

# ESTIMACIÓN DE LA CURVA DE PRESIÓN EN LA CÁMARA DE COMBUSTIÓN DE MCI MONOCILÍNDRICOS A PARTIR DEL ANÁLISIS DE VIBRACIONES

**Daniela Torres M.<sup>1</sup>, José A. Hernández-Muriel<sup>2</sup>,  
Andrés M. Álvarez M.<sup>3</sup>, Héctor F. Quintero<sup>4</sup>, Álvaro A. Orozco<sup>5</sup>**

1-Facultad de Ingeniería Mecánica, Universidad Tecnológica de Pereira,  
Carrera 27 No. 10-02, Pereira, Colombia.  
dantorres@utp.edu.co

2-Facultad de Ingeniería, Universidad Tecnológica de Pereira,  
Carrera 27 No. 10-02, Pereira, Colombia.  
j.hernandezm12@utp.edu.co

3-Facultad de Ingeniería, Universidad Tecnológica de Pereira,  
Carrera 27 No. 10-02, Pereira, Colombia.  
andres.alvarez1@utp.edu.co

4-Facultad de Ingeniería Mecánica, Universidad Tecnológica de Pereira,  
Carrera 27 No. 10-02, Pereira, Colombia.  
hquinte@utp.edu.co

5-Facultad de Ingenierías, Universidad Tecnológica de Pereira,  
Carrera 27 No. 10-02, Pereira, Colombia.  
aaog@utp.edu.co

**Palabras clave:** Motores de combustión interna, análisis de vibraciones, representación tiempo-frecuencia, curva de presión en motores.

## Resumen

En este artículo se diseña e implementa un sistema para la estimación de la curva de presión en la cámara de combustión en un MCI mediante el análisis de las vibraciones mecánicas provenientes del bloque del motor. Para la generación de la base de datos, se capturaron tres tipos de señales: Vibración en el bloque, velocidad de rotación del cigüeñal y presión en la cámara de combustión (como referencia). Se evaluó el motor trabajando con gasolina a diferentes regímenes de velocidad (1100, 1500, 2000 y 2500 rpm) en condiciones normales. Las señales de vibración fueron caracterizadas mediante el uso de transformadas rápidas de Fourier (FFT) y transformadas en tiempo corto de Fourier (STFT). Para estimar la curva de presión, se hizo uso de regresión rígida con Kernel utilizando una función gaussiana. Se valida la estimación de la curva de presión comparándola con la curva obtenida por medio del sensor de presión. Se utilizó una validación cruzada para medir la precisión del sistema. Los resultados demostraron que la estimación de la curva de presión en la cámara de combustión es apropiada, cuando el MCI trabaja a diferentes velocidades en condiciones normales de operación.

## 1. Introducción

En la actualidad, los motores de combustión interna (MCI) juegan un papel muy importante en el mundo, ya que su uso se ha llevado a muchos campos de acción, ejemplos claros de ello son la industria y el transporte de pasajeros. Los sistemas para el diagnóstico de fallos

en este tipo de mecanismos permiten identificar deficiencias en etapas iniciales, que de no ser tratadas a tiempo, pueden disminuir notablemente la potencia del motor, provocando como contraprestación, desde el aumento en el consumo de combustible hasta daño irreparable del mismo [1, 2]. Además, la complejidad intrínseca de los MCI, junto con la enorme cantidad de equipos conectados a ellos, hace que su mantenimiento sea difícil [1]. Es por ello que ha surgido la necesidad de desarrollar métodos de diagnóstico eficaces, con la capacidad de advertir al operador en cuanto los primeros signos de mal funcionamiento comienzan a aparecer, de modo que puedan tomarse medidas correctivas [3]. Por lo tanto, el monitoreo de condición de los equipos industriales en general, y de los motores en particular, es muy importante para garantizar la productividad, la seguridad y la reducción de costos de mantenimiento en las instalaciones industriales y sistemas de transporte.

Desde los inicios de los motores térmicos, el estudio de la presión en la cámara de combustión ha sido una herramienta importante para el monitoreo de su condición, la cual se considera una fuente valiosa de información durante las etapas de desarrollo y calibración del motor [4], sirve para analizar su rendimiento [5] y es uno de los parámetros más importantes para la evaluación de la calidad de la combustión [6 – 8], por lo cual ha sido objeto de estudio desde la invención del MCI, siendo una de las herramientas principales de diagnóstico para los investigadores [9]. La caracterización de esta curva se puede dar mediante dos técnicas diferentes: intrusivas y no intrusivas. Las intrusivas consisten en la implementación de sensores de presión que deben ser ubicados en la cámara de combustión, lo que representa una serie de limitaciones [10], tanto por las características que debe poseer el sensor para soportar el medio agresivo en el cual va a ser instalado, como por el acondicionamiento que debe hacerse para la ubicación del mismo, lo que incurre en altos costos y difícil instalación [7]. Las técnicas no intrusivas consisten en estimar la curva de presión mediante el análisis de señales que puedan adquirirse con mayor facilidad, por ejemplo, vibración en el bloque del motor, sonidos emitidos, variaciones en la velocidad del cigüeñal, entre otros.

En las últimas dos décadas, se han propuesto un gran número de nuevos métodos para la detección y el diagnóstico de fallas basados en técnicas no intrusivas, y se han obtenido resultados interesantes de investigación [10 – 12], que promueven en gran medida el desarrollo de la tecnología de diagnóstico de fallas de máquinas [14]. Uno de los métodos más comunes y prometedores es el análisis de vibración que se utiliza de manera efectiva en el diagnóstico de fallas de MCI [10, 13 – 15], ya que las señales de vibración ofrecen información dinámica sobre el estado mecánico del sistema [12]. Considerando que la curva de presión en la cámara de combustión de motores se puede reconstruir a partir de estas señales, resulta conveniente y oportuna la implementación de metodologías que contribuyan al diagnóstico de fallas y al mantenimiento basado en la condición, utilizando técnicas no intrusivas, para la caracterización y análisis de la curva de presión en la cámara de combustión, con el fin de reducir costos de mantenimiento en motores, involucrando mejoras en su eficiencia y control del consumo de combustible.

En el presente artículo se diseña e implementa un sistema para la estimación automática de la curva de presión en la cámara de combustión en un MCI mediante el análisis de las vibraciones mecánicas provenientes del bloque del motor. En la sección 2 se describen los métodos utilizados para el análisis y caracterización de las señales de vibración capturadas por el acelerómetro ubicado en el bloque del motor en estudio y las técnicas

implementadas para la reconstrucción de la presión a partir de las señales de vibración. En la sección 3 se especifica la instrumentación utilizada para la generación de las bases de datos y el procedimiento tenido en cuenta en los experimentos. En la sección 4 se detallan los resultados obtenidos en la investigación y su respectiva discusión. Finalmente, en la sección 5 se describen las conclusiones obtenidas a partir del estudio realizado.

## **2. Materiales y métodos**

Para la realización de las pruebas inmersas al interior de este artículo, fue necesario conjugar un conocimiento interdisciplinario que abarca tres áreas específicas: motores, procesamiento de señales y modelado estadístico. A continuación se mencionan los conceptos utilizados:

### **2.1. Caracterización de la presión en la cámara de combustión**

La cámara de combustión se encuentra en la parte superior del cilindro y es fundamental para el funcionamiento de MCI, ya que es el lugar en donde se da la ignición, además, debe concentrar completamente la fuerza explosiva de la gasolina que se quema en la cabeza del pistón, en el caso de motores de encendido por chispa. Dado esto, la caracterización de la presión en la cámara es un parámetro importante para conocer el comportamiento de la combustión del motor [8]. Es decir, el estudio de la curva característica de presión puede indicar la existencia de fallas en el funcionamiento del motor [17], es por ello que representa gran importancia en el momento de hacer un análisis del rendimiento y la eficiencia en la combustión de motores térmicos [5 – 7], lo cual la hace una herramienta clave para la investigación y el diagnóstico de los mismos [9].

Como ya se había mencionado, se pueden aplicar dos técnicas diferentes para conocer la variación de la presión en la cámara: intrusivas y no intrusivas. Las intrusivas consisten en la implementación de sensores de presión que deben ser ubicados en la cámara de combustión y las técnicas no intrusivas consisten en estimar la curva de presión mediante el análisis de señales que puedan adquirirse con mayor facilidad, por ejemplo, vibración en el bloque del motor, sonidos emitidos, variaciones en la velocidad del cigüeñal, entre otros. Las no invasivas ofrecen ventajas sobre las intrusivas: los sensores se colocan en el exterior del motor, por lo que no se requieren modificaciones estructurales en el mismo. Por otra parte, no se necesitan sensores que resistan altas presiones y temperaturas; por lo que las técnicas no intrusivas representan menores costos de implementación.

Una estrategia no intrusiva para conocer el comportamiento de la presión en la cámara de combustión consiste en medir las vibraciones mecánicas provenientes del bloque del motor, ya que las vibraciones en el bloque son producto del funcionamiento del motor y de la combustión que se da dentro de la cámara. Investigaciones anteriores han demostrado que un procesamiento adecuado de las señales de vibración puede ser efectivo para reconstruir la curva de presión en la cámara de combustión de motores de manera parcial o total [17]. La Figura 1 muestra la relación existente entre las vibraciones y la presión en la cámara, caracterizadas por las líneas azul y roja, respectivamente. En la figura, el punto 1 indica el cierre de válvulas de escape, el 2 el cierre de válvulas de admisión de combustible, el 3 la combustión y el 4 el escape de los gases.

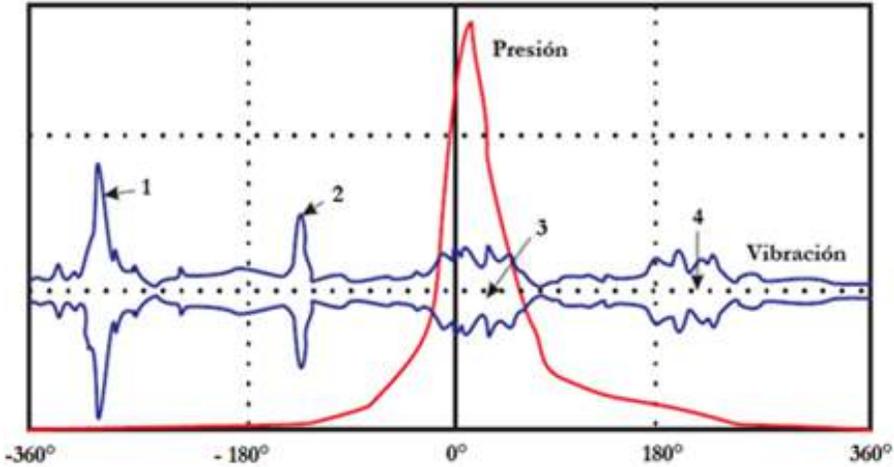


Figura 1. Relación entre las vibraciones y la curva de presión.

## 2.2. Curva de presión en la cámara de combustión vs ángulo del cigüeñal ( $p - \varphi$ )

El diagrama  $p - \varphi$  caracteriza la variación de la presión en la cámara de combustión (eje de ordenadas) en relación a la posición de giro del cigüeñal (eje de la abscisa) durante el desarrollo de un ciclo completo, como se observa en la Figura 2. Permite identificar el punto máximo de presión, es decir, el ángulo del cigüeñal para el cual se da la presión máxima al interior de la cámara, y las etapas del ciclo.

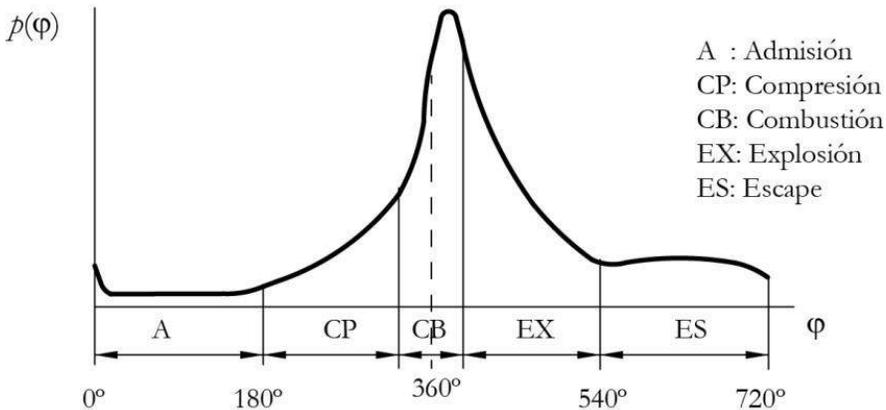


Figura 2. Diagrama  $p - \varphi$  de un MCI de 4 tiempos. Fuente: Adaptada de [18].

## 2.3. Técnicas para la caracterización de las señales de vibración

### 2.3.1. Transformada de Fourier (FT)

La Transformada de Fourier, es una técnica muy utilizada en el análisis de señales. Permite transformar señales entre el dominio del tiempo y el dominio de la frecuencia, su base matemática consiste en la descomposición de una señal en un conjunto de componentes de frecuencia única.

La FT tiene un inconveniente, una vez realizada una transformación del dominio temporal al dominio de la frecuencia, no es posible identificar los instantes de tiempo en el cual ocurren los diferentes cambios de la señal. Por esto, esta descomposición es útil para señales estacionarias (señales cuyo contenido espectral no cambian a lo largo del tiempo).

Para realizar un análisis de este tipo, se debe partir de la base de que toda señal genérica, se puede descomponer en una suma de funciones periódicas simples de diferente frecuencia. Así pues, la TF se define como:

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad \text{Ec. 1}$$

En general,  $x(t)$  es una señal continua en el tiempo y  $X(f)$  es una función compleja que representa a la señal en el dominio de la frecuencia [19].

### 2.3.2. Transformada Discreta de Fourier (DFT)

La TF es una herramienta muy útil cuando se trabaja con modelos matemáticos, pero en la vida real, las señales a analizar son señales obtenidas de forma digital, lo cual implica que dichas señales pueden ser una serie de datos finitos y discretos. Para este tipo de análisis, es de vital importancia conocer la frecuencia máxima contenida al interior de la señal para la selección de la frecuencia de muestreo, la cual debe ser como mínimo dos veces dicha frecuencia (Según el teorema de Nyquist).

La DFT viene dada por:

$$X(k) = \sum_{n=0}^{N-1} x[n]e^{-\frac{j2\pi kn}{N}} \quad \text{Ec. 2}$$

Donde  $N$  es el número total de muestras de la señal discreta  $x[n]$ ,  $n$  toma valores discretos en el intervalo  $[0, N - 1]$  y  $X[k]$  es una aproximación al espectro de la señal analógica original [20].

### 2.3.3. Transformada Rápida de Fourier (FFT)

La FFT es una herramienta muy utilizada en el procesamiento digital de señales. Básicamente, esta técnica es un algoritmo que tiene como objetivo calcular la DFT. Su gran importancia, radica en el hecho que el algoritmo elimina una gran parte de los cálculos repetitivos que se pueden encontrar al momento de determinar una DFT, logrando una disminución considerable en el tiempo de cómputo [21].

### 2.3.4. Transformada de Fourier de Tiempo Corto (STFT)

La STFT toma la señal en el dominio del tiempo, la divide en pequeños segmentos y posteriormente, calcula la FT de cada segmento por separado; de esta forma, se logra una representación en tiempo-frecuencia de la señal, que permite conocer no sólo el valor de sus componentes en frecuencia, sino también su ubicación temporal. El inconveniente de esta técnica, se encuentra en que sólo puede obtenerse información de este tipo con una exactitud limitada por el ancho de la ventana temporal utilizada para el análisis.

La STFT se define como:

$$X_m(f) = \sum_{n=-\infty}^{\infty} x[n]w[n - mR]e^{-j2\pi f n} \quad \text{Ec. 3}$$

Donde  $w[n - mR]$  es una ventana temporal de tamaño  $m$ ,  $R$  es el largo de los saltos entre DFTs sucesivas.

### 2.4. Regresión Rígida con Kernel

Los procesos de regresión son muy utilizados en múltiples áreas del conocimiento, básicamente son métodos para analizar la relación o dependencia que hay entre un conjunto de variables estudiadas, para posteriormente, estimar un conjunto de ellas a partir de un conjunto inicial dado. Para el caso de la regresión rígida, la tarea es encontrar una función lineal que modele la dependencia entre las covariancias  $\{x_i\}$  y las variables a estimar  $\{y_i\}$ . El camino clásico para ello, es minimizar una función cuadrática de costo,

$$C(\mathbf{w}) = \frac{1}{2} \sum_i (y_i - \mathbf{w}^T x_i)^2 \quad \text{Ec. 4}$$

Sin embargo, el objetivo de este trabajo es realizar este análisis desde el espacio de características extraídas, en este caso, sólo basta con realizar un cambio en la ecuación ( $x_i \rightarrow \Phi(x_i)$ ), el peligro de realizar este cambio, se encuentra en la posibilidad de sobreajustarse.

Para disminuir este riesgo, se adiciona un parámetro para regularizar la norma de  $\mathbf{w}$ , lo cual se conoce como decaimiento de peso.

$$C(\mathbf{w}) = \frac{1}{2} \sum_i (y_i - \mathbf{w}^T \Phi(x_i))^2 + \frac{1}{2} \lambda \|\mathbf{w}\|^2 \quad \text{Ec. 5}$$

Ahora, sólo queda por determinar cómo elegir el parámetro  $\lambda$ . El algoritmo más utilizado para realizar este proceso se llama correlación cruzada.

Si se reemplaza todos los posibles casos por su vector de características:  $x_i \rightarrow \Phi_i = \Phi(x_i)$ . El número de dimensiones a evaluar será muchísimo mayor. Existe un truco para mejorar el rendimiento al momento del cálculo, para tal fin, se realiza el siguiente procedimiento:

Se define  $\Phi = \Phi_{ai}$  e  $y = y_i$ . La solución está dada entonces por:

$$w = (\lambda I_d + \Phi\Phi^T)^{-1}\Phi y = \Phi(\Phi^T\Phi + \lambda I_n)^{-1}y \quad \text{Ec. 6}$$

Esta ecuación puede ser reescrita como:

$$w = \sum_i \alpha_i \Phi(x_i) \quad \text{Ec. 7}$$

Donde  $\alpha_i = (\Phi^T\Phi + \lambda I_n)^{-1}y$ . La solución  $w$  siempre debe recaer en el rango de todos los posibles casos de los datos, incluso si la dimensionalidad del espacio de características es mucho mayor. Esto es intuitivamente claro, si se tiene en cuenta que el algoritmo es lineal en el espacio de características [22].

### 3. Experimentos

#### 3.1. Base de datos

Para la obtención de los resultados acá condensados, fue necesaria la adquisición de una base de datos a partir de las señales generadas por un MCI monocilindrico Robin EY15, cuyas características se muestran en la Tabla 1, el cual está ubicado en un banco de pruebas al interior del laboratorio de Motores de la Universidad Tecnológica de Pereira. Dicha base de datos cuenta con una gran variedad de señales, de las cuales se utilizan las siguientes: vibración del bloque del motor, presión en la cámara de combustión y velocidad angular del cigüeñal. En la Figura 1 se presenta el banco de pruebas experimental utilizado para la realización de este estudio.

Tabla 1. Características del motor Robin EY15.

<b>Robin EY 15</b>	
Tipo	Motor de gasolina, monocilindrico, refrigerado por aire , 4 tiempos
Rango de velocidad	0 – 3600 rpm
Máxima potencia	2.0 kW
Diámetro x Carrera	63 x 46 mm
Cilindrada	143 cm <sup>3</sup>
Relación de compresión	6.3



Figura 3. Montaje experimental.

Para la instrumentación del banco de pruebas, se utilizaron tres elementos importantes: un arreglo de sensores debidamente sincronizados para la adquisición de cada una de las señales anteriormente mencionadas y dos tarjetas de adquisición de datos (NI 9222) que funcionaron bajo una frecuencia de muestreo de 65 kHz, montadas sobre un chasis (NIcDAQ 9178). De manera específica, los sensores utilizados fueron: un acelerómetro (100 mV/g) ubicado en la parte superior del bloque del motor en dirección vertical, un sensor de presión (0,74 mV/psi) que a su vez funciona como bujía del motor y un sensor inductivo combinado con una rueda fónica de 60 dientes ubicado sobre el eje de rotación del cigüeñal.

Se realizaron 4 experimentos con 10 repeticiones cada uno, para la obtención final de más de 5000 ciclos de combustión. Cada una de las pruebas realizadas sobre el MCI monocilindrico Robin EY15 funcionando con combustión en estado normal y sometido a una carga constante tuvo una ventana temporal de captura de 5 segundos. Las velocidades a las cuales se capturaron las señales fueron de 1100, 1500, 2000 y 2500 rpm respectivamente para cada experimento.

### 3.2. Caracterización de las señales de vibración

Como se ha mencionado anteriormente, el objetivo es realizar una estimación de la curva de presión del motor, para tal fin, se utiliza regresión rígida con kernel gaussiano a partir del conjunto de características extraídas de la señal de vibración en el bloque para reconstruir la curva de presión en el motor.

Inicialmente, se utiliza la FFT para extraer el espectro en frecuencia de la señal en cuestión y a partir de allí observar su contenido espectral teniendo en cuenta que la frecuencia de muestreo para realizar el análisis es de 65 kHz. Posteriormente, se utiliza el método de caracterización de STFT. Como se mencionó anteriormente, esta técnica consiste en analizar la señal en ventanas de tiempo y seguidamente, extraer la FFT para cada una de las ventanas de análisis. Se implementó una ventana de Hamming con traslape al 50%. El tamaño elegido varía dependiendo del número de divisiones deseadas en la señal de vibración, teniendo en cuenta que para ventanas de tiempo con un tamaño menor a 20 muestras, el análisis deja de ser estacionario. Finalmente, se compara el resultado obtenido de cada una de las caracterizaciones teniendo en cuenta los objetivos establecidos.

### 3.3. Implementación del método de estimación

El método de estimación propuesto es la regresión rígida con kernel gaussiano, en donde la entrada es el conjunto de características de la señal de vibración, es decir, el conjunto de datos obtenidos después de aplicar la FFT y la STFT de cada señal.

Teniendo en cuenta la información que se obtiene en el tiempo para cada método de caracterización, es posible estimar ya sea el área bajo la curva  $P - \varphi$  o el valor aproximado de eficiencia (Para el caso de la FFT) o una secuencia de puntos (uno por cada ventana de análisis en la STFT) con las cuales es posible reconstruir la curva de presión y a partir de allí, realizar todo el análisis mecánico anteriormente mencionado.

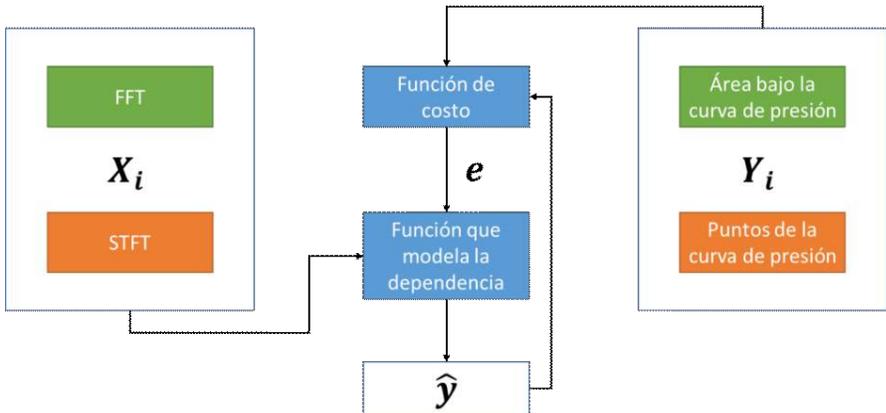


Figura 4. Metodología propuesta para la estimación de parámetros utilizando regresión rígida con kernel gaussiano.

La Figura 4 muestra las metodologías a implementar, la primera de ellas, consiste en estimar el valor del área bajo la curva  $P - \varphi$  a partir de la FFT aplicada sobre la señal de vibración (recuadros de color verde) y la segunda, en estimar puntos de la curva de presión tomando como referencia la caracterización mediante STFT (recuadro de color naranja).

La base de datos cuenta con más de 5000 ciclos de combustión debidamente segmentados. Para entrenar el sistema, se utiliza validación cruzada con un 70% del total de las muestras. El 30% restante, es empleado para medir la precisión de la estimación calculada.

## 4. Resultados y discusión

### 4.1. Procesamiento de datos

Las señales utilizadas al interior de este artículo fueron: Señal de vibración en el bloque del motor, señal de presión al interior de la cámara de combustión (como referencia) y la señal de velocidad en el cigüeñal. La Figura 5 muestra las señales dentro de un pequeño intervalo de tiempo.

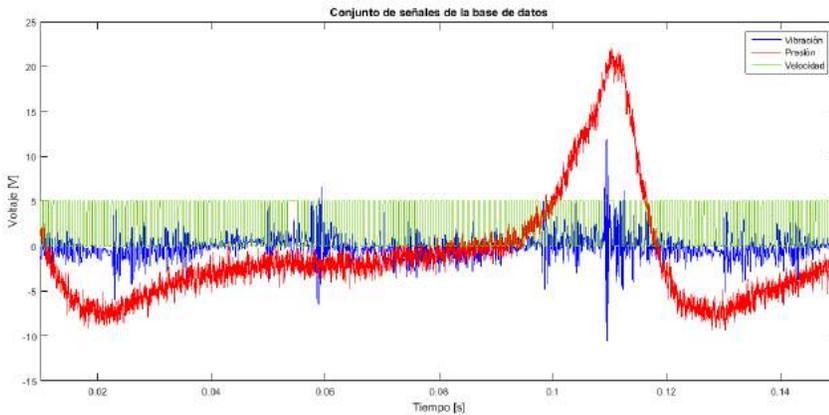


Figura 5. Conjunto de señales de conforman la base de datos capturada vista en un pequeño intervalo de tiempo.

En la Figura 5 se visualizan las tres señales utilizadas durante la realización de las pruebas. La señal de color azul, corresponde a la señal de vibración en el bloque del motor. La señal de color verde es la señal de velocidad capturada por el sensor inductivo en conjunto con la rueda fónica. La señal de color rojo representa la presión al interior de la cámara de combustión.

### 4.2. Caracterización de las señales de vibración

Inicialmente, se caracterizó la señal de vibración utilizando FFT, el resultado obtenido es el espectro en frecuencia de dicha señal. En la Figura 6 se puede observar una alta conglomeración de contenido espectral en la banda de frecuencias inferiores a 8000 Hz.

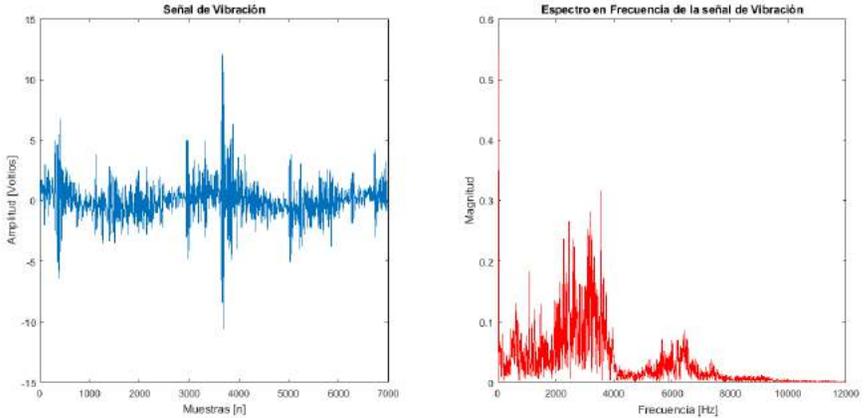


Figura 6. Caracterización de la señal de vibración utilizando FFT.  
*Señal en color azul:* Señal de vibración para un ciclo de combustión.  
*Señal roja:* Espectro en frecuencia para la señal de vibración de la izquierda.

El segundo método de caracterización fue la STFT, la Figura 7 muestra un resultado para la señal de vibración anterior dividida 10 veces, lo cual da como resultado un total de 19 ventanas de análisis (de acuerdo con el traslape del 50%). Las zonas más amarillas, representan las frecuencias para las cuales se encuentra la mayor concentración espectral para la ventana temporal analizada, dicho color se degrada hasta llegar al color azul oscuro. De igual manera, se observa un comportamiento muy similar al caso anterior, el mayor contenido espectral se encuentra para las frecuencias inferiores a 8 kHz.

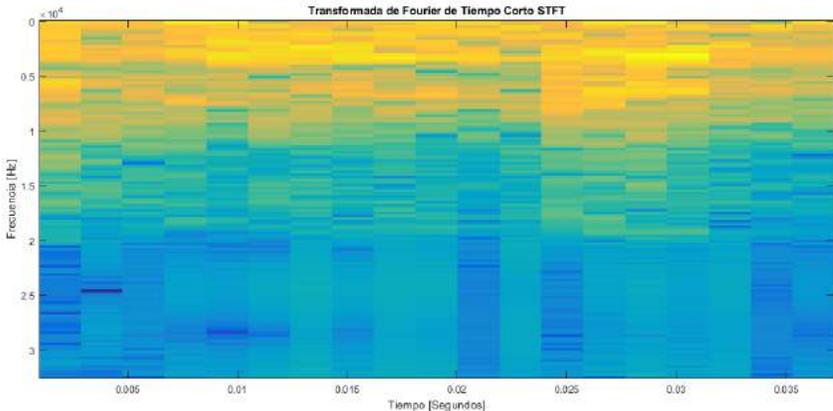


Figura 7. Caracterización de la señal de vibración utilizando STFT, la señal de vibración se dividió 10 veces, es decir, un total de 19 ventanas de análisis.

### 4.3. Implementación del método de estimación propuesto

La Figura 8 muestra el resultado obtenido al estimar un total de 59 puntos de la curva de presión, aplicando regresión rígida con kernel gaussiano, a partir de una STFT con 30 divisiones.

La señal coloreada de azul representa la curva obtenida con el sensor de presión y la coloreada de verde es la señal que se desea seguir. Los círculos de color rojo corresponden a los puntos estimados mediante la regresión.

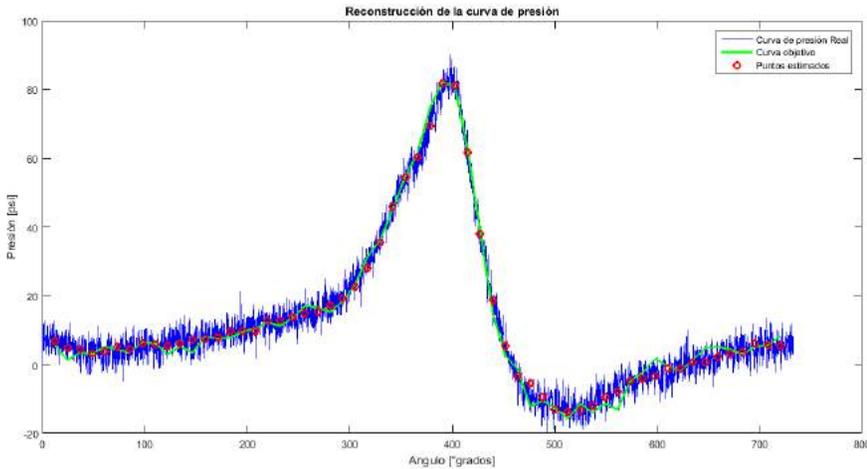


Figura 8. Resultado obtenido al estimar un total de 59 puntos de la curva de presión a partir de una STFT con 30 divisiones.  
 Señal coloreada de azul: Señal de presión.  
 Señal coloreada de verde: Señal que se desea seguir.  
 Puntos de color Rojo: puntos estimados.

La regresión se implementó para señales de vibración capturadas a 1100, 1500, 2000 y 2500 rpm, estimando de 29 a 59 puntos pertenecientes a la curva de presión para cada una de las velocidades.

En la Tabla 6 se puede observar la precisión obtenida para cada caso. Los resultados muestran que la curva de presión puede ser reconstruida con buena exactitud.

Tabla 2. Precisión de la estimación de puntos de la curva utilizando Regresión rígida con kernel gaussiano para cada caso.

Velocidad	Número de puntos	Precisión
1100 rpm	29	98.01±0.05
	39	98.16±0.03
	49	98.49±0.02
	59	98.70±0.06
1500 rpm	29	98.98±0.04
	39	98.13±0.02
	49	98.48±0.02
	59	98.55±0.04
2000 rpm	29	97.94±0.05
	39	98.09±0.04
	49	98.40±0.04
	59	98.57±0.02
2500 rpm	29	97.85±0.03
	39	98.04±0.07
	49	98.39±0.03
	59	98.40±0.02

## 5. Conclusiones

La curva de presión en la cámara de combustión de MCI monocilíndricos se reconoce como un parámetro importante para analizar el estado de los motores, es decir, para controlar su funcionamiento con fines de diagnóstico. A pesar de su relevancia, su aplicación se ha inhibido por la dificultad de medir la presión en la cámara, por lo cual, las técnicas no intrusivas para la caracterización de esta variable toman cada vez más importancia.

Fue posible cumplir el objetivo principal del presente estudio: se desarrolló una metodología de estimación de la curva de presión en la cámara de combustión de un motor monocilíndrico trabajando con gasolina, a diferentes velocidades y en condiciones normales de operación, a partir de las vibraciones mecánicas provenientes del bloque. Se caracterizaron las señales de vibración utilizando FFT y STFT, a partir de lo cual se reconstruyó, con una buena precisión, la curva de presión en la cámara de combustión aplicando una regresión rígida con kernel utilizando una función gaussiana. El modelo propuesto puede ser utilizado como una herramienta de diagnóstico no invasiva para la evaluación de la presión en la cámara y la calidad de combustión del motor.

## 6. Trabajo futuro

Como trabajo futuro, se pretende incorporar otro tipo de caracterización de las señales de vibración, utilizando Wavelets y Máquinas de Soporte Vectorial (para realizar una clasificación entre los diferentes estados del motor). Así mismo, se considera de gran importancia explorar la estimación de la eficiencia de la combustión en MCI, a partir de la curva de presión en la cámara de combustión contra volumen específico, con el fin de desarrollar un sistema de diagnóstico aplicado a los sistemas de transporte público masivo.

## 7. Agradecimientos

Los autores agradecen a COLCIENCIAS por el apoyo al proyecto titulado: "Diseño y desarrollo de un sistema prototipo en línea para el diagnóstico de motores de combustión interna diésel en servicio con base en vibraciones mecánicas. Aplicación a los sistemas de transporte público masivo" con código 1110-669-46074, por medio del cual se desarrolló la investigación descrita en el presente artículo. Adicionalmente, se quiere agradecer a las Maestrías en Ingeniería Eléctrica e Ingeniería Mecánica de la Universidad Tecnológica de Pereira por su apoyo a lo largo de la investigación. Adicionalmente, se agradece al Laboratorio de Motores del Programa de Ingeniería Mecánica por la ayuda y asesoramiento en relación con las máquinas de combustión interna y la construcción de la base de datos mencionada al interior de este artículo.

## 8. Referencias

- [1] J. Porteiro, J. Collazo, D. Patiño, y J. L. Miguez, «Diesel engine condition monitoring using a multi-net neural network system with nonintrusive sensors», *Applied Thermal Engineering*, vol. 31, n.º 17-18, pp. 4097-4105, 2011.
- [2] J. A. Grajales Herrera, J. F. López López, y H. F. Quintero, «Diagnostic method based on the analysis of vibration and acoustic emissions for internal combustion engines faults», en *Image, Signal Processing and Artificial Vision (STSIVA), 2014 XIX Symposium on. IEEE*, 2014.
- [3] G. O. Chandroth, A. J. C. Sharkey, y N. E. Sharkey, «Cylinder pressures and vibration in internal combustion engine condition monitoring», *Proceedings of Comadem*, vol. 99, n.º V, pp. 294-297, 1999.
- [4] F. Payri, J. M. Luján, J. Martín, y A. Abbad, «Digital signal processing of in-cylinder pressure for combustion diagnosis of internal combustion engines», *Mechanical Systems and Signal Processing*, vol. 24, n.º 6, pp. 1767-1784, 2010.
- [5] H. Hamedovic, F. Raichle, y J. F. Böhme, «In-cylinder pressure reconstruction for multicylinder SI-engine by combined processing of engine speed and one cylinder pressure», en *International Conference on Acoustics, Speech and Signal Processing (ICASSP 2005)*, 2005, vol. 0, n.º 4, pp. 677-680.
- [6] G. V. Zurita y J. C. Peña, «Vibration based reconstruction of the cylinder pressure in diesel engines by using neural networks», *Investigación y desarrollo*, vol. 60, n.º 5, pp. 53-60, 2005.
- [7] S. Saraswati y S. Chand, «Reconstruction of cylinder pressure for SI engine using recurrent neural network», *Neural Computing and Applications*, vol. 19, n.º 6, pp. 935-944, 2010.

- [8] F. Tagliatalata, M. Lavorgna, E. Mancaruso, y B. M. Vaglieco, «Determination of combustion parameters using engine crankshaft speed», *Mechanical Systems and Signal Processing*, vol. 38, n.º 2, pp. 628-633, 2013.
- [9] Y. Zhang y R. B. Randall, «The In-cylinder Pressure Reconstruction and Indicated Torque Estimation Based on Instantaneous Engine Speed and One Measured In-cylinder Pressure», en *Proceedings of Comadem 2007 - The 20th International Congress on Condition Monitoring and Diagnostic Engineering Management*, 2007, pp. 657-666.
- [10] R. Johnsson, «Cylinder pressure reconstruction based on complex radial basis function networks from vibration and speed signals», *Mechanical Systems and Signal Processing*, vol. 20, n.º 8, pp. 1923-1940, 2006.
- [11] A. Moosavian, G. Najafi, B. Ghobadian, M. Mirsalim, S. M. Jafari, y P. Sharghi, «Piston scuffing fault and its identification in an IC engine by vibration analysis», *Applied Acoustics*, vol. 102, pp. 40-48, 2016.
- [12] X. Wang, C. Liu, F. Bi, X. Bi, y K. Shao, «Fault diagnosis of diesel engine based on adaptive wavelet packets and EEMD-fractal dimension», *Mechanical Systems and Signal Processing*, vol. 41, n.º 1-2, pp. 581-597, 2013.
- [13] J. Arroyo, M. Muñoz, F. Moreno, N. Bernal, y C. Monné, «Diagnostic method based on the analysis of the vibration and acoustic emission energy for emergency diesel generators in nuclear plants», *Applied Acoustics*, vol. 74, n.º 4, pp. 502-508, 2013.
- [14] L. Deng y R. Zhao, «A vibration analysis method based on hybrid techniques and its application to rotating machinery», *Measurement*, vol. 46, n.º 9, pp. 3671-3682, 2013.
- [15] A. P. Carlucci, F. F. Chiara, y D. Laforgia, «Analysis of the relation between injection parameter variation and block vibration of an internal combustion diesel engine», *Journal of Sound and Vibration*, vol. 295, n.º 1-2, pp. 141-164, 2006.
- [16] S. Vulli, J. F. Dunne, R. Potenza, D. Richardson, y P. King, «Time-frequency analysis of single-point engine-block vibration measurements for multiple excitation-event identification», *Journal of Sound and Vibration*, vol. 321, n.º 3-5, pp. 1129-1143, 2009.
- [17] J. Antoni, J. Daniere, F. Guillet, y R. B. Randall, «Effective Vibration Analysis Of IC Engines Using Cyclostationarity. Part 2: New Results On The Reconstruction Of The Cylinder Pressures», *Journal of Sound and Vibration*, vol. 257, n.º 5, pp. 839-856, 2002.
- [18] D. Garcia de Frutos, *Encargado de obra civil. Maquinaria y medios auxiliares*, 1.ª ed. Madrid, España: Fundación Laboral de la Construcción, 2009.
- [19] J. Bernal, P. Gómez, y J. Bobadilla, «Una visión práctica en el uso de la Transformada de Fourier como herramienta para el análisis espectral de la voz», *Estudios de fonética experimental*, vol. 10, pp. 75-105, 1999.
- [20] J. Morón, *Señales y sistemas*. Fondo editorial biblioteca, 2011.
- [21] G. Castellanos Domínguez y Á. Á. Orozco Gutiérrez, *Representación de señales y sistemas*, vol. 1. Universidad Tecnológica de Pereira, 2007.
- [22] M. Welling, «Kernel ridge regression», *Empirical Inference: Festschrift in Honor of Vladimir N. Vapnik*, n.º 3, pp. 105-116, 2013.

