado por los diferentes cambios. En las gráficas comparativas de las señales temporales se pudo observar que en cada caso se detectan cambios en las intensidades captadas por ambos sensores. Puntualmente, las señales de presión se ven más afectadas en las observaciones realizadas en las fallas de las válvulas y las señales de vibración en los casos de fallas en las válvulas y en el soporte del motor.

Valores pico de aceleración de la vibración y de presión: estos escalares nos dan una idea de la aceleración máxima que puede presentar la señal temporal. En las señales temporales se puede notar que algunos picos presentan alturas mayores en algunos de los casos, por lo que puede llegar a ser un buen factor para considerar.

Factor de cresta de aceleración de la vibración y de presión: El factor de cresta está más relacionado con la forma de la señal, así que, al presentarse perturbaciones, es interesante verificar estos cambios. Según lo observado, hay cambios claros en la forma de la señal temporal de la presión cuando se siembran fallos en las válvulas de admisión y escape, además, se plantea su uso para verificar si existe un cambio en este aspecto en la señal de aceleración.

Kurtosis de aceleración de la vibración y presión: Como se explicó anteriormente, la Kurtosis es el cuarto momento estadístico de una señal, e indica que tan concentrados están los datos respecto a una medida central. Se presenta esta característica como una posibilidad de evaluar diferencias entre las distribuciones de datos en un daño y otro.

Variables en el Dominio de la frecuencia:

Según lo observado en las diferentes gráficas generadas en el dominio de la frecuencia, se observaron cambios principalmente en las frecuencias 0.5X, 1X, 1.5X y 2.0X. Con el fin de discriminar lo ocurrido en estos puntos, se proponen filtrar la señal para obtener el cálculo del valor RMS alrededor de estas frecuencias particulares, tomando los tramos de la señal 0.2X por debajo y por encima de cada una de éstas.

Se toman entonces como posibles insumos para la red neuronal los valores RMS de las señales filtradas de presión y aceleración en los siguientes tramos:

0.3X-0.7X

0.8X-1.2X

1.3X-1.7X

1.8X-2.2X

Este valor debería verse afectado por los cambios en la magnitud de la señal y también por la posible presencia de bandas laterales, lo que quizás podría dar ciertas luces acerca de la posibilidad de detectar algunos de los fallos.

4.5.1. Análisis estadístico de variables

Con el fin de evaluar la efectividad del uso de las variables propuestas, se realiza un análisis estadístico que ayude a determinar cuáles de éstas son las más pertinentes para la detección de fallos, en esencia, cuales de estas realmente explican los fenómenos que se pueden detectar al introducir cada una de las fallas.

Para el análisis estadístico multivariado se deben tener en cuenta varias cosas:

En el proceso experimental se analizaron 4 factores en 2 niveles, de lo cual se obtuvieron 16 unidades experimentales ($2^4=16$)

Debido al proceso de ajuste que se requiere para la configuración de cada una de estas posiciones, las corridas experimentales se realizaron por bloques.

4.5.1.1. Matriz de correlación:

Inicialmente se realiza una matriz de correlación para verificar qué tan relacionadas están las variables de respuesta con los factores que se modificaron en la experimentación. Dicha matriz está codificada de la siguiente forma:

Factores:

E1: Desajuste en la válvula de admisión

E2: Desajuste en la válvula de escape

E3: Cambio en la relación de compresión en la cámara

E4: Desajuste en el soporte del motor

Variables de respuesta:

R1: RMS de la señal de aceleración de la vibración

R2: RMS de la señal de presión

R3: Valor pico de la señal de aceleración de la vibración

R4: Valor pico de la señal de presión

R5: Factor de cresta de la señal de aceleración de la vibración

R6: Factor de cresta de la señal de presión

R7: Kurtosis de la señal de aceleración de la vibración

R8 Kurtosis de la señal de presión

R9: RMS de la señal de aceleración filtrada entre 0.8X y 1.2X

R10: RMS de la señal de presión filtrada entre 0.8X y 1.2X

R11: RMS de la señal de aceleración filtrada entre 1.8X y 2.2X

R12: RMS de la señal de presión filtrada entre 1.8X y 2.2X

R13: RMS de la señal de aceleración de la vibración, filtrada entre 0.3X y 0.7X

R14: RMS de la señal de presión filtrada entre 0.3X y 0.7X

R15: RMS de la señal de aceleración de la vibración, filtrada entre 1.3X y 1.7X

R16: RMS de la señal de presión filtrada entre 1.3X y 1.7X




Ilustración 23. Matriz de correlación entre las variables de entrada y las características de respuesta

La Ilustración 23 muestra claramente que E3 (Cambio en la relación de compresión en la cámara) tiene una baja correlación con las 16 variables de respuesta. Lo que quiere decir que con la información medida es muy difícil realizar una detección de este defecto, al menos en el nivel que se evaluó. Debido a esto, se concentrará el análisis en la detección y clasificación de 3 defectos (fallo en válvula de admisión, fallo en válvula de escape y fallo en soporte), acorde al compromiso planteado en los objetivos, por lo que es posible reducir las combinaciones experimentales a solo 8 ($2^3=8$).

Las entradas propuestas para alimentar la red neuronal serán evaluadas también utilizando la prueba de Kruskal-Wallis para ver si los daños tienen efecto estadísticamente significativo en las variables de entrada a la red.

Inicialmente, se procede a hacer una reducción de los casos, de 16 a 8 posibles, para este fin, y con el fin de realizar una codificación más práctica se realizaron las siguientes etiquetas:

- 0: fallo únicamente en el soporte del motor
- 1: fallo en la válvula de admisión y el soporte del motor
- 2: fallo en válvulas de admisión y escape y en el soporte del motor
- 3: fallo en válvula de escape y en el soporte del motor
- 4: fallo en válvulas de admisión y escape
- 5: fallo únicamente en válvula de escape
- 6: posición de control, sin fallas
- 7: fallo únicamente en la válvula de admisión

4.6. Análisis de varianza (Test alternativo):

Para realizar el análisis de varianza, se tomó la información usada en la matriz de correlación y se depuró para eliminar los tipos de fallos donde estaba involucrado el cambio en la relación de compresión, con lo que se genera una matriz con las columnas desde R0 hasta R15, pertenecientes a las variables de entrada de la red y la columna RP que pertenece a las etiquetas correspondientes según lo determinado en el aparte anterior. Luego de realizar la prueba ks.test (Kolmogórov-Smirnov) se verifica que no existe normalidad en los datos, debido a esto, se opta por validar a partir de la prueba Kruskal-Wallis para determinar si las diferencias entre los grupos comparados son estadísticamente significativas.

A continuación, se presenta el resultado de las pruebas arrojado por el software RStudio®.

```
> kruskal.test(R0~RP)
```

```
kruskal-wallis rank sum test
```

```
data: R0 by RP
```

```
Kruskal-wallis chi-squared = 285.88, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R1~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R1 by RP
```

```
Kruskal-wallis chi-squared = 309.33, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R2~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R2 by RP
```

```
Kruskal-wallis chi-squared = 265.17, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R3~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R3 by RP
```

```
Kruskal-wallis chi-squared = 276.16, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R4~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R4 by RP
```

```
Kruskal-wallis chi-squared = 268.48, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R5~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R5 by RP
```

```
Kruskal-wallis chi-squared = 300.26, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R6~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R6 by RP
```

```
Kruskal-wallis chi-squared = 307.47, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R7~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R7 by RP
```

```
Kruskal-wallis chi-squared = 283.09, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R8~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R8 by RP
```

```
Kruskal-wallis chi-squared = 307.25, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R9~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R9 by RP
```

```
Kruskal-wallis chi-squared = 308.11, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R10~RP)
```

```
Kruskal-wallis rank sum test
```

```
data: R10 by RP
```

```
Kruskal-wallis chi-squared = 285.17, df = 7, p-value < 2.2e-16
```

```
> kruskal.test(R11~RP)
```

```
Kruskal-wallis rank sum test
data: R11 by RP
Kruskal-wallis chi-squared = 310.59, df = 7, p-value < 2.2e-16
> kruskal.test(R12~RP)
Kruskal-wallis rank sum test
data: R12 by RP
Kruskal-wallis chi-squared = 8.7073, df = 7, p-value = 0.2744
> kruskal.test(R13~RP)
Kruskal-wallis rank sum test
data: R13 by RP
Kruskal-wallis chi-squared = 301.15, df = 7, p-value < 2.2e-16
> kruskal.test(R14~RP)
Kruskal-wallis rank sum test
data: R14 by RP
Kruskal-wallis chi-squared = 282.41, df = 7, p-value < 2.2e-16
> kruskal.test(R15~RP)
Kruskal-wallis rank sum test
data: R15 by RP
Kruskal-wallis chi-squared = 303.39, df = 7, p-value < 2.2e-16
```

Variable	Valor P
R0	2.2 e-16
R1	2.2 e-16
R2	2.2 e-16
R3	2.2 e-16
R4	2.2 e-16
R5	2.2 e-16
R6	2.2 e-16
R7	2.2 e-16
R8	2.2 e-16
R9	2.2 e-16
R10	2.2 e-16
R11	2.2 e-16
R12	0.2744
R13	2.2 e-16
R14	2.2 e-16
R15	2.2 e-16

Tabla 10. Resultados de la prueba Kruskal-Wallis

En la Tabla 10, podemos observar que todos los valores P, excepto el de la variable R12, arrojan como resultado el número 2.2e-16, el cual es un número

usualmente usado dentro de este tipo de softwares para denotar un número demasiado pequeño (menor que 0.00000000000000022).

La prueba de Kruskal-Wallis, si bien no exige normalidad en la distribución de los datos, requiere homocedasticidad, es decir, que la varianza de los errores sea constante. Para verificar esta condición, se usa la prueba de Levene [38].

```
> leveneTest(R0~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7  9.4785 1.129e-10 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R1~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7  7.8619 8.846e-09 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R2~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7  8.9041 5.277e-10 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R3~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7  7.4767 2.522e-08 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R4~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7  6.2722 6.773e-07 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R5~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7 19.424 < 2.2e-16 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R6~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7  5.1491 1.462e-05 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R7~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7 13.194 6.71e-15 ***
```

```
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R8~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7  11.928 1.756e-13 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R9~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7   6.6555 2.373e-07 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R10~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7   2.3386 0.02438 *
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R11~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7   5.3688 8.026e-06 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R12~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7   0.8436 0.5519
312
> leveneTest(R13~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7   1.6859 0.1117
312
> leveneTest(R14~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7   6.8525 1.385e-07 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> leveneTest(R15~as.factor(RP),data=datos)
Levene's Test for Homogeneity of Variance (center = median)
      Df F value    Pr(>F)
group  7   9.0315 3.746e-10 ***
312
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
>
```

Como se había observado previamente, en la matriz de correlaciones, la variable de respuesta R13 (en este caso R12 debido a que el conteo inicia en 0), es la única que no es estadísticamente significativa para la detección de fallos. Valga aclarar, que, al no ser relevante, podría ser descartada de la red neuronal.

4.7. Red neuronal

Existen diversos factores que pueden afectar la efectividad de una red neuronal para la clasificación de fallos. Uno de los más importantes es la buena selección de los parámetros de entrada que se usan para alimentarla, dado que éstos son los que le servirán a la red para determinar cuáles son las “reglas” que le ayudarán a clasificar un comportamiento particular del sistema.

Para realizar una buena selección de parámetros se deben tener en cuenta varias cosas:

1. Se debe conocer bien el sistema y su comportamiento: comprender el efecto de las averías en las diferentes señales puede ser de gran utilidad a la hora de seleccionar los parámetros que alimentarán la red neuronal.
2. Es importante hacer un análisis exploratorio de los datos, las señales temporales y de frecuencia, esto en busca de patrones de cambio con relación a los presentados cuando el dispositivo se encuentra sin averías. Estos patrones de cambio pueden servir para proponer postprocesamientos y filtros de las señales, para garantizar características particulares que ayuden a la detección de averías.
3. Se debe verificar si el uso de factores estadísticos de índole descriptivo, tales como la media, el valor pico, el factor de cresta, la amplitud, el valor RMS, entre otros, tiene un efecto positivo en la fiabilidad de la red para la clasificación de fallos.
4. En la actualidad, uno de los métodos más usados es la extracción directa de las características desde la misma red neuronal, bien sea a partir de señales, imágenes, espectrogramas, videos, etc., permitiendo que la red determine las reglas que regirán la clasificación [39, 40].

En los apartes anteriores se realizó la selección de los parámetros, ahora, el enfoque está en el tipo de red neuronal usada para la clasificación y la arquitectura de esta con el fin de determinar si es una buena opción para la detección de este tipo de fallos.

Para el problema de clasificación de fallos se optó por una FNN (*Feedforward Neural Network*), una red neuronal perceptrón multicapa, donde cada perceptrón en una capa se conecta con cada perceptrón en la siguiente. En este tipo de redes, la información viaja en un solo sentido, desde la capa de entrada, hacia la o las capas ocultas y luego a la capa de salida, sin ningún tipo de ciclo de regreso.

La FNN, debido a este flujo de información en un solo sentido, es una red neuronal de arquitectura simple y fácil comprensión y además, es flexible a la hora de abordar problemas que no presenten linealidad en los datos, lo que le permite establecer relaciones complejas entre las variables de entrada y de salida de la red.

Este tipo de red neuronal se usa en diversos tipos de aplicaciones, tales como la compresión de información, el reconocimiento de patrones, filtrado de ruido, y la realización de pronósticos financieros.

El caso de estudio se enfoca en el reconocimiento de patrones para detectar cuando los cambios en las señales indican una falla en uno u otro sistema. Un clasificador de fallos de este tipo puede ser de gran utilidad para el diagnóstico del motor, abriendo la posibilidad de descartar o confirmar diferentes tipos de averías que indicarían si es necesario o no, realizar un desarme del motor.

Características de la red neuronal (Ilustración 24):

- Neuronas de entrada: 16

Las neuronas de entrada del sistema se refieren a las variables con las que se alimenta el sistema de clasificación, las cuales serán operadas en capas posteriores con el fin de obtener la salida esperada. Se tienen 16 neuronas en la capa de entrada, las cuales corresponden a las diferentes variables de respuesta discutidas con anterioridad en este mismo aparte.

- Capas ocultas: 1

Las capas ocultas de una red neuronal implican la cantidad de operaciones que se efectúan en las variables de entrada antes de obtener las salidas deseadas. La mayoría de los problemas que se afrontan a través de las redes neuronales, requieren solamente 1 capa oculta, sin embargo, problemas más complejos requieren más capas ocultas.

- Neuronas en la capa oculta: 8

Las neuronas en la capa oculta son los nodos de conexión entre las variables de entrada y las de salida y encargadas de aplicar las operaciones complejas no lineales a las entradas, en busca de lograr obtener, luego de pasar por la función de activación, los valores que se encuentran en la capa de salida. El número recomendado de neuronas no tiene una fórmula general, sin embargo, una de las recomendaciones es que sea un número que se encuentre entre el número de neuronas de entrada y el de neuronas de salida.

- Función de activación en la capa oculta: ReLU

ReLU es una función de activación simple y eficiente, que se encarga de introducir la no linealidad al modelo. Esta función permite que el valor pase sin modificación alguna si este es positivo, sin embargo, lo convierte en 0 si este es negativo. Es la función de activación más usada debido a que no tiene el inconveniente de la saturación que se da en otras como tanh y sigmoideal.

- Neuronas en la capa de salida: 8

Las neuronas en la capa de salida indica la cantidad de variables de salida, en este caso particular, se refiere a las 8 configuraciones de fallo mencionadas previamente.

- Función de activación en la capa de salida: Softmax

Softmax es una función de activación que se encarga de calcular las probabilidades de que el caso estudiado se trate de una u otra clase, y luego arroja como resultado la que tenga la probabilidad más alta.

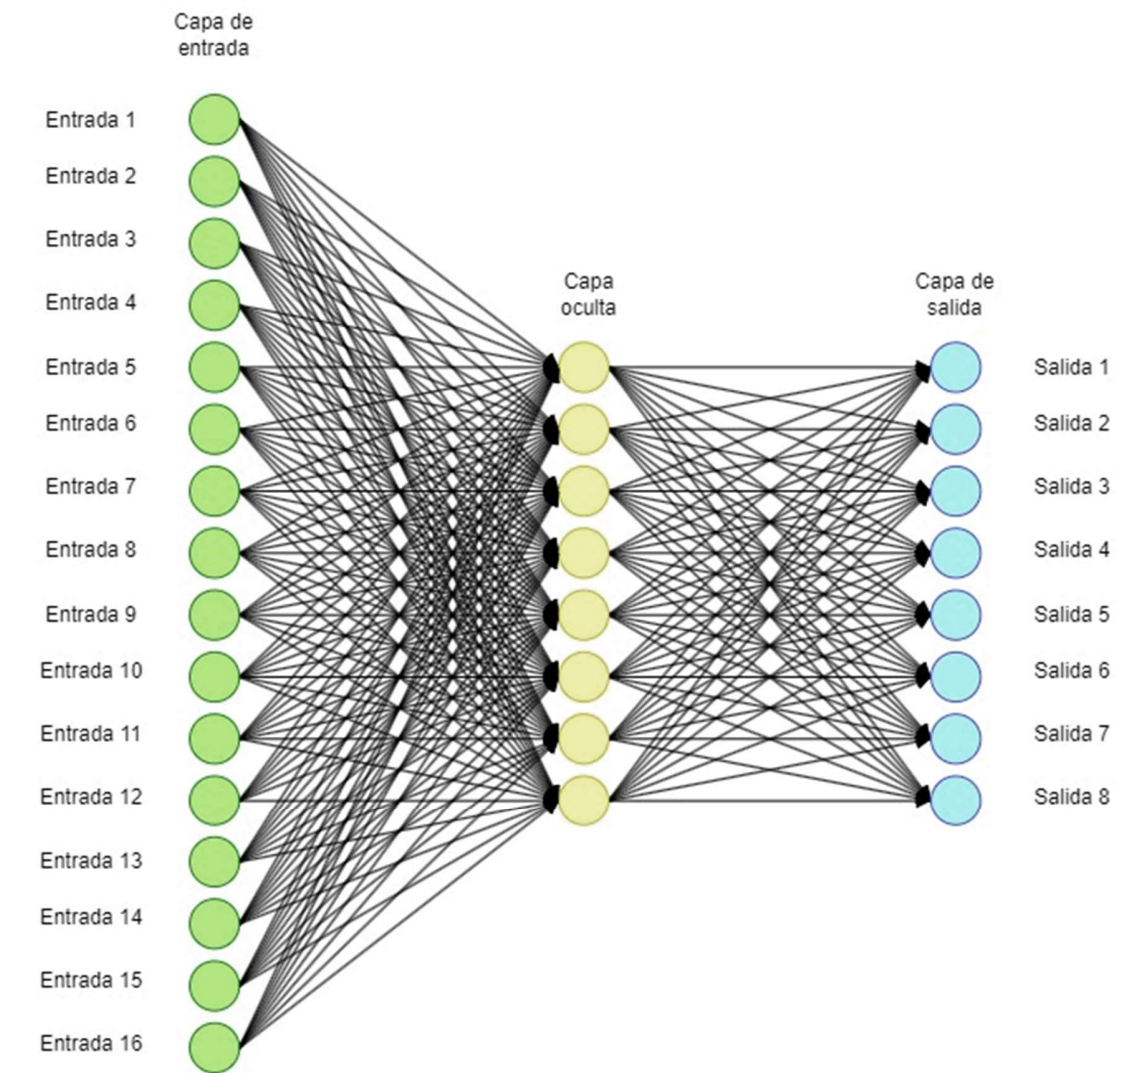


Ilustración 24. Red neuronal resultante

4.7.1. Validación de la red

4.8. Estadística

Se toma la decisión de correr el algoritmo 100 veces con el fin de determinar cuál es la media de la precisión del sistema y su desviación estándar, para darle validez al uso de la red neuronal como un clasificador confiable de las posibles combinaciones de fallas que se pueden encontrar en el motor.

El resultado arrojado por las 100 pruebas es el siguiente:

```
Prueba 100 de: 100  
0.96375  
0.04733524057190371
```

Donde 0.96375 se refiere a la precisión y 0.0473 a la desviación estándar, lo que nos indica una tasa de aciertos de la red neuronal de 96.375% y que los valores de precisión arrojados por las 100 pruebas están concentrados cerca de esta precisión.

4.9. Matriz de confusión

La efectividad de la red neuronal se puede verificar por medio de varias técnicas creadas para determinar las métricas resultantes del proceso de clasificación. Una de las más usadas es la matriz de confusión. Para obtener la matriz de confusión se usa el algoritmo que se presenta en la Ilustración 25.

En la diagonal de la matriz de confusión encontraremos los casos clasificados correctamente como verdaderos negativos y verdaderos positivos, por encima de la diagonal encontramos los falsos positivos y por debajo los falsos negativos.

+ Código + Texto

```
[ ] from sklearn.metrics import confusion_matrix as CM, ConfusionMatrixDisplay
import matplotlib.pyplot as plt

from sklearn.metrics import accuracy_score as ACC
from sklearn.metrics import precision_score as PR
from sklearn.metrics import recall_score as RC
from sklearn.metrics import f1_score as F1

# Evaluar el modelo en el conjunto de prueba
y_pred = model.predict(X_test)
y_pred_classes = np.argmax(y_pred, axis=1)

Matriz = CM(y_test, y_pred_classes)
disp = ConfusionMatrixDisplay(confusion_matrix=Matriz)
disp.plot()

print("Accuracy Bayes", ACC(y_test, y_pred_classes))
print("Precision Bayes", PR(y_test, y_pred_classes, average='macro'))
print("Recall Bayes", RC(y_test, y_pred_classes, average='macro'))
print("F1_Score Bayes", F1(y_test, y_pred_classes, average='macro'))
```

Ilustración 25. Código para generar la matriz de confusión.

En la Ilustración 26, se puede apreciar la matriz de confusión arrojada por la red neuronal, en 3 corridas diferentes que arrojaron precisiones de 0.98, 0.89 y 0.96

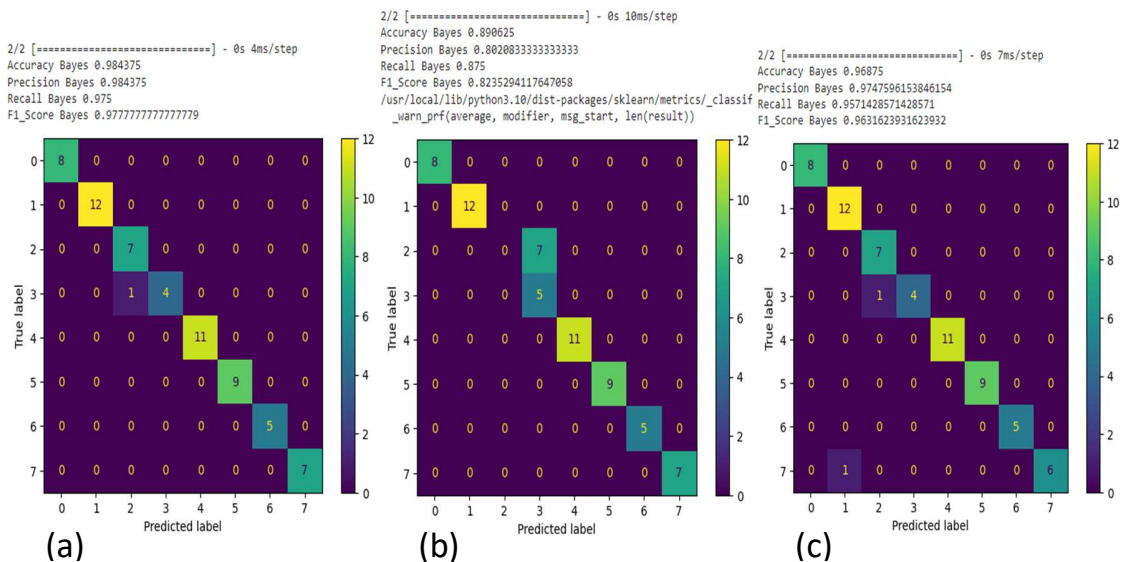


Ilustración 26. Matrices de confusión. (a) Precisión del 98% (b) Precisión del 89% (c) Precisión del 96%.

En la parte (a) se puede apreciar que la red solo tuvo un fallo en su etapa de verificación, al clasificar dentro de la clase de configuración de fallos 2 la información que realmente pertenecía a la clase 3. Esto quiere decir que debía identificar el fallo como “fallo en válvula

de escape y en el soporte del motor “, pero lo clasificó como “fallo en válvulas de admisión y escape y en el soporte del motor”. En este caso se puede concluir, que, a pesar de tener una excelente tasa de aciertos, una buena práctica consistiría en realizar otro tipo de chequeos, luego de la clasificación, para dar mayor validez a la lectura. Vale también aclarar, que, para efectos prácticos, un error como este, al final, no tiene un efecto grave en el mantenimiento del motor, debido a que al haber un diagnóstico en donde al menos una de las válvulas no está asentando bien, el motor debe ser destapado, lo que permite hacer una inspección de todo el sistema.

En la parte (b) podemos apreciar que la red tiene una confusión en la que se ven envueltas, nuevamente, las mismas clases, el sistema clasifica 7 casos dentro de la configuración de fallas del tipo 3, siendo realmente del tipo 2. En ambas clases, hay combinaciones de fallos, en los que prevalecen fallos de válvulas que implican desarme del motor. En la parte (c) podemos observar 2 desaciertos, 1 caso predicho como de clase 1, siendo clase 7, en este caso, la red clasificó como “fallo en la válvula de admisión y el soporte del motor” a un “fallo únicamente en la válvula de admisión”. En el segundo caso de mala clasificación, nuevamente predice un fallo como clase 2, siendo realmente clase 3. La tasa de clasificación correcta es muy alta. Para evitar falsas alarmas, se puede realizar un protocolo, en el que la red neuronal realice la clasificación 10 veces dentro de la prueba y si coincide al menos 6 veces el diagnóstico, se puede emitir la alarma de fallo.

5. CONCLUSIONES

El estudio de las señales de presión y vibración en el motor CFR arroja resultados interesantes que permiten la detección de algunos tipos de fallas que se pueden presentar dentro del mismo. Es posible inferir, que el tipo de relaciones encontradas dentro de este estudio, se pueden extrapolar a otros tipos de MCI, lo que tendría una aplicación bastante interesante en el área del mantenimiento.

Los análisis gráficos y de frecuencia muestran que es posible detectar los fallos en el asentamiento de válvulas y en los soportes del motor al trabajar con ambas señales, dado que se generan diferencias significativas en cada uno de los posibles casos de falla, y luego, al usar una red neuronal como clasificador, se puede lograr la automatización de este proceso.

Los análisis gráficos mostraron, en el caso de las señales superpuestas en presión y aceleración de la vibración, que era posible identificar fácilmente los instantes de cierre de válvulas y del proceso de admisión de aire al pistón cuando existe un correcto asentamiento de éstas, además, que cuando existe un mal asentamiento solamente en la válvula de admisión, se presentan señales de presión intermedias que indican que hay un proceso de succión por el espacio generado en el instante en que se debería presentar la expansión a la vez que se presenta una caída en la magnitud de la señal vibratoria que acompaña el cierre de esta válvula. En el caso de un mal asentamiento solo de la válvula de escape, se puede apreciar con claridad la caída en la magnitud de la señal de presión debido a que la cámara también está presentando una succión del lado de la apertura que se presenta en el escape, a la vez que se nota una caída significativa en la magnitud de la señal vibratoria que acompaña el cierre de esta válvula. Para terminar, en el caso de un fallo de asentamiento en ambas válvulas, se combinan los efectos, señales intermedias en presión y caída en las magnitudes de las señales vibratorias.

Los análisis en frecuencia en presión mostraron ser interesantes para identificar las fallas relacionadas con el mal asentamiento de válvulas debido a que se presentaron diferencias identificables en cada uno de los casos propuestos, esto es notable en las frecuencias 0.5X, 1X, 1.5X y 2X. Los análisis en frecuencia de las señales vibratorias mostraron potencial para la identificación de fallas en el asentamiento de válvulas debido a los cambios presentados en las señales en las frecuencias correspondientes a 0.5X, 1X, 1.5X y 2X, por otro lado, también mostraron que, para el caso de una soltura en el soporte del motor, se presentan cambios identificables en las frecuencias 1X, 2X y 4X.

A través de la matriz de correlación y de los análisis estadísticos, se pudo verificar que 15 de las 16 variables de entrada (preprocesamientos provenientes de las señales de presión en la admisión y vibración del motor) usados para alimentar la red neuronal podían aportar información valiosa para la efectividad de la red neuronal, lo cual se comprueba al observar los resultados obtenidos por ésta en la fase de verificación (test).

La red neuronal probó ser de gran utilidad para realizar la clasificación de fallos al tener un porcentaje promedio de acierto del 96.375% en la clasificación de fallos, además, a partir

CONCLUSIONES

Daniel Felipe Salazar Ramírez

de la información obtenida de las matrices de confusión, se puede notar que los pocos errores de clasificación de la red tenían que ver cuando se presentaban varios daños simultáneamente, y las combinaciones siempre tenían un daño de válvula que, implica para la reparación, el desarme del motor. Para evitar falsas alarmas, se propone realizar la prueba 10 veces consecutivas y si, el diagnóstico se repite más de 5 veces, se procede con emitir la alarma.

Es importante resaltar que estos hallazgos abren la puerta a grandes posibilidades dentro del sistema de alarmas del vehículo, debido a que no existe ningún proceso estandarizado para la detección de este tipo de fallas.

El hecho de que la red neuronal sea de tipo FNN, hace que la carga computacional para la clasificación sea de baja demanda computacional, por lo que este programa podría ser instalado sin problema en la computadora del vehículo, y, a través de algunos filtros de seguridad, basados en la repetición de alguna de las clasificaciones mencionadas anteriormente, se podría usar para generar un nuevo código de alarma en el OBD, que indique cuando ocurre alguno de estos tipos de fallo.

Como trabajo futuro, se pueden agregar entrenamientos de clasificaciones de mas daños en el motor como por ejemplo problemas en los anillos del motor, ya que aunque este problema generaría cambios en la señal de presión (similares al mal asentamiento de válvulas), la red neuronal podría clasificarlos debido a que presentaría señales vibratorias diferentes.

6. REFERENCIAS

- [1] R. Moreno, J. M. Chicharro, and P. Pintado, "Comparison of minimum detectable crack size in a geared system from three different vibration transducer types," *Exp Tech*, vol. 38, no. 1, 2014, doi: 10.1111/j.1747-1567.2011.00774.x.
- [2] K. Jafarian, M. Mobin, R. Jafari-Marandi, and E. Rabiei, "Misfire and valve clearance faults detection in the combustion engines based on a multi-sensor vibration signal monitoring," *Measurement (Lond)*, vol. 128, 2018, doi: 10.1016/j.measurement.2018.04.062.
- [3] A. Soualhi and H. Razik, "Chapter 4. Modal Decomposition for Bearing Fault Detection," in *Electrical Systems 1: From Diagnosis to Prognosis*, 2020. doi: 10.1002/9781119720317.fmatter.
- [4] M. Moreno, J. Villarraga, and R. Moreno, "Vista de Diagnóstico de fallas tempranas de rodamientos en mecanismos susceptibles al desbalanceo y a la desalineación," *Revista UIS Ingenierías*, vol. 18, no. N^o. 2 (abril-junio), pp. 187–198, 2019.
- [5] O. Garcia, "El mantenimiento general, Administración de empresas," <https://repositorio.uptc.edu.co/bitstream/handle/001/1297/RED-70.pdf;jsessionid=C8E3E8829406FBD1D54B7C2F7FF35233?sequence=1>.
- [6] P. Girdhar and C. Scheffer, *Practical Machinery Vibration Analysis and Predictive Maintenance*. 2004. doi: 10.1016/B978-0-7506-6275-8.X5000-0.
- [7] S. S. Rao, *Mechanical vibrations*. Prentice Hall, 2011.
- [8] C. M. Santana, J. E. M. Barros, and H. A. De Almeida, "Analysis of vibration and noise of an internal combustion engine by application of test and experimental analysis of the frequency spectrum," in *SAE Technical Papers*, 2013. doi: 10.4271/2013-36-0103.
- [9] V. Gómez and R. Moreno, "Clasificador neuronal de fallos en rodamientos utilizando entradas basadas en transformadas wavelet packet y de Fourier," *Revista facultad de ingeniería Universidad de Antioquia*, vol. 67, pp. 126–136, 2013.
- [10] D. Goyal and B. S. Pabla, "The Vibration Monitoring Methods and Signal Processing Techniques for Structural Health Monitoring: A Review," *Archives of Computational Methods in Engineering*, vol. 23, no. 4, pp. 585–594, Dec. 2016, doi: 10.1007/s11831-015-9145-0.
- [11] A. Dockx, "Tratamiento numérico de señales," *Ingeniería e Investigación*, vol. 4, pp. 11–18, 1986.
- [12] M. Vishwakarma, R. Purohit, V. Harshlata, and P. Rajput, "Vibration Analysis & Condition Monitoring for Rotating Machines: A Review," in *Materials Today: Proceedings*, Elsevier Ltd, 2017, pp. 2659–2664. doi: 10.1016/j.matpr.2017.02.140.
- [13] J. A. Hernández-Muriel, A. M. Álvarez-Meza, J. D. Echeverry-Correa, Á. Á. Orozco-Gutierrez, and M. A. Álvarez-López, "Feature relevance estimation for vibration-

based condition monitoring of an internal combustion engine,” *Tecnológicas*, vol. 20, no. 39, 2017, doi: 10.22430/22565337.698.

- [14] J. A. Cortés, F. A. M. A, and J. A. C. O, “Del análisis de Fourier a las wavelets análisis de Fourier,” *Scientia Et Technica*, 2007.
- [15] M. J. Spilsbury and A. Euceda, “Transformada Rápida de Fourier,” *Revista de la Escuela de Física*, vol. 4, no. 2, 2019, doi: 10.5377/ref.v4i2.8276.
- [16] F. Bi, T. Ma, and X. Wang, “Development of a novel knock characteristic detection method for gasoline engines based on wavelet-denoising and EMD decomposition,” *Mech Syst Signal Process*, vol. 117, 2019, doi: 10.1016/j.ymssp.2018.08.008.
- [17] D. Zhang, “Wavelet transform,” in *Fundamentals of Image Data Mining: Analysis, Features, Classification and Retrieval*, Springer International Publishing, 2019, pp. 35–44.
- [18] Mathworks, “Continuous and Discrete Wavelet Transforms: User’s Guide (r2020b). Recuperada Noviembre 30, 2022.” 2020.
- [19] B. M. del Brio and A. Sanz Molina, *Redes Neuronales y Sistemas Difusos*, 2a ed. Mexico, D.F.: Alfaomega grupo editores, 2002.
- [20] H. Kim, “The Definition of Convolution in Deep Learning by using Matrix,” *Journal of Engineering and Applied Sciences*, vol. 14, no. 7, 2019, doi: 10.36478/jeasci.2019.2272.2275.
- [21] E. Sánchez Camperos and A. Y. Alanís García, *Redes Neuronales, conceptos fundamentales y aplicaciones a control automático*. Madrid: Pearson-Prentice Hall, 2006.
- [22] S. Shanmuganathan, “Artificial neural network modelling: An introduction,” in *Studies in Computational Intelligence*, vol. 628, 2016. doi: 10.1007/978-3-319-28495-8_1.
- [23] M. Douglas C, *Diseño y análisis de experimentos*. 2004.
- [24] H. Gutiérrez Pulido and R. De La Vara Salazar, *Análisis y diseños de experimentos*. 2008.
- [25] J. A. Grajales, H. F. Quintero, C. A. Romero, E. Henao, J. F. López, and D. Torres, “Combustion pressure estimation method of a spark ignited combustion engine based on vibration signal processing,” *Journal of Vibroengineering*, vol. 18, no. 7, pp. 4237–4247, Nov. 2016, doi: 10.21595/jve.2016.17311.
- [26] D. Torres M, H. F. Quintero R, J. F. López L, and Á. A. Orozco G, “Monitoreo de Condición en Motores de Combustión Interna Monocilíndricos con Base en Adquisición y Procesamiento de Señales Experimentales,” *KnE Engineering*, vol. 3, no. 1, p. 736, Feb. 2018, doi: 10.18502/keg.v3i1.1477.
- [27] C. Jie and L. Si-Ran, “IC engine vibration time-frequency analysis based on a novel fast matching pursuit algorithm,” in *Proceedings of 2017 IEEE 2nd Advanced Information*

- Technology, Electronic and Automation Control Conference, IAEC 2017*, 2017. doi: 10.1109/IAEC.2017.8054414.
- [28] S. Nasiri, M. R. Khosravani, and K. Weinberg, "Fracture mechanics and mechanical fault detection by artificial intelligence methods: A review," *Engineering Failure Analysis*, vol. 81. Elsevier Ltd, pp. 270–293, Nov. 01, 2017. doi: 10.1016/j.engfailanal.2017.07.011.
- [29] J. Chen *et al.*, "Wavelet transform based on inner product in fault diagnosis of rotating machinery: A review," *Mechanical Systems and Signal Processing*, vol. 70–71. Academic Press, pp. 1–35, Mar. 01, 2016. doi: 10.1016/j.ymssp.2015.08.023.
- [30] N. Dolatabadi, S. Theodossiades, and S. J. Rothberg, "On the identification of piston slap events in internal combustion engines using tribodynamic analysis," *Mech Syst Signal Process*, vol. 58, 2015, doi: 10.1016/j.ymssp.2014.11.012.
- [31] J. Chen, R. B. Randall, and B. Peeters, "Advanced diagnostic system for piston slap faults in IC engines, based on the non-stationary characteristics of the vibration signals," *Mech Syst Signal Process*, vol. 75, pp. 434–454, Jun. 2016, doi: 10.1016/j.ymssp.2015.12.023.
- [32] J. Da Wu and C. C. Hsu, "Fault gear identification using vibration signal with discrete wavelet transform technique and fuzzy-logic inference," *Expert Syst Appl*, vol. 36, no. 2 PART 2, pp. 3785–3794, 2009, doi: 10.1016/j.eswa.2008.02.026.
- [33] J. Da Wu, C. K. Huang, Y. W. Chang, and Y. J. Shiao, "Fault diagnosis for internal combustion engines using intake manifold pressure and artificial neural network," *Expert Syst Appl*, vol. 37, no. 2, pp. 949–958, Mar. 2010, doi: 10.1016/j.eswa.2009.05.082.
- [34] H. Shi, K. Uddeen, Y. An, Y. Pei, and B. Johansson, "Statistical study on engine knock oscillation and heat release using multiple spark plugs and pressure sensors," *Fuel*, vol. 297, Aug. 2021, doi: 10.1016/j.fuel.2021.120746.
- [35] L. Haiqiang, Z. Bo, S. Jintao, and D. Qinwen, "Failure analysis of engine mounting bracket of a passenger car," *Eng Fail Anal*, vol. 136, Jun. 2022, doi: 10.1016/j.engfailanal.2022.106190.
- [36] C. Huang *et al.*, "Monitoring of valve gap in diesel engine based on vibration response feature extraction," *Sensors and Materials*, vol. 33, no. 7, pp. 2365–2383, Jul. 2021, doi: 10.18494/SAM.2021.3289.
- [37] I. Komorska and Z. Wólczyński, "Fault diagnostics of air intake system of the internal combustion engine," in *Applied Condition Monitoring*, vol. 10, Springer, 2018, pp. 91–100. doi: 10.1007/978-3-319-62042-8_8.
- [38] T. Van Hecke, "Power study of anova versus Kruskal-Wallis test," *Journal of Statistics and Management Systems*, vol. 15, no. 2–3, pp. 241–247, May 2012, doi: 10.1080/09720510.2012.10701623.

CONCLUSIONES

Daniel Felipe Salazar Ramírez

- [39] D. Rubén Ruiz González, “Análisis de vibraciones mecánicas mediante un clasificador basado en SVM para el mantenimiento predictivo de máquinas: aplicación en una cosechadora agrícola.,” UNIVERSIDAD DE VALLADOLID ESCUELA TÉCNICA SUPERIOR DE INGENIEROS DE TELECOMUNICACIÓN, Valladolid, 2014.
- [40] Á. H. Rangel Rodríguez, “Análisis tiempo-frecuencia de vibraciones y redes neuronales convolucionales para detectar daño en aerogeneradores de baja potencia,” Universidad Autónoma de Querétaro, 2022.