



Universidad Autónoma de Querétaro  
Facultad de ingeniería  
Maestría en Ciencias Mecatrónica

**Metodología de diagnóstico para la detección de fallas en  
sistemas valvulares en motores de combustión basada en  
fusión de señales**

**Tesis**

Que como parte de los requisitos para obtener el grado de:

**Maestro en Ciencias (Mecatrónica)**

**Presenta:**

Ing. Alejandro García Basurto

**Dirigido por:**

Dr. Juan José Saucedo Dorantes

San Juan del Río, Qro. México, Julio de 2021



Universidad Autónoma de Querétaro  
Facultad de Ingeniería  
Maestría en Ciencias Mecatrónica

**Metodología de diagnóstico para la detección de fallas en sistemas  
valvulares en motores de combustión basada en fusión de señales**

**Tesis**

Que como parte de los requisitos para obtener el grado de:

**Maestro en Ciencias (Mecatrónica)**

Presenta:

**Ing. Alejandro García Basurto**

Dirigido por:

**Dr. Juan José Saucedo Dorantes**

**Dr. Juan José Saucedo Dorantes**

Presidente

**Dr. Ángel Pérez Cruz**

Secretario

**Dr. Roque Alfredo Osornio Ríos**

Vocal

**Dr. J. Jesús de Santiago Pérez**

Suplente

**Dr. Juan Primo Benítez Rangel**

Suplente

Centro Universitario  
Querétaro, Qro.  
29 de Julio de 2021  
México

## Resumen

En este trabajo de tesis se propone una metodología de diagnóstico basada en el cálculo y reducción de indicadores estadísticos estimados mediante señales de vibración y corriente, fusionando los datos de dichos indicadores para la detección de fallas en el sistema de tren valvular en un motor de combustión interna (MCI). El trabajo realizado incluye la caracterización de señales de vibración y de corriente mediante cuatro indicadores estadísticos capaces de modelar la tendencia y describir cambios de las señales a lo largo del tiempo. El método propuesto introduce el uso de las técnicas de reducción de la dimensionalidad como análisis de componentes principales (PCA) y análisis discriminante lineal (LDA) las cuales tienen la capacidad de reducir la dimensión de un espacio de un conjunto original de indicadores para obtener representaciones visuales de los patrones característicos de las diferentes condiciones de operación valoradas. También, estas técnicas se utilizan para fusionar los datos de los conjuntos de indicadores reducidos con la finalidad de generar diagnósticos que contengan posibles causas diversas y problemas de enmascaramiento por ruido de fondo y para aportar más datos a la estructura de un algoritmo que se utiliza en una red neuronal capaz de clasificar diferentes severidades de falla en forma automática. El método propuesto es evaluado sobre datos experimentales adquiridos durante la operación normal y con falla del sistema valvular de un MCI en régimen de ciclo de arranque. El procesamiento de las señales de vibración y corriente adquiridas y la aplicación de la metodología de diagnóstico propuesta se realizó bajo el entorno de programación de Matlab®. Los resultados obtenidos en patrones característicos bidimensionales presentan claramente la separación de las diferentes condiciones de operación y la clasificación de la severidad de la falla, dichos resultados demuestran que la metodología permite diagnosticar y clasificar fallas en MCI generadas en el sistema del tren valvular de forma efectiva independientemente del cilindro afectado.

**(Palabras clave:** Análisis discriminante lineal, detección de fallas, fusión de señales, indicadores estadísticos, motor de combustión interna).

## **Abstract**

In this thesis work, a diagnostic methodology based on the calculation and reduction of estimated statistical indicators through vibration and current signals is proposed, fusing the data of said indicators for the detection of failures in the valve train system in an internal combustion engine (ICE). The work done includes the characterization of vibration and current signals through four statistical indicators capable of modeling the trend and describing changes in the signals over time. The proposed method introduces the use of statistical indicator reduction techniques such as principal component analysis (PCA) and linear discriminant analysis (LDA), which have the ability to reduce the dimension of a space from an original set of indicators to obtain visual representations of the characteristic patterns of the different operating conditions valued. Also, these techniques are used to fusion the data from the reduced indicator sets in order to generate diagnoses that contain various possible causes and masking problems due to background noise and to contribute more data to the structure of an algorithm that is used in a neural network capable of classify different severities of failure automatically. The proposed method is evaluated on experimental data acquired during normal and faulty operation of the valve system of an ICE in a starting cycle regime. The processing of the vibration and current signals acquired and the application of the proposed diagnostic methodology was did under the Matlab ® programming environment. The results obtained in two-dimensional characteristic patterns clearly present the separation of the different operating conditions and the classification of the severity of the failure, these results demonstrate that the methodology allows to diagnose and classify failures in ICE generated in the valve train system in an effective way regardless of the affected cylinder.

**(Key words:** Linear discriminant analysis, fault detection, signal fusion, statistical indicators, internal combustion engine).

## Dedicatorias

A los integrantes de mi familia más cercana, quienes en todo momento me impulsaron y apoyaron para llevar a cabo mis estudios, especialmente a mis hermanas Mary y Celina (q.e.p.d.).

## **Agradecimientos**

En primer lugar quiero expresar mi agradecimiento a cada uno de los miembros de mi familia y compartir con ellos el logro de esta meta que me trace hace tiempo, ya que siempre me expresaron su confianza y apoyo incondicional para culminarla. Quiero también hacer mención de personas que ya no están presentes como mi padre y madre, pero que de igual forma les entrego todo mi agradecimiento por haberme dado una educación y formación con valores aplicables en todos los ámbitos de la vida, asimismo a mi hermana Celina que fue un ejemplo para mí de esfuerzo y tenacidad en el medio académico y como ser humano. A mis hijos Aldo y Adrián que son mi fuente de inspiración intelectual, a mi hermana Mary por animarme continuamente y desde luego a mi compañera sentimental Lupita por tenerme paciencia durante todo este proceso que no puede dedicarle mucho tiempo.

También quiero agradecer a mi director de tesis Dr. Saucedo, a mi tutor Dr. Ángel, a mi coordinador Dr. Roque, y a mis sinodales quienes confiaron en mi trabajo de investigación y me ayudaron mucho con su asesoría, observaciones y acertados consejos. De igual forma, quiero agradecerle al Dr. Valtierra por ser la persona que me abrió la mente e impulsó el sueño en mí para estudiar esta maestría y que se volvió realidad. No puedo omitir agradecerles desde luego, a todos mis profesores de la maestría que con todo profesionalismo me instalaron en el saber-hacer y que además me tuvieron mucha paciencia en mi proceso de aprendizaje.

Por último, agradezco al Consejo Nacional de Ciencia y Tecnología (CONACYT) y a la Universidad Autónoma de Querétaro por haberme otorgado una beca de manutención y académica durante la realización de este proyecto de investigación.

## ÍNDICE GENERAL

Resumen .....	i
Abstract.....	ii
Dedicatorias.....	iii
Agradecimientos .....	iv
Índice de tablas.....	vii
Índice de figuras.....	vii
1 Introducción .....	1
1.1 Antecedentes.....	2
1.2 Descripción del problema.....	11
1.3 Justificación .....	12
1.4 Hipótesis y Objetivos .....	13
1.4.1 Hipótesis.....	13
1.4.2 Objetivo general.....	13
1.4.3 Objetivos específicos.....	13
1.5 Planteamiento general.....	14
2 Fundamentación teórica .....	15
2.1 Estadística descriptiva .....	15
2.1.1 Herramientas estadísticas de clasificación .....	15
2.1.2 Reducción de indicadores.....	17
2.1.3 Indicadores de confiabilidad .....	20
2.2 Técnicas empleadas en la fusión de Señales.....	21
2.3 Inteligencia artificial .....	22
2.3.1 Algoritmos inteligentes.....	23

2.3.2	Redes neuronales artificiales .....	23
2.4	Mecánica automotriz.....	25
2.4.1	Motor de combustión interna .....	25
2.4.2	Ciclo Otto y tren valvular.....	26
2.4.3	Falla en el tren valvular y sus repercusiones en el MCI.....	28
3	Metodología.....	30
3.1	Experimentación.....	31
3.1.1	MCI bajo estudio.....	31
3.1.2	Instrumentación del MCI.....	33
3.1.3	Evaluación iterativa.....	34
3.1.4	Adquisición de señales.....	35
3.2	Evaluación.....	37
3.2.1	Caracterización.....	37
3.2.2	Fusión de señales.....	38
3.2.3	Clasificación y evaluación.....	39
3.2.4	Análisis de la confiabilidad.....	39
4	Resultados.....	41
4.1	Procesamiento de señales.....	41
4.1.1	Condición sana del tren valvular.....	41
4.1.2	Condiciones de falla del tren valvular .....	43
4.2	Fusión de señales y evaluación de la severidad.....	45
4.3	Clasificación de la falla .....	51
4.4	Evaluación de la fiabilidad .....	54
5	Conclusiones .....	58

6	Referencias.....	60
7	Apéndice.....	63
7.1	Artículos publicados en revistas .....	63
7.2	Artículos de congreso .....	63

## ÍNDICE DE TABLAS

Tabla 2.1	Indicadores estadísticos en el dominio del tiempo.....	16
Tabla 3.1	Datos técnicos del motor de combustión interna utilizado en las pruebas experimentales.....	31
Tabla 3.2	Especificaciones técnicas de los sensores de vibración y corriente .....	34
Tabla 3.5	Matriz de experimentos para la validación de la metodología.....	40
Tabla 4.1	Matriz de predicción de la red neuronal bajo el esquema de validación cruzada durante el entrenamiento.....	51
Tabla 4.2	Matriz de predicción de la red neuronal bajo el esquema de validación cruzada durante la prueba.....	52

## ÍNDICE DE FIGURAS

Figura 2.1	Representación de una red de clasificación (Fuente: Duda et al., 2012) .....	18
Figura 2.2	Línea de decisión para clases compactas y no compactas (Fuente: Theodoridis y Koutroumbas, 2006) .....	20
Figura 2.3	Célula nerviosa o neurona (Fuente: Russell y Norvig, 2002).....	23
Figura 2.4	Modelo matemático simple de una neurona artificial (Fuente: Russell y Norvig, 2002) .....	24

Figura 2.5 Porcentaje de calorías pérdidas y aprovechadas en un MCI (Autoría propia).....	26
Figura 2.6 Proceso real del ciclo Otto (Fuente: Agüero-Alva, 2002) .....	27
Figura 2.7 Configuración de un tren valvular para motores OHV (Fuente: Agüero-Alva, 2002).....	28
Figura 3.1 Diagrama de bloques de la metodología en general (Autoría propia)...	30
Figura 3.2 Diagrama de bloques en detalle para la fase de experimentación (Autoría propia).....	32
Figura 3.3 Calibración de la condición sana del tren valvular (Autoría propia) .....	33
Figura 3.4 Panorámica de la colocación de los sensores de vibración y corriente en el MCI (Autoría propia).....	33
Figura 3.5 Detalle de colocación de sensores de vibración y corriente en el MCI (Autoría propia).....	34
Figura 3.6 Calibración de holgura para condición de severidad (Autoría propia) ..	35
Tabla 3.3 Matriz de experimentos para 4 condiciones de operación .....	35
Figura 3.7 Tarjeta DAS (FPGA-Field Programmable Gate Array) (Fuente: Morales-Velázquez, 2013).....	36
Figura 4.1 Señales de corriente adquiridas del motor de arranque en la fase de puesta en marcha del MCI para la condición sana del tren valvular. ....	42
Figura 4.2 Señales de vibración en el eje X, Y, Z adquiridas del MCI en su fase de puesta en marcha para la condición sana del tren valvular. ....	42
Figura 4.3 Señales de corriente adquiridas del motor de arranque del MCI durante su fase de puesta en marcha para la condición sana y tres severidades de falla de holgura en el tren valvular: (a) 720° de sobre-ajuste, (b) 360° de sobre-ajuste y (c) 540° de sub-ajuste.....	43

Figura 4.4 Señales de vibración en el eje "X" adquiridas del MCI durante su fase de puesta en marcha para la condición sana y tres severidades de falla de holgura en el tren valvular: (a) 720° de sobre-ajuste, (b) 360° de sobre-ajuste y (c) 540° de sub-ajuste. ....	44
Figura 4.5 Indicadores estadísticos para vibraciones en el eje "X" en diferentes condiciones de operación. ....	45
Figura 4.6 Proyección obtenida aplicando la técnica PCA al conjunto de indicadores estadísticos para las señales de corriente adquiridas del motor de arranque durante la fase de puesta en marcha del MCI para la condición sana y tres severidades de falla de holgura del tren valvular. ....	45
Figura 4.7 Proyección obtenida aplicando la técnica PCA al conjunto de indicadores estadísticos para las señales de vibración en el eje "X" adquiridas en el MCI durante su fase de puesta en marcha para la condición sana y tres severidades de falla en la holgura del tren valvular. ....	46
Figura 4.8 Proyección obtenida aplicando la técnica de PCA para fusionar indicadores estadísticos de las señales de corriente y vibración en el eje "X" adquiridas durante la fase de puesta en marcha del MCI para la condición sana y tres severidades de falla en la holgura del tren valvular. ....	47
Figura 4.9 Proyección obtenida aplicando la técnica LDA al conjunto de indicadores estadísticos para las señales de corriente adquiridas del motor de arranque durante la fase de puesta en marcha del MCI para la condición sana y tres severidades de falla de holgura del tren valvular. ....	48
Figura 4.10 Proyección obtenida aplicando la técnica LDA al conjunto de indicadores estadísticos para las señales de vibración en el eje "X" adquiridas en el MCI durante su fase de puesta en marcha para la condición sana y tres severidades de falla en la holgura del tren valvular. ....	49
Figura 4.11 Proyección obtenida aplicando la técnica LDA para fusionar indicadores estadísticos de las señales de corriente y vibración en el eje "X" adquiridas durante	

la fase de puesta en marcha del MCI para la condición sana y tres severidades de falla en la holgura del tren valvular. ....	50
Figura 4.12 Muestras de entrenamiento para la clasificación automática de la Severidad de falla del Tren Valvular mediante una Red Neuronal para LDA. ....	53
Figura 4.13 Muestras de validación para la clasificación automática de la Severidad de falla del Tren Valvular mediante una Red Neuronal para LDA.....	53
Figura 4.14 Muestras de entrenamiento para la clasificación automática de la Severidad de falla del Tren Valvular mediante una Red Neuronal para PCA. ....	54
Figura 4.15 Muestras de validación para la clasificación automática de la Severidad de falla del Tren Valvular mediante una Red Neuronal para PCA. ....	54
Figura 4.16 Proyección obtenida aplicando la técnica de PCA en indicadores estadísticos de las señales de corriente y vibración en el eje "X" adquiridas durante la fase de puesta en marcha del MCI para un sub-ajuste de 540° del cilindro 1 sobre el patrón de la condición sana y tres severidades de falla en la holgura del tren valvular. ....	55
Figura 4.17 Proyección obtenida aplicando la técnica de LDA en indicadores estadísticos de las señales de corriente y vibración en el eje "X" adquiridas durante la fase de puesta en marcha del MCI para un sub-ajuste de 540° del cilindro 1 sobre el patrón de la condición sana y tres severidades de falla en la holgura del tren valvular. ....	56

# 1 INTRODUCCIÓN

La invención del motor de combustión interna (MCI), permitió poner en marcha el desarrollo del automóvil y desde entonces ambos se convirtieron en un solo producto, que a partir de las nuevas tecnologías de la industria automotriz se ha transformado en un artículo casi necesario a nivel mundial. El MCI como principal sistema de un vehículo, es una máquina termodinámica que convierte su energía en trabajo mecánico produciendo movimiento en el automovil, pero estando en operación siempre presenta pérdidas energéticas por diferentes factores como calor y fuerzas de fricción por lo que su trabajo útil es relativamente bajo. Por tal motivo es importante y necesario asegurarse que los componentes del motor se mantengan funcionando en óptimas condiciones, para conservar particularmente la potencia y minimizar las emisiones contaminantes al medio ambiente.

El tren valvular o tren de válvulas es un subsistema que pertenece al sistema de distribución del MCI formado por un grupo de componentes; válvula de admisión y escape, levanta válvula o punteria hidráulica o mecánica, varilla de empuje, balancin, tornillo ajustador, resorte y elementos de fijación, en el caso de motores con valvulas en la cabeza (OHV-Over Head Valve) y sus variantes árbol a la cabeza (OHC-Over Head Cam) y doble árbol a la cabeza (DOHC-Double Over Head Cam). Este subsistema tiene como finalidad regular el ingreso de la mezcla de aire y combustible a los cilindros del motor, permitir la salida de los gases de la combustión de los cilindros y hermetizar las cámaras de combustión. La potencia del MCI depende en mucho del tiempo de apertura y cierre de la válvula y también de la elevación de la misma, de manera que si el tren valvular no opera correctamente, causará en el motor una marcha errática, velocidad excesiva, titubeo durante la aceleración, explosiones descontroladas y eventualmente emisiones contaminantes.

En la mayoría de los MCI modernos, el tiempo de apertura y cierre de las válvulas esta controlada por un sistema electrónico compuesto de un sensor de posición de árbol de levas (CMP-Camshaft Position Sensor), una válvula de tiempo

variable inteligente (VVTi-Variable Valve Timing Intelligence), un módulo de control del motor (ECM-Engine Control Module) y un sensor de posición del cigüeñal (CKP-Crankshaft Position Sensor), este sistema efectúa los ajustes necesarios dependiendo de los diferentes regímenes de carga durante la conducción, sin embargo el sistema de tren valvular sigue siendo susceptible a operaciones incorrectas. La identificación de este tipo de fallas en forma convencional es complicada debido a que se requiere la inspección física de los componentes, por lo que puede resultar costoso e impreciso y por otra parte, la detección automática de este tipo de falla aún no se integra en los sistemas modernos de diagnóstico. Por lo anterior es importante y necesario desarrollar estrategias basadas en el análisis de señales de vibración y corriente adquiridas para mejorar la fiabilidad del diagnóstico.

En esta tesis se describe el desarrollo de una metodología para la identificación de fallas producidas por la holgura excesiva o reducida de las válvulas y que esta relacionada al grupo de componentes del tren valvular en el MCI, dicho desarrollo incluye la descripción de cómo obtener un conjunto de señales, el procesamiento que debe realizarse para evaluar diferentes grados de falla y la determinación de la condición actual del tren valvular del MCI. Parte importante del desarrollo de esta tesis reside en el uso de técnicas de fusión de datos y la aplicación de técnicas inteligentes de clasificación que ayuden a realizar la identificación automática de fallas. Con este trabajo se espera obtener una metodología de diagnóstico para monitorear e identificar patrones de señales de vibración y corriente que permita cuantificar la operación del tren valvular, dejando las bases para el desarrollo de una interfaz y la evaluación de otras fallas en el MCI con mayores capacidades de detección que ayude al personal del área automotriz a sustentar un mantenimiento preventivo y correctivo fiable.

## **1.1 Antecedentes**

Los sistemas de monitoreo y diagnóstico juegan un papel muy importante para la mayoría de aplicaciones en la industria, esto se debe a que la correcta

aplicación de estrategias de monitoreo ayudan a mantener y asegurar el adecuado funcionamiento y disponibilidad de la maquinaria. En este sentido, la industria no es el único sector que se beneficia con la creación de nuevos métodos y estrategias de monitoreo y diagnóstico; existen otros sectores importantes, como el sector automotriz, que también puede ser beneficiado con estos métodos. Los actuales avances tecnológicos de la industria automotriz en el desarrollo de los automóviles, la evolución e implementación de la tecnología en los vehículos, ha sido drástica en las dos últimas décadas y aunque se han obtenido múltiples beneficios, desafortunadamente esta evolución no ha sido proporcional en el mantenimiento. En los últimos años, la identificación de fallas en sistemas automotrices ha tomado gran importancia, tanto así que, ha resultado atractiva para los investigadores para resolver diferentes problemáticas. En el ámbito internacional, el uso de herramientas de análisis de señales como método de diagnóstico, para la detección de fallas en los diferentes componentes de motores de combustión interna, han tenido un alto impacto y se han mostrado avances significativos.

Así, en esta sección se presentan los trabajos que constituyen el estado del arte de los estudios más relevantes; en lo que respecta a los métodos y estrategias de monitoreo y diagnóstico que han sido enfocados a la detección de fallas en motores de combustión interna (MCI) generadas en el tren de válvulas; además, se han incluido aquellos trabajos que involucran el análisis y fusión de señales que son adquiridas durante la operación del mismo. En este sentido, en el trabajo desarrollado por (Wu y Chuang, 2005) se propuso una técnica de diagnóstico de fallas en MCI basada en patrones de puntos visuales de las señales acústicas y de vibración adquiridas, los resultados experimentales indicaron que el método propuesto es efectivo para la identificación de fallas en el MCI y en ejes de transmisión, sin embargo, el método fue aplicado exclusivamente al monitoreo del sistema de enfriamiento del MCI.

Por otro lado (Merkisz y Waligórski, 2014) refirieron en su artículo, la evaluación de la corrección de un proceso de combustión, en un motor de inyección

directa de encendido por compresión, sobre la base de las señales de vibración y su procesamiento digital, a través del análisis conjunto de tiempo-frecuencia (JTFA-Joint Time-Frequency Analysis). El método que presentaron se caracteriza por tener alta dinámica en los cambios de parámetros, que refleja la aparición o la falta de ignición en el cilindro del motor (15-24 dB). Este método obtuvo entre otros resultados, una correlación explícita y precisa entre el proceso de combustión del motor y los parámetros de señales de vibración los cuales permiten una detección inequívoca de fallas, sin embargo el método propuesto para la identificación de dichas fallas utiliza solo mapas de frecuencia-tiempo-aceleración involucrando un complejo procesamiento de señales, en este sentido, podría construirse un algoritmo de diagnóstico basado en la fusión de señales mediante técnicas inteligentes de clasificación como se propone en esta tesis.

Más adelante, (Moosavian et al., 2016) investigaron que efecto tiene una falla en el desgaste del pistón y los efectos producidos sobre el rendimiento del motor mediante el análisis de señales de vibración. Específicamente, las señales de vibración fueron analizadas mediante técnicas de procesamiento en el dominio del tiempo, frecuencia y tiempo-frecuencia. Así, mediante el uso de la transformada continua Wavelet (CWT-Continuous Wavelet Transform) obtuvieron la representación de las señales de vibración en mapas del dominio tiempo-frecuencia. Los resultados obtenidos en su investigación demostraron que las vibraciones del motor son una medida fiable y apropiada para identificar fallas de desgaste del pistón además de que, la capacidad de las señales de vibración fusionadas con otro tipo de señal, como las de corriente, se puede incrementar para identificar la aparición de otro tipo de fallos en MCI, e incluso ayudarían a la identificación temprana de su aparición.

Así mismo, (Delvecchio et al., 2018) proporcionaron una descripción general de las técnicas de monitoreo y diagnóstico basadas en la utilización de señales acústicas o señales de presión sonora (SP-Sound Pressure) y de vibración para establecer las diferentes condiciones de falla que afectan la combustión,

mecánica y aerodinámica de los MCI. Así, este trabajo ha sido considerado como una guía para que los ingenieros de prueba comprendan qué tipos de fallas se pueden diagnosticar, mediante el uso de señales vibro-acústicas. Por otra parte, la importancia de medir señales acústicas, además de señales de vibración, se debe a que las primeras, en vista de su comportamiento no intrusivo, parecen ser más adecuadas para la implementación en sistemas de monitoreo a bordo, mientras que las segundas, se debe a su capacidad para capturar simultáneamente señales de varios componentes mecánicos y detectar sus fallas. Así mismo, con el desarrollo de este trabajo los investigadores obtuvieron como resultado la tabla 7 de su artículo, relacionada con fallas en los MCI que afectan diferentes sistemas, tales como: encendido, combustión, inyección y válvulas mal calibradas; así como también, fallas en los sistemas auxiliares como el alternador, sistema de lubricación y turbocompresores. En esa misma tabla 7 de resultados, recomiendan una técnica y una señal a utilizar para la identificación de cada una de las fallas; sin embargo, aunque todo se reduce al uso de señales de vibración, acústica o ambas, para una mejor interpretación en la identificación de las fallas, no se hace la recomendación de un método o técnica en específico. El uso de señales SP para detección de fallas en válvulas por holguras está lejos de su madurez debido al efecto de enmascaramiento dado por el ruido de fondo, sin embargo, al utilizar la señal de corriente eléctrica como una de las señales a fusionar, como se plantea en esta tesis en lugar de las señales SP, podría ayudar a mejorar el análisis de la fusión de señales y por ende la identificación de fallas en sistemas valvulares.

Por otra parte, el análisis de vibraciones como herramienta de diagnóstico de degradación de máquinas ha sido muy utilizada en la industria, y en el caso del diagnóstico de diferentes componentes mecánicos de los motores de MCI también es muy común. En este contexto, (Siano et al., 2017) usaron el análisis espectral de vibraciones como herramienta de diagnóstico para determinar la degradación de una bomba de lubricación en aplicaciones automotrices. Con este trabajo se determinó que el análisis espectral de vibraciones es un método fiable por sí solo, pero únicamente en condiciones reguladas ya que otras fuentes de vibración

secundarias como desalineaciones radiales, variaciones de presión del impulsor, defectos de fabricación de sellos, cojinetes e impulsores, e incluso fuentes de ruido hidráulicas se suman a la medición final capturada por el acelerómetro. Así como presentaron sus resultados, no siempre es obvio determinar cuando el problema de cavitación está presente o no y esto puede afectar el diagnóstico.

En este sentido, una de las soluciones que podrían ayudar a los desarrollos futuros en la implementación de métodos y estrategias de monitoreo y diagnóstico aplicadas a MCI, específicamente a las fallas de válvulas, es la utilización de diferentes variables y el uso de técnicas de fusión de datos, como las técnicas de análisis discriminante lineal (LDA-Linear Discriminant Analysis) y análisis de componentes principales (PCA-Principal Component Analysis), que es precisamente lo que se propone en esta tesis para establecer los parámetros que determinen si la falla está presente o no. En términos generales, y en base a los trabajos de investigación anteriores, se puede inferir que es altamente recomendable llevar los métodos de diagnóstico por medio de análisis de señales, utilizados para detectar fallas en MCI en el ramo automotriz a un contexto más específico, como es la detección de fallas en el tren valvular (válvulas).

Ya existen algunos estudios sistemáticos sobre métodos de diagnóstico para detectar fallas por tren valvular en motores de combustión interna que se han llevado a cabo recientemente, como es el caso de (Flett y Bone, 2016) quienes desarrollaron un sistema para detectar y diagnosticar fallas, empleando un tren de válvulas de un MCI diésel. En este sistema se generó una caracterización novedosa por cada cierre de válvula e impactos de combustión. Las fallas de deformación del resorte y del espacio de la válvula se indujeron en un motor diésel instrumentado con un acelerómetro. Su método probabilístico Resistencia al Impacto Naive-Bayes (IS-NB-Impact Strength Naive-Bayes) demostró que detecta y clasifica con precisión: fallas de resortes grupal e individualmente y fallas de espacio libre que ocurren en múltiples válvulas simultáneamente, pero este método solo toma en cuenta la señal de vibración y la clasificación no es para diferentes condiciones de

fallo, por lo que si se agregara la señal de corriente eléctrica y una fusión de ambas se podría mejorar los resultados.

Otros estudios sobre fallas en válvulas de MCI indican que es fiable utilizar análisis de vibraciones, como por ejemplo, (Jafarian et al., 2016) donde el objetivo principal de su trabajo fue utilizar el análisis de vibraciones con el método análisis de componentes principales en la industria automotriz, para detectar y clasificar fallas presentes debido a la holgura del asiento de la válvula y la combustión incompleta; que a veces se denomina fenómeno de falla en el motor de combustión interna. Las especificaciones del nuevo subconjunto PCA se reconstruyeron con parámetros controlables para categorizar las características con alta precisión y menos cálculos, lo que demostró que el método es adecuado. Sin embargo, el uso de más herramientas como LDA mejoraría la fiabilidad de los resultados.

En lo que respecta al uso de señales múltiples, como pueden ser vibratorias, temperaturas, presiones y eléctricas, se necesita no solo medir la presencia de señales, sino también estimar el número de señales y los parámetros correspondientes como lo hicieron (Zhu y Zhu, 2020) al modelar y resolver el problema de fusión, detección conjunta de señales múltiples y con su estimación demostraron que los resultados de su algoritmo propuesto: Característica de Operación del Receptor Alternativo de Respuesta Libre (AFROC- Alternative Free-Response Receiver Operating Characteristic) es superior a otros algoritmos como el de Característica de Operación del Receptor de Respuesta Libre) (FROC- Free-Response Receiver Operating Characteristic) y el de Característica de Operación del Receptor de Estimación (EROC- Estimation Receiver Operating Characteristic ). El modelo del problema construido supone que las señales verdaderas son independientes entre sí, sin embargo, en algunas aplicaciones prácticas, estas condiciones no siempre se cumplen por lo que podría considerarse el caso con señales correlacionadas en trabajos futuros.

En Latinoamérica, ya se han realizado trabajos de investigación utilizando las señales eléctricas, (Mendonça et al., 2017) presentaron el desarrollo de una

metodología que permite la detección de fallas incipientes tanto en el motor principal que es un MCI como en un generador síncrono acoplado a éste, basándose únicamente en las mediciones de los voltajes y corrientes del estator del generador. Los patrones de falla obtenidos mediante los análisis de firma eléctrica (ESA-Electric Signature Analysis) propuestos se basan en frecuencias definidas y las características estructurales de la máquina, por lo que pueden reproducirse en una amplia gama de conjuntos de motores y generadores. Las principales ventajas del sistema propuesto son su baja intrusión, instalación factible y rentabilidad. Los resultados que obtuvieron además de detectar fallas eléctricas, incluyen las fallas de la válvula de admisión y las fallas en anillos del pistón, pero si se agrega la variable de vibración, se obtendrían mejores resultados en la identificación de fallas en sistemas valvulares.

En lo que respecta al progreso de los algoritmos de procesamiento de señales digitales y las técnicas de implementación además de la tecnología de diagnóstico convencional, utilizando acústica y las señales de vibración, ya existen en forma de técnicas que aplican el dominio de tiempo y frecuencia de las señales y analizan la diferencia de señales en el espectro. Por ejemplo (Wu y Chen, 2006) propusieron un algoritmo basado en la CWT y el cual fue utilizado para el diagnóstico de la señal de falla en un MCI y su sistema de enfriamiento. Los resultados indicaron que la propuesta de la técnica CWT es efectiva en el diagnóstico de señales de falla, desafortunadamente el método no siempre detecta aquellas fallas cuyas señales están en el fondo de la banda ancha.

Así mismo, el uso de indicadores estadísticos para el análisis de señales es una herramienta de gran ayuda para la construcción de un algoritmo de identificación de fallas, por ejemplo; (Chao et al., 2019) mencionaron en su trabajo de investigación que un algoritmo de ponderación se puede emplear para optimizar el coeficiente de correlación entre la corriente de ionización y la detonación en las cámaras de combustión del motor, ya que en sus trabajos alcanzaron una tasa de precisión de diagnóstico de 87.2 % y un coeficiente de variación integral menor al

4%. Aunque el trabajo que presentaron es novedoso por utilizar señales de corriente de iones en el combustible detonado en un MCI aún no toman en cuenta otras señales como vibratorias y presiones por mencionar algunas.

Los métodos inteligentes para automatizar el diagnósticos en fallas en máquinas rotativas se pueden utilizar en el área automotriz, específicamente en MCI, tomando como referencia algunos casos recientes donde aplican estos métodos, ejemplo de ello, (Jia et al.,2016) estudiaron los métodos basados en redes neuronales artificiales (ANN-Artificial Neural Networks), que emplean técnicas de procesamiento de señales para extraer características y además ingresan las características a las ANN para clasificar fallas en máquinas rotativas y propusieron un método inteligente novedoso para superar algunas deficiencias de este método. Con el objetivo de procesar rápidamente los datos de fallas masivas y proporcionar automáticamente resultados de diagnóstico precisos, realizaron numerosos estudios sobre el diagnóstico inteligente de fallas en maquinaria rotativa. La efectividad del método propuesto: Red Neuronal Profunda (DNN-Deep Neural Network) lo validaron utilizando específicamente una base de datos con información asociada a rodamientos y cajas de engranajes planetarios, pero es generalizado para máquinas rotativas. Estos conjuntos de datos contienen señales medidas masivas que involucran diferentes condiciones de salud bajo diversas condiciones de operación. Los resultados del diagnóstico mostraron que el método propuesto no solo puede extraer adaptativamente las características de falla disponibles de las señales medidas, sino también obtener una precisión de diagnóstico superior en comparación con los métodos existentes, sin embargo este método propuesto no utiliza conjuntos de señales diferentes que pueden ser fusionadas para aportar mejores resultados y es precisamente la propuesta de fusionar señales vibratorias y de corriente eléctrica usando métodos inteligentes que ayuden a realizar la identificación automática de fallas.

Otros métodos aplicados en la detección de fallas en MCI con origen en el tren de válvulas son los realizados por (Zhou et al., 2017) quienes propusieron un

modelo dinámico flexible mejorado para analizar la holgura y deformaciones multidireccionales de las válvulas, basado en el método de elementos finitos (FEM- Finite Element Method), y verificado mediante experimentos. En este trabajo se analizaron los efectos del juego de válvulas y la velocidad de rotación de la leva sobre la fuerza de contacto, la aceleración y el error de transmisión dinámica. De acuerdo con el perfil medido de la leva, las excitaciones internas están disponibles como una solución numérica para el modelo, que se logra mediante el uso de un polinomio de interpolación cúbico Hermite por partes. Esto les permitió demostrar que el método sirve para analizar deformaciones multidireccionales en el sistema valvular, pero no consideran otras variables, como la corriente por ejemplo y tampoco el método está enfocado como herramienta de diagnóstico de mantenimiento sino más bien de diseño.

En este mismo contexto, (Ftoutou et al., 2012) trabajaron sobre la clasificación de una falla de holgura de válvula en un motor diésel de combustión interna utilizando indicadores calculados con técnicas en el dominio de tiempo y señales de vibración extraídas de segmentos medidos en varios puntos del bloque del motor. Luego utilizaron un algoritmo de selección de variables por pasos, basado en análisis de varianza univariado y multivariado para clasificar las variables de acuerdo con su capacidad de diagnóstico, confirmando que el uso de más variables, de acuerdo con el resultado de la selección por pasos, generalmente aumenta la tasa de clasificación correcta. El rendimiento de los cuatro clasificadores probados fue casi el mismo, aproximadamente el 90% de la tasa de clasificación correcta cuando solo se usa la señal de vibración en el punto 1 que es la primera variable y el 96% cuando se usa también la señal de vibración en el punto 2, es decir, con dos variables. Por otro lado, solo consideraron variables de vibración en distintos puntos de medición, por lo que podría mejorarse este método con el uso de la variable de corriente.

Los métodos empleados que se han reportado en la literatura se enfocan mayormente al uso de las señales vibratorias, en otros trabajos emplearon señales

vibro-acústicas, algunos usaron señales eléctricas, y en lo que se refiere al cálculo de indicadores estadísticos y al uso de técnicas de fusión de datos, LDA y PCA, para caracterizar las diferentes condiciones de falla se utilizaron aisladamente pero no de manera conjunta. Por lo tanto, debido a que no se han reportado resultados referentes al monitoreo de condición y diagnóstico de fallas aplicado en MCI, en este trabajo se propone desarrollar una estrategia de condición de monitoreo que sea capaz de fusionar información extraída por diferentes sensores. Es decir, mediante el procesamiento y fusión de señales de vibración y corriente se lograra proporcionar mayor información a una estructura conformada por un algoritmo de clasificación, para realizar la identificación de fallas que puedan ocurrir en el sistema valvular de un MCI.

## **1.2 Descripción del problema**

Hoy en día, el personal de mantenimiento automotriz continúa utilizando más el conocimiento basado en su experiencia y en métodos invasivos para diagnosticar e identificar fallos en el tren valvular u holgura de válvulas, esto debido a que actualmente aún no existen herramientas como el “escáner” de aplicación automotriz, que ayuden a realizar el diagnóstico de fallas que afecten alguno de los diferentes sistemas mecánicos del MCI, es decir, a pesar de que el “escáner” es una herramienta de uso ampliamente cotidiano, aún no cuenta con la capacidad de aplicar una estrategia de monitoreo que permita identificar diferentes condiciones de fallas en el tren valvular y que ayuden mejorar la fiabilidad del diagnóstico. Además, debido a la limitación del “escáner”, normalmente el diagnóstico de fallas mecánicas en el sistema valvular se vuelve heurístico, enfocándose solo a determinar si el sistema valvular está trabajando bien o presenta daño y no es capaz de efectuar una clasificación de diferentes tipos de condiciones de fallas; es decir, la severidad que presentan las fallas por la holgura de las válvulas, por lo tanto no es posible conocer que el tren valvular está llegando al final de su vida útil antes de que pueda generar problemas en otros componentes y esto vuelve muy complicado mantener y extender la vida útil del MCI al menor costo posible.

### 1.3 Justificación

En base a los antecedentes presentados y debido a que en la actualidad existen millones de automóviles con MCI circulando en el mundo y en México, existe una alta demanda ante la necesidad de desarrollar nuevas herramientas de monitoreo, detección y diagnóstico de fallas en los MCI, esta demanda se ha incrementado sustancialmente tanto en los talleres de servicio posventa de los concesionarios como en talleres particulares con el objetivo de incrementar la vida útil del MCI y al mismo tiempo minimizar los gastos de mantenimiento en términos generales.

Las fallas en los MCI ocasionadas particularmente en el sistema de válvulas, causan problemas directos al MCI que repercuten en su desempeño y afectan su velocidad de régimen permanente y crucero, también conducen a generar sobrecalentamiento, ruidos indeseables y afectación a otros componentes. Además, independientemente de la factibilidad de reemplazar componentes en el MCI, si las fallas no son detectadas oportunamente, pueden generar gastos innecesarios por largos periodos de tiempo debido al consumo excesivo de combustible, al mismo tiempo provocan emisiones contaminantes no deseables para el medio ambiente como hidrocarburos, monóxido de carbono y óxido de nitrógeno, entre otros.

Por tal motivo, es importante el uso de diferentes señales (vibración y corriente) y mediante técnicas de fusión y reducción de datos como LDA y PCA sería posible caracterizar diferentes severidades de fallas y obtener sus patrones característicos. Por otra parte, el uso de técnicas o algoritmos inteligentes de clasificación pueden ayudar en la identificación automática de fallas, facilitando el análisis de los efectos producidos por dichas fallas en el tren valvular, lo cual conduce a determinar el estado actual de su calibración y tomar las acciones necesarias de ajustes o mantenimiento al componente en cuestión.

Es por eso que un método de monitoreo y diagnóstico automatizado tomando en cuenta señales de vibración y corriente, puede representar una solución

práctica capaz de proporcionar diagnósticos fiables a diferencia de los métodos tradicionales que solo utilizan una variable (que por lo general de acuerdo a la literatura es vibratoria o acústica) y que además ayuden a reducir las horas-hombre empleadas en el diagnóstico y detección de fallas en las válvulas de los MCI.

También ayudaría a mantener el rendimiento y correcto funcionamiento del tren valvular y por otro lado, dejar sentadas las bases para el desarrollo de una interfaz y generar una herramienta que permita al personal de mantenimiento, diagnosticar este sistema cuantitativamente.

## **1.4 Hipótesis y Objetivos**

### **1.4.1 Hipótesis**

Mediante el uso de sensores de vibración y corriente es posible establecer una estrategia de monitoreo no intrusiva basada en técnicas de fusión de señales y técnicas de clasificación que permitan identificar diferentes condiciones de falla en el tren valvular de MCI, mejorando la fiabilidad del diagnóstico respecto a trabajos ya reportados.

### **1.4.2 Objetivo general**

Establecer un método de diagnóstico no intrusivo mediante técnicas de fusión de señales para la identificación de grados de severidad de falla del tren de válvulas en motores de combustión interna.

### **1.4.3 Objetivos específicos**

- 1) Instrumentar un motor de combustión interna con sensores para la obtención de señales de vibración y corriente; que permitan caracterizar la condición sana y su condición actual de operación del tren valvular mediante la calibración de diferentes alturas en las válvulas.
- 2) Realizar el procesamiento de las diferentes señales obtenidas, mediante el cálculo de indicadores estadísticos y el uso de técnicas de fusión de datos, análisis discriminante lineal y análisis de componentes principales, para

- caracterizar la condición sana y tres severidades de fallo en el tren valvular.
- 3) Evaluar tres severidades diferentes de fallo en el tren valvular de un motor de combustión interna, para adquirir una base de datos con los patrones característicos de las señales que describan a cada condición evaluada.
  - 4) Aplicar técnicas inteligentes de clasificación que ayuden a realizar la identificación automática de grados de falla, valorando las características para determinar el estado actual de calibración del tren valvular.
  - 5) Realizar la evaluación de la fiabilidad de la metodología de diagnóstico propuesta, mediante herramientas estadísticas, para establecer el grado de certeza de los resultados.

### **1.5 Planteamiento general**

Para el desarrollo de la metodología de monitoreo y diagnóstico de fallas en los sistemas valvulares de los MCI se propone hacer en primer lugar una inspección del motor revisando que tenga los requisitos mínimos necesarios para llevar a cabo la metodología propuesta como la puesta en marcha del motor y su operación continua. Posteriormente registrar las condiciones actuales para detectar posibles variaciones en el proceso de monitoreo y adquisición de señales y de ser necesario hacer los ajustes para mantener dichas condiciones controladas.

Antes de comenzar el proceso, es conveniente contar con la mayor información técnica disponible del motor y específicamente de los parámetros de calibración del tren valvular para realizar los ajustes necesarios dentro del rango especificado por el fabricante del motor. Finalmente se sugiere también hacer una evaluación previa de costo-beneficio de los instrumentos, sensores y equipo a utilizar para el desarrollo de la metodología propuesta en relación a los resultados esperados para no incurrir en costos excesivos e innecesarios.

## **2 FUNDAMENTACIÓN TEÓRICA**

El desarrollo de este trabajo de investigación requiere del conocimiento de varias herramientas teóricas de diversas disciplinas de la ingeniería, entre las más relevantes se encuentran métodos de la estadística descriptiva, inteligencia artificial, mecánica, entre otros.

### **2.1 Estadística descriptiva**

La estadística descriptiva con sus herramientas permite organizar, clasificar y analizar un conjunto de datos que puedan servir para extraer conclusiones válidas y representadas con valores. También propone metodologías que permiten deducir características poblacionales a partir de muestras de ella y que a continuación se describen brevemente.

#### **2.1.1 Herramientas estadísticas de clasificación**

##### **a) Segmentación**

Los patrones individuales tienen que ser segmentados. Si ya se ha reconocido un tipo de señal, entonces es más fácil segmentarla. Pero, ¿cómo se pueden segmentar las señales?, ¿antes de que sean clasificadas o clasificarlas antes de que hayan sido segmentadas? Parece que se necesita una forma de saber cuándo se ha cambiado de un modelo a otro, cuándo se tienen únicamente datos o cuándo están sin categoría. ¿Cómo se puede hacer esto? La mejor manera es, concentrar los datos en agrupaciones de tamaño correcto, y en la unidad más útil para el reconocimiento (Duda et al., 2012).

##### **b) Índices estadísticos basados en el tiempo**

Son herramientas para clarificar y definir, de forma más precisa las medidas verificables de cambio o resultado y que están diseñadas para contar con un estándar contra el cual evaluar, estimar o demostrar un cambio con respecto a parámetros ya establecidos.

En la Tabla 2.1 se muestran los índices estadísticos o características más comunes a utilizar en el análisis de las señales en el dominio del tiempo (Saucedo-Dorantes et al., 2017).

**Tabla 2.1 Indicadores estadísticos en el dominio del tiempo**

Indicador	Ecuación
Media $\bar{X}$	$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.1)$
Valor máximo $\hat{X}$	$\hat{X} = \max(x_i) \quad (2.2)$
Valor eficaz (Root Mean Square, $RMS$ )	$RMS = \sqrt{\frac{\sum_{i=1}^n (x_i)^2}{n}} \quad (2.3)$
Media cuadrática (Square Root Mean, $SMR$ )	$SMR = \left( \frac{\sum_{i=1}^n \sqrt{ x_i }}{n} \right)^2 \quad (2.4)$
Desviación estándar ( $\sigma$ )	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2} \quad (2.5)$
Varianza ( $\sigma^2$ )	$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2 \quad (2.6)$
Factor forma RMS (Shape Factor, $SF_{RMS}$ )	$SF_{RMS} = \frac{RMS}{\frac{1}{n} \sum_{i=1}^n  x_i } \quad (2.7)$
Factor forma SRM (Shape Factor, $SF_{SRM}$ )	$SF_{SRM} = \frac{SMR}{\frac{1}{n} \sum_{i=1}^n  x_i } \quad (2.8)$
Factor cresta ( $CF$ )	$CF = \frac{\bar{X}}{RMS} \quad (2.9)$
Factor latitud ( $LF$ )	$LF = \frac{\bar{X}}{SMR} \quad (2.10)$
Factor impulso ( $IF$ )	$IF = \frac{\hat{X}}{\bar{X}} \quad (2.11)$
Oblicuidad (Skewness, $S_k$ )	$S_k = \frac{\sum_{i=1}^n (x_i - \bar{X})^3}{\sigma^3} \quad (2.12)$
Curtosis ( $K_{ur}$ )	$K_{ur} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^4}{\sigma^4} \quad (2.13)$
Momento de nivel superior ( $M_g$ )	$M_g = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^g}{\sigma^g} \quad (2.14)$

### c) Normalización de datos

En muchas situaciones prácticas, se observan características cuyos valores residen dentro de diferentes rangos dinámicos. Por lo tanto, las características con valores grandes pueden tener una mayor influencia en la función, que las características con valores pequeños, aunque esto no necesariamente refleja su respectivo significado en el diseño del clasificador. El problema se supera normalizando las características para que sus valores se encuentren dentro de rangos similares. Una técnica sencilla es la normalización a través de las respectivas estimaciones de la media y la varianza como lo muestra la ecuación (2.15) (Theodoridis y Koutroumbas, 2006).

$$X_n = \frac{X_1 - \bar{X}_2}{\sigma_{X_2}} \quad (2.15)$$

Donde:

$X_n$  Es la nueva característica normalizada

$X_1$  Es la característica a normalizar

$X_2$  Es la característica original de referencia

$\bar{X}_2$  Es la media de la característica de referencia

$\sigma$  Desviación estándar de la característica de referencia

### 2.1.2 Reducción de indicadores

#### a) Análisis discriminante lineal

Hay muchas formas diferentes de representar clasificadores de patrones, uno de los más útiles es en términos de un conjunto de funciones discriminantes, por ejemplo  $g_i(x)$ ,  $i = 1, \dots, c$  y se dice que el clasificador asigna un vector de característica  $x$  a la clase  $\omega_i$  si se cumple la ecuación (2.16)

$$g_i(x) > g_j(x) \quad (2.16)$$

Para toda  $j \neq i$

Entonces para el caso de la tasa de error mínima, podemos tomar la función discriminante máxima, que corresponde a la probabilidad posterior máxima como se indica en la ecuación (2.17)

$$g_i(x) = P(\omega_i|x) \quad (2.17)$$

Por lo tanto, el clasificador se ve como una red o máquina que computa “ $c$ ” funciones discriminantes y selecciona la categoría correspondiente a lo largo del discriminante. La representación de una red de clasificación se ilustra en la Figura 2.1

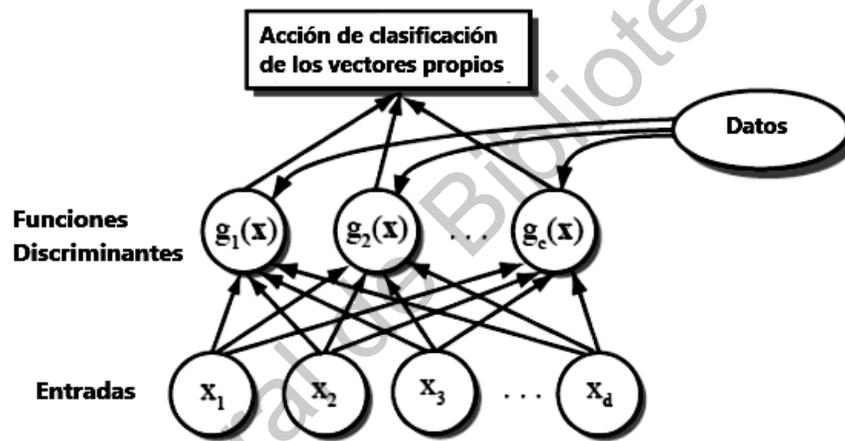


Figura 2.1 Representación de una red de clasificación (Fuente: Duda et al., 2012)

La estructura funcional de un clasificador estadístico general de patrones incluye  $d$  entradas y  $c$  funciones discriminantes  $g_i(x)$ . Un paso posterior determina cuál de los valores discriminantes es el máximo y clasifica el patrón de entrada, en consecuencia las flechas muestran la dirección del flujo de información, sin embargo frecuentemente las flechas se omiten cuando la dirección del flujo es evidente. (Duda et al., 2012).

El principal objetivo de la técnica LDA se encuentra en la búsqueda de una nueva proyección de menor dimensión donde la información más discriminativa entre los puntos de datos pertenecientes a diferentes clases se maximiza (Saucedo-Dorantes, 2017).

### b) Análisis de componentes principales

La PCA o la transformación de Karhunen-Loève es una técnica que tiene sus bases en el álgebra lineal, específicamente en las transformaciones lineales, no supervisada, es decir, que no se requiere conocer a que conjunto pertenecen las muestras y que se enfoca a la reducción de la dimensionalidad de una base de datos, para conservar tanto como sea posible la varianza del conjunto de datos originales.

Matemáticamente el concepto es bastante simple. Primero, se calcula la media del vector dimensional  $d$  y la  $\Sigma$  matriz  $d \times d$  de covarianza  $\mu$ , para el conjunto de datos normalizados completo. A continuación, se calculan los vectores propios y los valores propios de la matriz de covarianza y se ordenan de acuerdo con el valor propio decreciente, llamando estos vectores propios  $e_1$  con valor propio  $\lambda_1$ ,  $e_2$  con valor propio  $\lambda_2$ , y así sucesivamente. A continuación, se eligen los  $k$  vectores propios más largos. En la práctica, esto se hace mirando un espectro de vectores propios. A menudo habrá implicada una dimensionalidad  $x, x$  inherente al subespacio que rige la "señal". Las otras dimensiones son el ruido. Finalmente se forma una matriz  $A, k \times k$  cuyas columnas consisten en los vectores propios  $k$  (Duda et al., 2012).

El procesamiento de datos se hace de acuerdo a la ecuación (2.18) y en la Figura 2.2 se representa el plano siguiendo los argumentos del algebra lineal en la matriz de covarianza.

$$X' = A^t(X - \mu) \quad (2.18)$$

El resultado de la aplicación de la técnica PCA sobre un conjunto de indicadores, es un nuevo conjunto de indicadores llamados componentes principales. Donde cada componente principal es una combinación lineal de los indicadores originales. Además, dentro de las componentes principales no hay información redundante por ser ortogonales entre sí; así, gran parte de la información de los datos será conservada en pocas componentes principales, es decir, toda la variabilidad contenida en el conjunto de indicadores originales se

representará por el nuevo conjunto de indicadores extraídos (Saucedo-Dorantes, 2017).

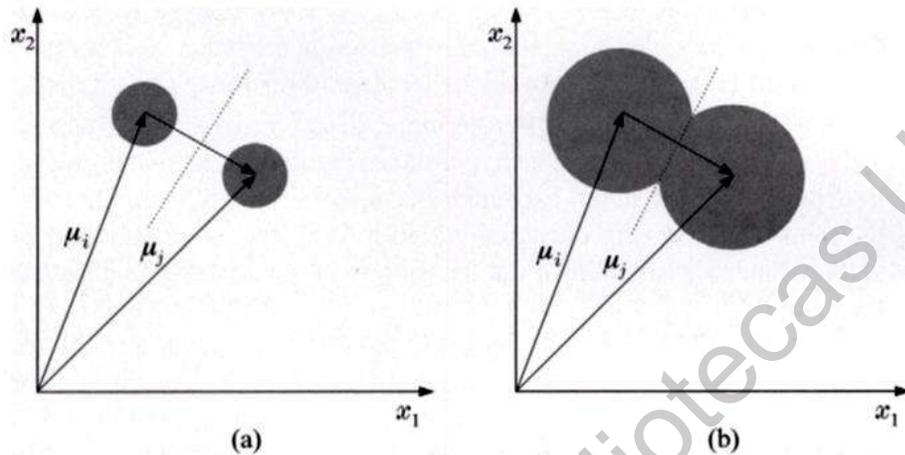


Figura 2.2 Línea de decisión para clases compactas y no compactas (Fuente: Theodoridis y Koutroumbas, 2006)

### 2.1.3 Indicadores de confiabilidad

Las mediciones de cualquier tipo en trabajos de investigación deben estar sustentadas en una precisión, fiabilidad o confiabilidad con un coeficiente que demuestre que un cierto conjunto o cantidad de pruebas experimentales estén en razón de lo esperado, incluso en las investigaciones más simples es cuestión vital la validez de sus medidas. Sin un coeficiente de validez y sin análisis factorial puede interpretarse una estimación adecuada de la magnitud medida como un error de medida. La mejor forma de conocer qué tan precisas son las medidas que un investigador efectúa, es hacer dos medidas independientes y compararlas.

Los métodos más conocidos son: el método de Spearman-Brown, el método de Kuder-Richardson, el método de Dressel y coeficiente alfa de Cronbach entre otros, aunque este último, es una de las medidas de confiabilidad más utilizadas en diferentes áreas (Cronbach, 1951).

La confiabilidad alfa de Cronbach describe la certeza de una suma o promedio de las mediciones de un conjunto de muestras, donde la cantidad de muestras definidas por  $k$ , pueden representar calificadores, elementos de

cuestionarios o pruebas. Cuando las medidas representan múltiples elementos de cuestionarios o pruebas, que es la aplicación más común, el alfa de Cronbach se conoce como una medida de confiabilidad de "consistencia interna". El coeficiente de alfa de Cronbach mide el grado en que las respuestas de los elementos obtenidos al mismo tiempo se correlacionan mucho entre sí, y se ha considerado como punto de corte ampliamente aceptado por la gran mayoría de las ciencias sociales y diferentes áreas de aplicación el valor de alfa de 0.70; por lo tanto, valores superiores a 0.70 representan una excelente confiabilidad. El coeficiente de alfa de Cronbach se define como:

$$\alpha = \frac{k}{k-1} \left( 1 - \frac{\sum \sigma_i^2}{\sigma_t^2} \right) \quad (2.19)$$

donde,  $\alpha$  es la confiabilidad estimada para un conjunto completo de muestras de una prueba,  $k$  es el número de muestras,  $\sigma_t^2$  es la varianza de todas las muestras de la prueba (el cuadrado de la desviación estándar), y  $\sum \sigma_i^2$  es la suma de las varianzas para la muestra  $k$  (Saucedo-Dorantes, 2017).

## 2.2 Técnicas empleadas en la fusión de Señales

Existen diferentes formas de fusionar datos y también algoritmos para realizar acciones de monitoreo y diagnóstico de fallas en diferentes sistemas industriales de acuerdo a la literatura investigada y aunque no específicamente aplicadas a fallas en trenes valvulares de motores de combustión interna, se ha conseguido incrementar la confiabilidad en el diagnóstico. Una simple forma es fusionar los indicadores estadísticos utilizados para el procesamiento de los datos aplicando las técnicas LDA o PCA, una segunda manera es fusionar los indicadores en el dominio del tiempo y los indicadores en el dominio de la frecuencia, solo que esta forma está limitada a fallas muy sencillas, también se pueden fusionar datos de múltiples fallas el cual en su procesamiento se emplea un filtro de respuestas infinitas de alta resolución espectral basado en un clasificador de señales múltiples, este tipo de fusión es precisa en la identificación de fallas pero requiere de mayor conocimiento y experiencia en el trabajo de procesamiento. También es posible

fusionar algoritmos genéticos para el diagnóstico y detección de fallas, utilizando una red neuronal artificial y un sistema adaptivo de inferencia neuro-difusa (Adaptive Neuro-Fuzzy Inference Systems-ANFIS) basados en indicadores de corriente y vibraciones realizan la toma de decisiones en el diagnóstico del estado del sistema para fallas típicas.

Existen otras maneras de fusionar datos con algunas variantes de las ya mencionadas como la fusión de datos con indicadores estadísticos en el dominio del tiempo de dos conjuntos de señales de diferentes características como son vibraciones y corrientes que es la forma que se utilizará en este caso. El principal objetivo es la búsqueda de una nueva proyección de menor dimensión en cada uno de los indicadores, donde la información más discriminativa entre los puntos de datos pertenecientes a diferentes clases se maximiza cuando se aplica la técnica LDA al conjunto de indicadores de señales de corriente y de señales de vibración. Por otro lado, el resultado de la aplicación de la técnica PCA sobre estos conjuntos de indicadores, es un nuevo conjunto de indicadores llamados componentes principales donde cada componente principal es una combinación lineal de los indicadores originales. Además, dentro de las componentes principales no hay información redundante por ser ortogonales entre sí; así, la mayor parte de la información del conjunto de señales de corriente y de vibración será conservada en componentes principales, es decir, toda la variabilidad contenida en el conjunto de indicadores originales de ambas señales, corriente y vibración, se representará por el nuevo conjunto de indicadores extraídos (Saucedo-Dorantes, 2017).

### **2.3 Inteligencia artificial**

La inteligencia artificial (IA) en el prólogo de su libro, (Russell y Norvig, 2002) comentan que es un campo enorme y que hay que explorar con plena profundidad acompañándolo constantemente de lógica, probabilidad y matemáticas; de percepción, razonamiento, aprendizaje y acción, es decir, de todo lo que procede de los dispositivos micro electrónicos hasta el planetario de la robótica. Una simple

definición según (Poole et al., 1998) definen IA desde la perspectiva de sistemas que actúan racionalmente como el estudio del diseño de agentes inteligentes.

### 2.3.1 Algoritmos inteligentes

Los algoritmos inteligentes son agentes que actúan dentro de un sistema y que tratan de emular una actividad similar a las neuronas humanas. Dichas actividades pueden ser: clasificación de características, reconocimiento de patrones, aprendizaje, y otras. Los algoritmos inteligentes a su vez pueden ser divididos en control difuso y redes neuronales como los más utilizados para la clasificación y reconocimiento de patrones, pero también se encuentran los algoritmos genéticos enfocados a la optimización y a lograr múltiples objetivos (Poole et al., 1998).

### 2.3.2 Redes neuronales artificiales

Una neurona es una célula en el cerebro cuya función principal es la recolección, procesamiento y difusión de señales eléctricas. La Figura 2.3 muestra un diagrama esquemático de una neurona típica.

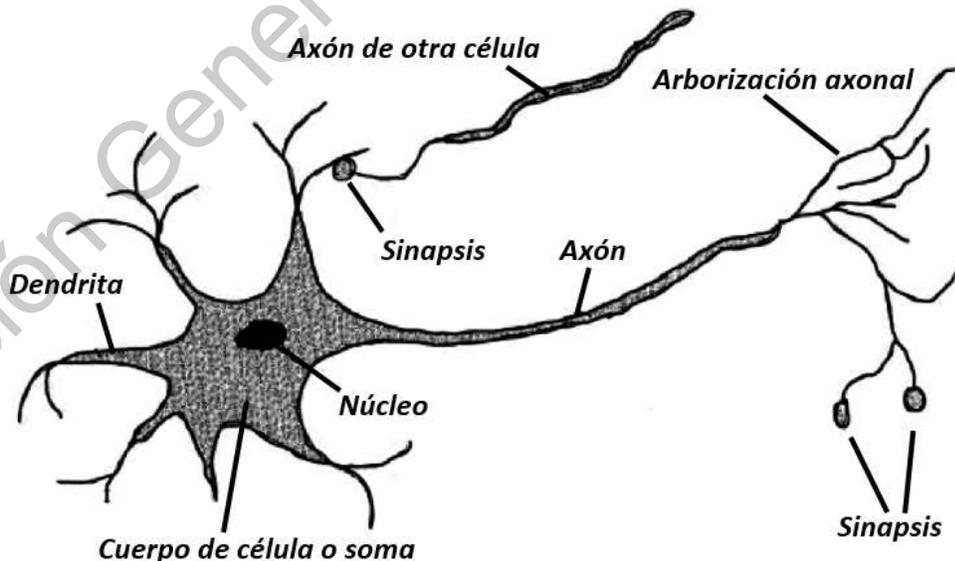


Figura 2.3 Célula nerviosa o neurona (Fuente: Russell y Norvig, 2002)

Se cree que la capacidad de procesamiento de información del cerebro emerge principalmente de redes de tales neuronas. Por esta razón, algunos de los primeros trabajos de IA tenían como objetivo redes neuronales artificiales.

Desde 1943 se han desarrollado modelos detallados y realistas, tanto para neuronas como para sistemas más grandes que conduce al campo moderno de la neurociencia computacional. Por otra parte, los investigadores en IA y las estadísticas se interesaron en las propiedades más abstractas de las redes neuronales, como su capacidad para realizar cálculos distribuidos, para tolerar entradas ruidosas, y para aprender. Se entiende que otros sistemas tienen estas propiedades, pero las redes neuronales siguen siendo una de las más populares y efectivas formas de sistema de aprendizaje. Las redes neuronales artificiales están compuestas de nodos o unidades conectados por enlaces (ver Figura 2.4).

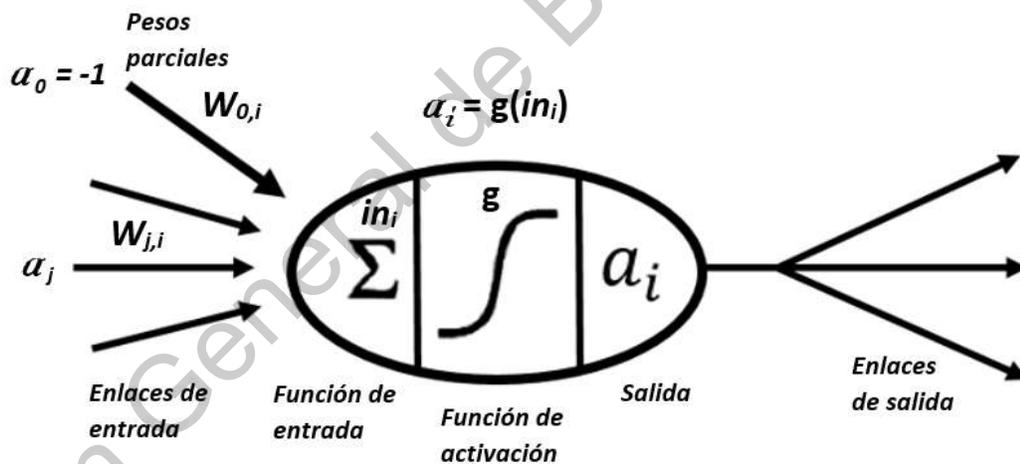


Figura 2.4 Modelo matemático simple de una neurona artificial (Fuente: Russell y Norvig, 2002)

Un enlace de la unidad  $j$  a la unidad  $i$  sirve para propagar la activación  $a_j$  de  $j$  a  $i$ . Cada enlace también tiene un peso  $W_{j,i}$  numérico asociado con éste, que muestra la fuerza y el signo de la conexión. Cada unidad  $i$  calcula primero una suma ponderada de sus entradas. El proceso se desarrolla conforme a la ecuación (2.20) y la ecuación (2.21).

$$in_i = \sum_{j=0}^n W_{j i} a_j \quad (2.20)$$

Luego se aplica una función de activación “ $g$ ” a esta suma para derivar la salida:

$$a_i = g(in_i) = g \sum_{j=0}^n W_{j i} a_j \quad (2.21)$$

Observe en la Figura 2.4 que se ha incluido un peso parcial ( $W_{0 i}$ , weight), conectada a una entrada fija  $a_0 = -1$ . La función de activación “ $g$ ” está diseñada para cumplir con dos desideratas. Primero, se requiere que la unidad esté "activo" (cerca de +1) cuando se dan las entradas "correctas" e "inactivo" (cerca de 0) cuando se dan entradas "incorrectas". En segundo lugar, la activación debe ser no lineal, de lo contrario, la totalidad de la red neuronal se colapsa en una función lineal simple (Russell y Norvig, 2002).

## 2.4 Mecánica automotriz

En términos generales la mecánica es una parte de la ciencia física que se encarga de estudiar los cuerpos en reposo y en movimiento, la cual encuentra una aplicación a través de la ingeniería en el área automotriz, específicamente en los motores de combustión interna.

### 2.4.1 Motor de combustión interna

Un motor de combustión interna es una máquina termodinámica formada por piezas y mecanismos fijos y móviles, cuya función principal es la de transformar energía química que proporciona la combustión de una mezcla de aire y combustible, en energía mecánica. Esta energía mecánica se puede utilizar como trabajo útil para mover una carga, como por ejemplo un generador de corriente directa de 12 volts, o una caja de engranes. Desafortunadamente solo una parte de la energía calorífica del combustible quemado en las cámaras de combustión del motor, se transforma en energía mecánica, el resto se pierde en calor y fuerzas de fricción como se muestra en la Figura 2.5. Es evidente que el aprovechamiento real

es bajo, por lo cual se hace importante mantener en funcionamiento un motor lo más eficiente posible (Agüero-Alva, 2002).

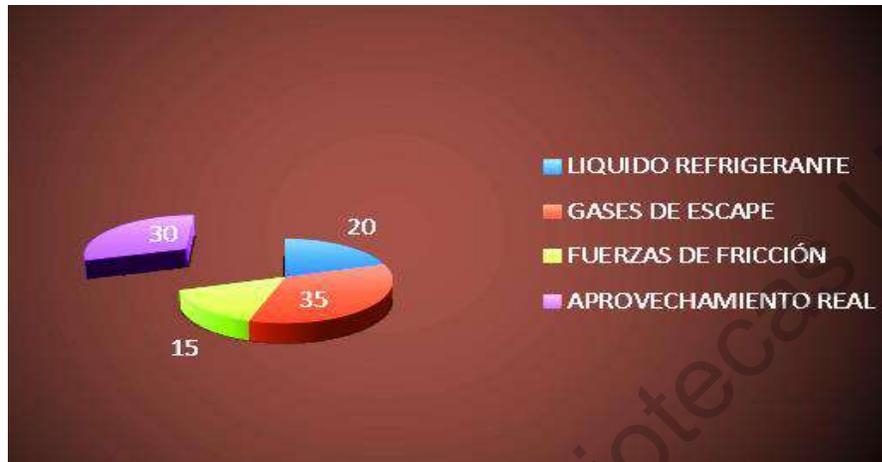


Figura 2.5 Porcentaje de calorías pérdidas y aprovechadas en un MCI (Autoría propia)

#### 2.4.2 Ciclo Otto y tren valvular

Los ciclos teóricos del motor de combustión a volumen constante fueron estudiados por Beau Rochas, pero su aplicación práctica se le debe a Nicolaus August Otto que construyó los primeros motores a gasolina, aproximadamente en 1862. El ciclo Otto es un ciclo cerrado, que utiliza una mezcla de aire y combustible y para su ignición ocupa una chispa eléctrica. Este ciclo consta de 4 etapas o tiempos: aspiración, compresión, combustión y fuerza. Sin embargo, en la práctica no se producen las aperturas y cierres de las válvulas de admisión y escape exactamente en los puntos muertos superior e inferior, sino que ocurren antes o después. Tampoco los tiempos ocurren a presión constante en admisión y escape o a volumen constante en la compresión y fuerza. En la Figura 2.6 se ilustra el proceso real.

En la admisión a) el pistón se desplaza desde el PMS (Punto Muerto Superior) al PMI (Punto Muerto Inferior) y mientras la válvula de admisión permanece abierta el cilindro se llena con la mezcla de aire y combustible, al final de la admisión en el PMI, la válvula de admisión se cierra. Durante la compresión b) con las válvulas de admisión y escape cerradas, el pistón se desplaza desde el

PMI al PMS y se comprime adiabáticamente la mezcla de aire y combustible. La explosión o encendido c) ocurre cuando el pistón llega al PMS y una chispa se enciende en la bujía para quemar la mezcla aumentando la presión en la cámara de combustión, con las válvulas de admisión y escape cerradas, el pistón se desplaza desde el PMS al PMI generando un trabajo positivo; esta evolución en principio también es adiabática. Por último en la etapa de escape d) el pistón se desplaza desde el PMI al PMS con la válvula de escape abierta, en este momento la presión dentro del cilindro es igual a la presión atmosférica, por lo que el trabajo requerido es igual a cero.

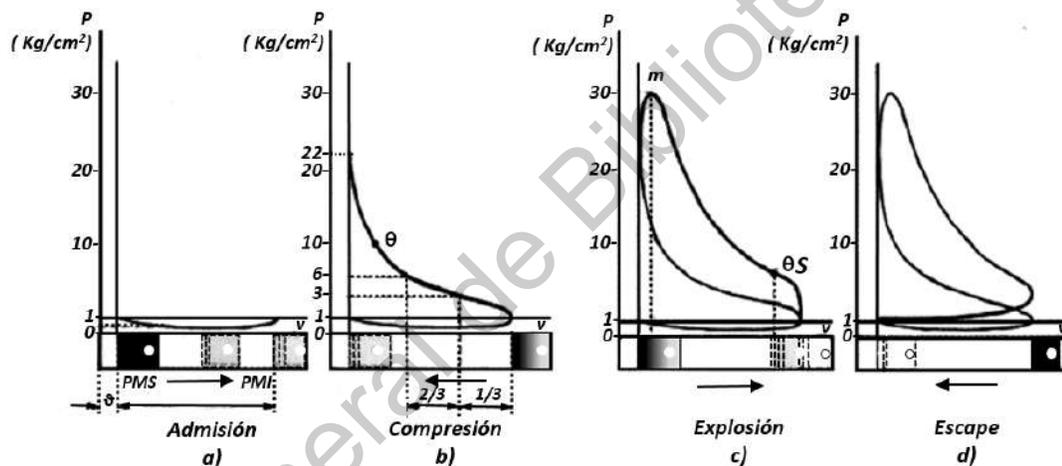


Figura 2.6 Proceso real del ciclo Otto (Fuente: Agüero-Alva, 2002)

El tren valvular o tren de válvulas es un grupo de componentes que pertenece al sistema de distribución del MCI formado por las válvulas de admisión y escape, levanta válvulas (punterías hidráulicas o mecánicas), varillas de empuje, balancines, tornillos ajustadores, resortes y elementos de fijación, para motores con válvulas en la cabeza (OHV-Over Head Valve) y sus variantes árbol a la cabeza (OHC-Over Head Cam) y doble árbol a la cabeza (DOHC-Double Over Head Cam). El tren valvular tiene como finalidad controlar el ingreso de la mezcla de aire y combustible a los cilindros del motor, permitir la salida de los residuos de la combustión de los cilindros al exterior y hermetizar las cámaras de combustión. Las características de funcionamiento del MCI dependen en mucho del tiempo que

permanecen abiertas las válvulas y de la altura que se levantan. En la Figura 2.7 se muestra un típico arreglo de válvulas.

La apertura y cierre de la válvula en el momento preciso se conoce como sincronización de válvulas y la potencia del motor depende en mucho de esta sincronización y de la elevación de la válvula, siendo un factor importante que determina la cantidad de mezcla aire-combustible (Agüero-Alva, 2002).

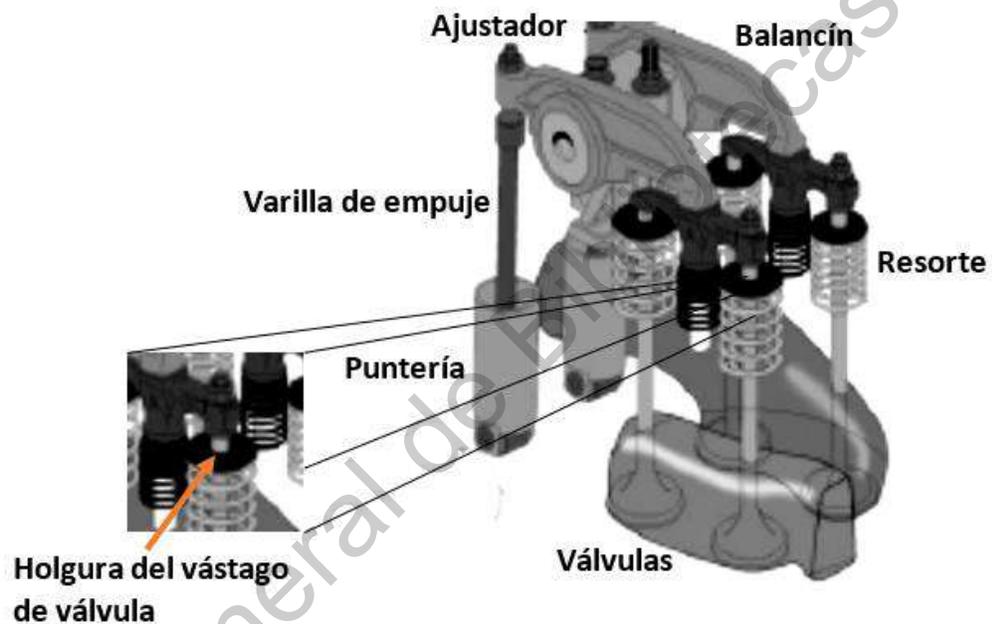


Figura 2.7 Configuración de un tren valvular para motores OHV (Fuente: Agüero-Alva, 2002)

### 2.4.3 Falla en el tren valvular y sus repercusiones en el MCI

Una falla está definida como una operación no deseada en un sistema, subsistema o componente del MCI, lo que lleva a definir que la falla generalizada en el tren valvular es “la holgura” entre el vástago de las válvulas y el balancín o leva del árbol, dependiendo del tipo de sistema valvular y dicha falla puede ser causada por los diferentes componentes ya mencionados en la sección 2.4.2. La falla del tren valvular genera a su vez otras fallas más específicas en el MCI como son:

- 1) El motor marcha erráticamente o falla en marcha mínima.
- 2) Velocidad del motor excesiva en marcha mínima.

- 3) El motor titubea durante la aceleración.
- 4) El motor marcha erráticamente en todas las revoluciones.
- 5) Falta de potencia al motor por holgura de válvulas demasiado ajustadas.
- 6) Ruidos misceláneos o golpeteos en el motor por válvulas con mucho claro.
- 7) El motor hace explosiones descontroladas (Warren y Haynes, 1995).

Estas fallas repercuten de manera significativa en la operación eficiente del MCI, lo cual hace evidente la importancia de tener un mantenimiento correcto del tren valvular.

Dirección General de Bibliotecas UAG

### 3 METODOLOGÍA

Para desarrollar la metodología de diagnóstico enfocada a la detección de fallas en un tren de válvulas en MCI basada en fusión de señales se deben de seguir una serie de pasos que se describen de forma gráfica en la Figura 3.1. De forma general, el desarrollo del trabajo en su fase de experimentación involucra la instrumentación con sensores de un MCI de seis cilindros con válvulas a la cabeza (OHV-Over Head Valve), la evaluación iterativa de diferentes severidades de falla en el sistema valvular y la adquisición de señales de vibración y corriente para cada experimento.

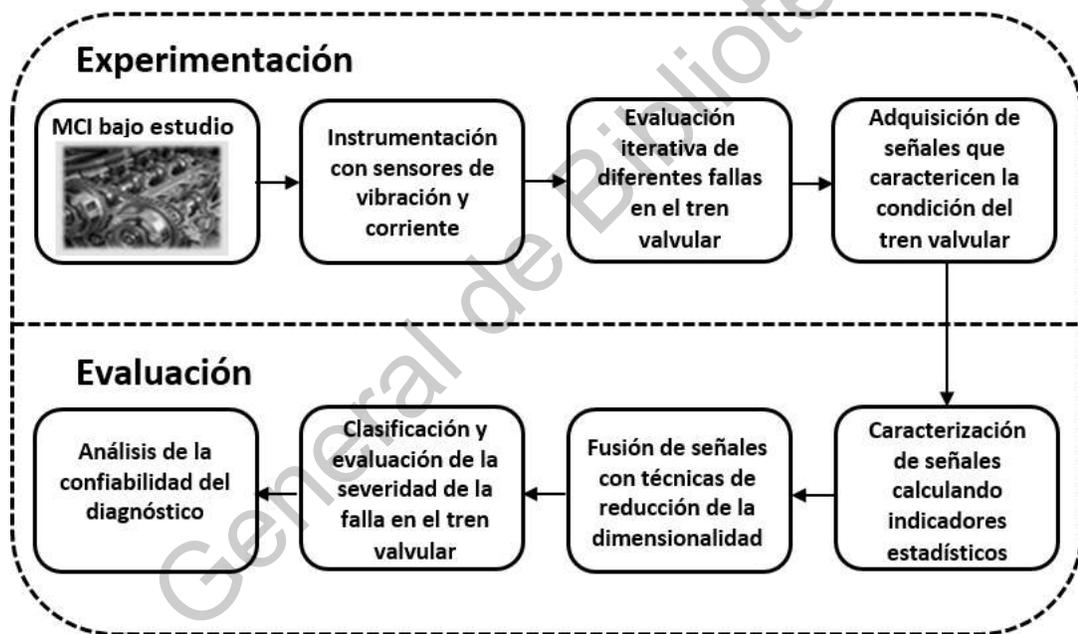


Figura 3.1 Diagrama de bloques de la metodología en general (Autoría propia)

En la fase de evaluación se usa la base de datos generada con la adquisición de señales en la fase de experimentación para un procesamiento de fusión de señales con técnicas de reducción de dimensionalidad, posteriormente se clasifican y evalúan las diferentes condiciones de fallas en forma automática y finalmente se realiza un análisis de la fiabilidad de los resultados.

### 3.1 Experimentación

#### 3.1.1 MCI bajo estudio

Las pruebas experimentales para validar la metodología de diagnóstico propuesta, se realizaron en un motor de combustión interna de seis cilindros cuyos datos técnicos se muestran en la Tabla 3.1

**Tabla 3.1 Datos técnicos del motor de combustión interna utilizado en las pruebas experimentales**

Tipo de motor	Inclinado en línea
Desplazamiento volumétrico	225 Pulgadas cúbicas
Relación de compresión	8.4:1
Presión de compresión	130 a 160 Libras / Pulgada cuadrada
Disposición de válvulas	Válvulas a la cabeza
Disposición de árbol de levas	En el bloque
Tipo de tren valvular	Balancines y punterías mecánicas
Tiempo de ignición básica	5° APMS (Antes del Punto Muerto Superior)
Condición actual	Reconstruido en 10 milésimas arriba del estándar
Kilometraje de trabajo	9,546 Km después de su reconstrucción

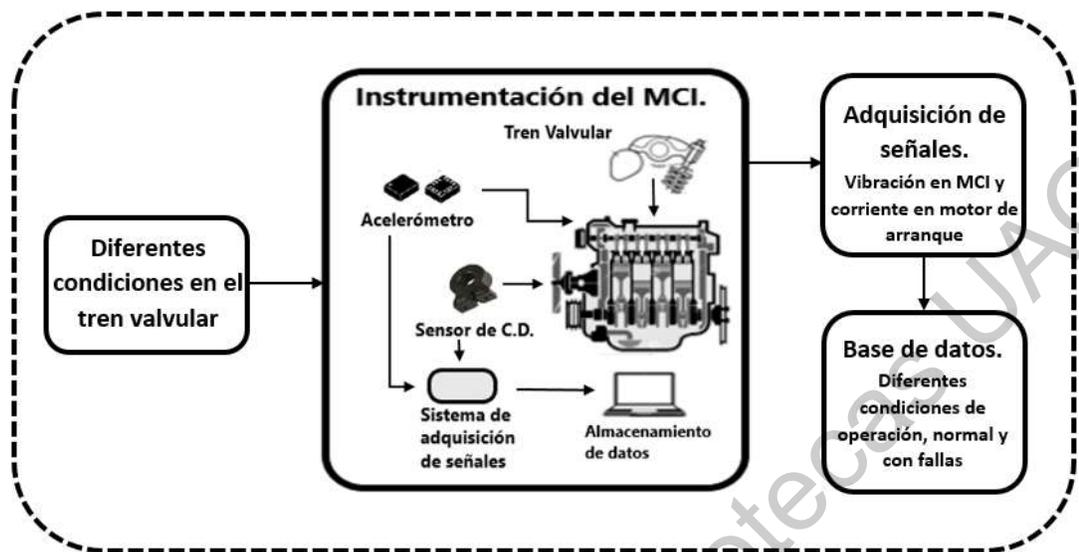


Figura 3.2 Diagrama de bloques en detalle para la fase de experimentación (Autoría propia)

Para evaluar las diferentes condiciones en el tren valvular del MCI como se muestran en el diagrama de la Figura 3.2 se acondicionó con sensores para medir vibración y corriente montados individualmente en tarjetas conectados a un sistema de adquisición de datos con cable blindado a prueba de ruido eléctrico. Posteriormente se procedió a verificar la condición inicial del tren valvular para fijar una referencia o condición sana conforme a las especificaciones del fabricante. En este caso específico se calibró la holgura de cada válvula a temperatura normal de operación del motor (82° a 87° Celsius). La calibración se llevó a cabo apretando o aflojando el tornillo ajustador del balancín en cada juego de válvulas. Las válvulas de admisión se calibraron con laines de 0.010" y las válvulas de escape con laines de 0.020" como se muestra en Figura 3.3. Posteriormente se permitió el reposo del MCI hasta la temperatura ambiente para llevar a cabo las pruebas en condición sana. Una vez realizado este paso, se procedió a la adquisición de señales de la condición actual y las distintas condiciones de severidad provocadas artificialmente y al término de cada experimento realizado, se capturaron los datos adquiridos en una computadora personal.

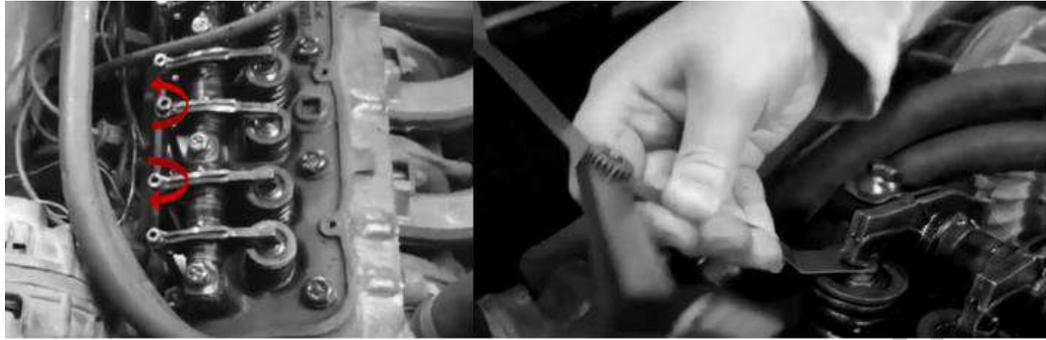


Figura 3.3 Calibración de la condición sana del tren valvular (Autoría propia)

### 3.1.2 Instrumentación del MCI

Para la instrumentación se instalaron, un sensor de vibración digital de 3 ejes con bajo nivel de ruido sobre la culata del MCI cerca del cilindro 3 y dos sensores de corriente instalados en dos cables derivados lado maza (-) cerca de la batería como se muestra en Figura 3.4 y Figura 3.5. **Error! No se encuentra el origen de la referencia.** Cada uno de los sensores cuenta con su etapa de acondicionamiento para evitar el efecto de anti-alias conectados a un sistema de adquisición de datos con cable blindado a prueba de ruido. Los datos técnicos de cada sensor se muestran en la Tabla 3.2

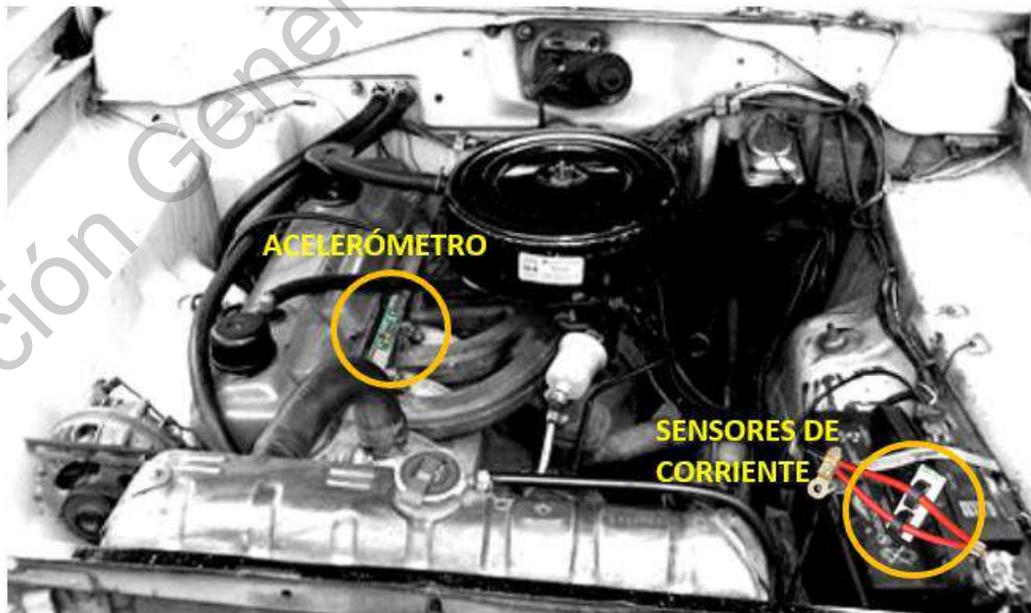


Figura 3.4 Panorámica de la colocación de los sensores de vibración y corriente en el MCI (Autoría propia)

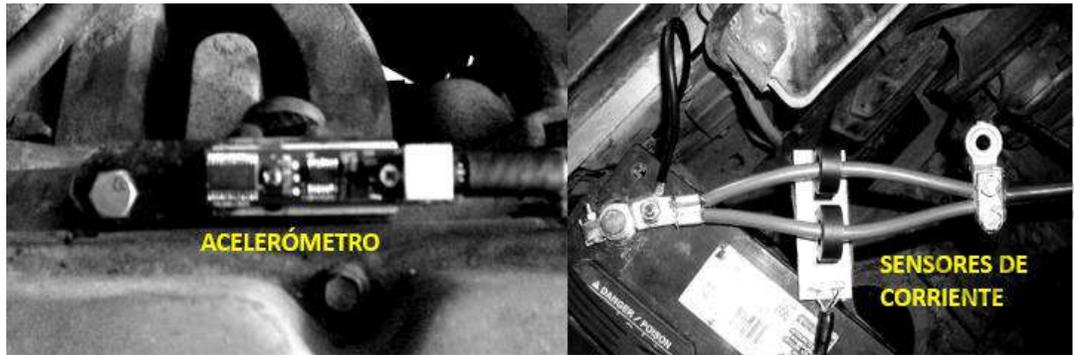


Figura 3.5 Detalle de colocación de sensores de vibración y corriente en el MCI (Autoría propia)

Los sensores sirven para monitorear de forma continua la operación del tren valvular solamente durante el periodo de puesta en marcha del MCI en los experimentos de condición sana y condiciones de falla.

Tabla 3.2 Especificaciones técnicas de los sensores de vibración y corriente

Sensor de Vibración LGA-14L	Sensor de Corriente CSAL-1DJ
Salida digital de 3 ejes	Corriente de pico censada: 225 ACD
Frecuencia de respuesta: 3 KHz (+/- 3 db)	Tiempo de respuesta: 3 $\mu$ Seg.
Temperatura de operación: - 40 a +105°C	Temperatura de operación: - 25 a + 85°C
Fuente de alimentación: Corriente Directa	Fuente de alimentación: Corriente Directa
Voltaje de operación: 2.1 V a 3.6 V	Voltaje de operación: 8 V a 16 V
Consumo de corriente: 1.1 mA máximo	Consumo de corriente: 19 mA máximo
Filtro pasa-baja y pasa-alta seleccionable	Sensibilidad de 13.2 mV a 12 VCD +/- 1.2 mV

### 3.1.3 Evaluación iterativa

La falla en el tren valvular como se describió en la sección 2.4.3 puede tener diferentes grados o condiciones de severidad y en la metodología propuesta se experimentó con tres condiciones. Las condiciones de severidad fueron simuladas artificialmente ajustando y desajustando el tornillo ajustador del balancín como se muestra en la Figura 3.6.

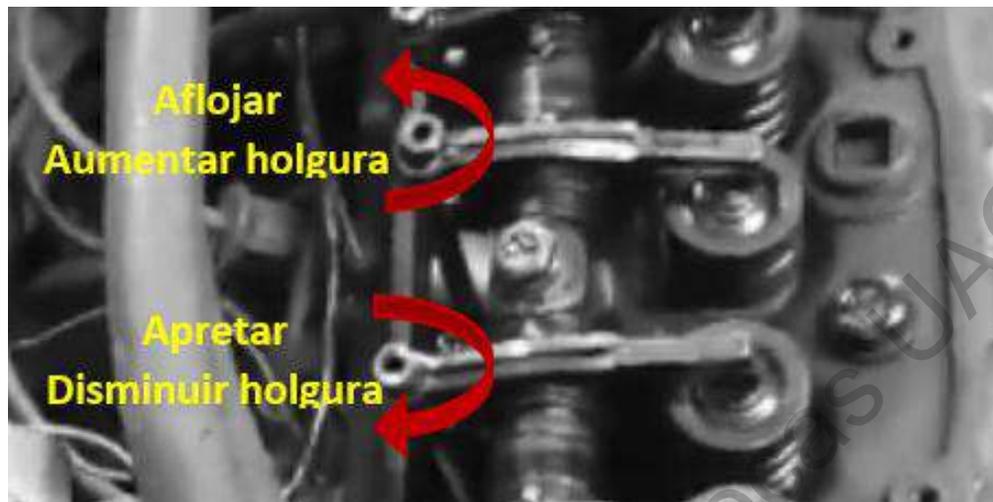


Figura 3.6 Calibración de holgura para condición de severidad (Autoría propia)

Este método se utilizó debido a que a partir de una holgura de 0" de la válvula, ya no es posible medir con laines, ya que siempre estaría en contacto el vástago con el balancín independientemente de la holgura. Tabla 3.3 Matriz de experimentos para 4 condiciones de operación muestra el número de experimentos realizados para diferentes condiciones de severidad.

Tabla 3.3 Matriz de experimentos para 4 condiciones de operación

	Condición del Tren Valvular del MCI				
	Sano	Apretadas	Apretadas	Flojas	
Válvula de admisión	0°	720°	360°	- 540°	Cilindros Afectados
Válvula de escape		720°	360°	- 540°	
Número de experimento	1	2	3	4	1, 2, 3, 4 ,5, 6
	5	6	7	8	

### 3.1.4 Adquisición de señales

Se adquirieron datos de vibraciones y corriente mediante una tarjeta de adquisición de datos (DAS) con un convertidor analógico-digital (modelo ADS7841)

de 12 bits de 4 canales de salida en serie. La tarjeta DAS es un diseño basado en tecnología de arreglo de compuertas lógicas programables en campo (FPGA-Field Programmable Gate Array), ver **¡Error! No se encuentra el origen de la referencia.** Las frecuencias de muestreo que se utilizaron durante la adquisición de las vibraciones y corrientes se fijaron en 3 kHz y 6kHz respectivamente. La tarjeta DAS se programó para adquirir estas señales durante el régimen de puesta en marcha, es decir, cuando el motor de arranque hace girar el volante de inercia del MCI pero con el sistema de ignición desconectado para no permitir el arranque del mismo. Cada experimento o condición de operación se efectuó en dos partes de seis pruebas cada una, espaciadas durante veinte minutos para mantener la temperatura del MCI sin variaciones mayores a 2° Celsius. Cada prueba se efectuó durante 10 segundos monitoreando continuamente el voltaje de batería entre 11.8 a 12.7 volts y la temperatura del MCI entre 24° y 26° Celsius.



Figura 3.7 Tarjeta DAS (FPGA-Field Programmable Gate Array) (Fuente: Morales-Velázquez, 2013)

Una vez que se realizaron los experimentos de una condición de operación del tren valvular con sus respectivas pruebas, todos los datos adquiridos por la tarjeta DAS fueron transmitidos y almacenados en una computadora personal para

su análisis de gabinete. Posteriormente se procedió a inducir una falla de holgura de válvulas artificialmente para tres diferentes condiciones de severidad que se detallan en la siguiente sección, repitiendo el mismo proceso de adquisición de señales como se explicó anteriormente. Cabe mencionar que la información cuantificada por el sensor de vibración fue adquirida de puntos cercanos al tren de válvulas en base a lo reportado en la literatura y respecto a la información del sensor de corriente, esta fue adquirida del motor de arranque empleado en el MCI.

## **3.2 Evaluación**

Se evaluó una condición sana y tres severidades diferentes de falla en el tren valvular de un motor de combustión interna con la finalidad de obtener un patrón característico de dichas condiciones a partir de la base de datos del conjunto de señales adquiridas en la fase de experimentación (ver sección 3.1.4).

### **3.2.1 Caracterización**

Primero: después de adquirir las señales de vibración y corriente, los patrones individuales se segmentaron para facilitar la identificación de un cambio de modelo, concentrando los datos en conjuntos de un tamaño correcto y en la unidad más útil para el reconocimiento. El tamaño y cantidad de los segmentos se calcularon en base a los ciclos de trabajo del MCI de seis cilindros, donde un ciclo completo lo realiza en dos revoluciones del cigüeñal y a 127 revoluciones por minuto (rpm) tarda aproximadamente 0.942 segundos. De acuerdo al procedimiento de adquisición de datos como se describió en la sección 3.1.4 se eliminó la fase transitoria inicial y final del conjunto de datos de cada prueba y se calculó un ciclo completo del MCI para cada segmento, por lo que resultó cada prueba dividida en 36 segmentos cada una.

Segundo: después de haber efectuado la segmentación se calcularon los indicadores estadísticos que describen el comportamiento y tendencia de las señales de vibración y corriente adquiridas; así, se realizó la caracterización de las señales adquiridas mediante la estimación numérica del conjunto de cuatro

indicadores estadísticos del dominio de tiempo, media de la raíz cuadrada, desviación estándar, sesgo y kurtosis, con la finalidad de obtener la caracterización de los patrones de las señales que representan diferentes condiciones de operación del tren valvular del MCI.

Tercero: en la etapa de reducción de indicadores, el conjunto original de cuatro indicadores estadísticos se sometió a un proceso de compresión y transformación de base mediante la aplicación de las técnicas de reducción de la dimensionalidad PCA y LDA. La finalidad de la aplicación del proceso de reducción es obtener una representación visual en un espacio bidimensional (2D); además, el uso de estas técnicas permite fusionar la información de cada uno de los indicadores estadísticos lo que conduce a una mejor caracterización de las condiciones evaluadas.

### **3.2.2 Fusión de señales**

Cuando se aplica la técnica análisis discriminante lineal (LDA- Linear Discriminant Analysis) al conjunto de indicadores de señales de corriente y de señales de vibración, el principal objetivo es la búsqueda de una nueva proyección de menor dimensión en cada uno, donde la información más discriminativa entre los puntos de datos pertenecientes a diferentes clases se maximiza. Por otro lado, el resultado de la aplicación de la técnica PCA sobre estos conjuntos de indicadores, es un nuevo conjunto de indicadores llamados componentes principales donde cada componente principal es una combinación lineal de los indicadores originales. Además, dentro de las componentes principales no hay información redundante por ser ortogonales entre sí; así, la mayor parte de la información del conjunto de señales de corriente y de vibración será conservada en componentes principales, es decir, toda la variabilidad contenida en el conjunto de indicadores originales de ambas señales, corriente y vibración, se representará por el nuevo conjunto de indicadores extraídos.

### 3.2.3 Clasificación y evaluación

Mediante la aplicación de un clasificador basado en una red neuronal de estructura simple se obtiene el diagnóstico y clasificación automática de la severidad de la falla en el tren valvular del MCI. El uso de la red neuronal como herramienta de clasificación ayuda a generar una estructura de diagnóstico automática debido a que las salidas del diagnóstico están basadas en el análisis de los resultados obtenidos por el uso de las técnicas PCA y LDA. Es decir, dicho clasificador se enfocará en realizar la clasificación basándose en el análisis de las proyecciones resultantes en el espacio bidimensional (2D).

Se aplica la técnica PCA que permitirá tomar información de los indicadores estadísticos usados en las diferentes condiciones de operación y que no necesariamente pertenecen solo a una condición, esta nueva información fusionada da como resultado una caracterización completa de las señales de corriente y vibración de las condiciones evaluadas del tren valvular. También se aplica la técnica LDA al conjunto de indicadores estadísticos de las señales de corriente para la condición sana y las tres severidades de falla en el tren valvular, para obtener la separación entre clases, es decir, una separación entre los datos de cada condición de operación.

### 3.2.4 Análisis de la confiabilidad

El análisis de confiabilidad está basado en calcular el coeficiente Alfa de Cronbach ( $\alpha$ ); por lo tanto, este coeficiente  $\alpha$  se calcula para medir la consistencia interna de la clasificación de salida de cada una de las muestras que generan las matrices de confusión obtenidas en los resultados de diagnóstico y clasificación de diferentes condiciones. La Tabla 3.4 muestra la matriz de experimentos para validar la metodología propuesta.

Tabla 3.4 Matriz de experimentos para la validación de la metodología

	Condición del Tren Valvular del MCI			
	Apretadas	Apretadas	Flojas	
Válvula de admisión	720°	360°	- 540°	Cilindros Afectados
Válvula de escape	720°	360°	- 540°	
Número de experimento	10	11	12	Cilindro 1
	13	14	15	Cilindros 1 y 5

Dirección General de Bibliotecas UAO

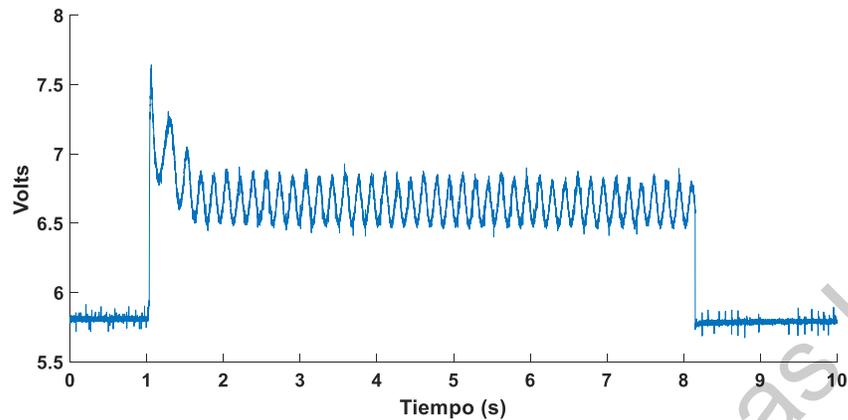
## 4 RESULTADOS

En este capítulo se describen los resultados obtenidos al aplicar la metodología propuesta de diagnóstico para la detección de fallas en sistemas valvulares en motores de combustión basada en fusión de señales y sus respectivas aplicaciones. El procesamiento de las señales adquiridas y la aplicación de la metodología de diagnóstico propuesta se hizo bajo el entorno de programación de Matlab®.

### 4.1 Procesamiento de señales

#### 4.1.1 Condición sana del tren valvular

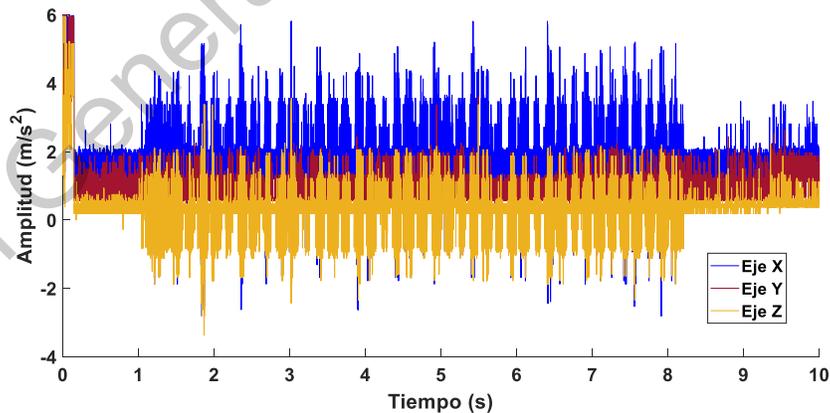
Para establecer la operación normal del tren valvular o condición sana se calibró la holgura de cada válvula a temperatura normal de operación del motor (82° a 87° Celsius) apretando o aflojando el tornillo ajustador del balancín en cada juego de válvulas. Las válvulas de admisión se calibraron con laines de 0.010" mientras que las válvulas de escape se calibraron con laines de 0.020" y para llevar a cabo las pruebas experimentales se permitió el reposo del MCI hasta la temperatura ambiente como se describió en la sección 3.1.4 En la Figura 4.1 se muestra el conjunto de señales de corriente adquiridas a una frecuencia de muestreo de 6 kHz, donde se puede observar un voltaje de pico de 7.641 volts que corresponde a una medida indirecta de la corriente consumida por el motor de arranque al inicio del ciclo, considerado como un periodo transitorio debido a que el arranque del MCI comienza desde el reposo, a su vez, esto provoca una fuerza estática en el cigüeñal y finalmente causa una corriente de pico en la armadura del motor de arranque en un tiempo relativamente corto antes de ser limitada por la fuerza contra-electromotriz (FCEM). Durante el periodo estable del ciclo de arranque del MCI se puede observar una señal estable, donde el voltaje promedio de referencia del sensor de corriente durante este periodo es de 6.645 volts y por otro lado los picos máximos y mínimos que se observan a lo largo de la gráfica representan el ciclo de compresión y escape de cada cilindro del MCI.



**Figura 4.1** Señales de corriente adquiridas del motor de arranque en la fase de puesta en marcha del MCI para la condición sana del tren valvular.

Las señales de vibraciones producidas por el MCI fueron adquiridas por el sensor acelerómetro a una frecuencia de muestreo de 3 kHz como se describió en la sección 3.1.4, cuando este se encontraba operando en la fase de arranque bajo la influencia de una condición sana.

El conjunto de señales de vibración en los ejes X, Y, Z del MCI para la condición sana del tren valvular se muestra en la Figura 4.2.



**Figura 4.2** Señales de vibración en el eje X, Y, Z adquiridas del MCI en su fase de puesta en marcha para la condición sana del tren valvular.

En esta gráfica se puede observar un patrón uniforme de las señales durante el período estable de cada ciclo de compresión y escape de los cilindros y por otra parte la magnitud de las vibraciones en el eje “X” que corresponde a la

posición transversal del MCI, son mayores con respecto a los otros ejes debido a la disposición en “línea” de los cilindros del MCI

#### 4.1.2 Condiciones de falla del tren valvular

Como anteriormente se mencionó, la adquisición de las señales de corriente y vibración se realizó durante 10 segundos cuando el MCI operaba en su etapa de arranque aproximadamente a 127 rpm. En la Figura 4.3 se muestran las señales de corriente adquiridas en su período estable, cuando se encuentra operando el MCI en fase de arranque, bajo la condición sana y la influencia de fallos inducidos en la holgura de válvulas en el tren valvular con sobre-ajustes de  $720^\circ$ ,  $360^\circ$  y sub-ajuste de  $540^\circ$  respectivamente.

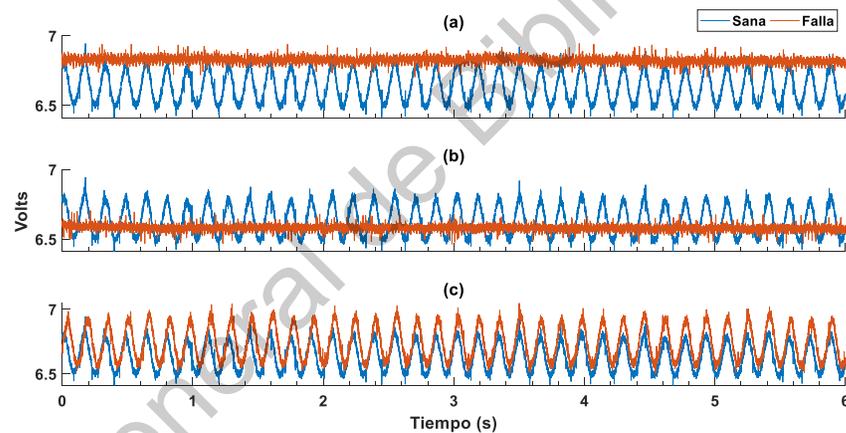
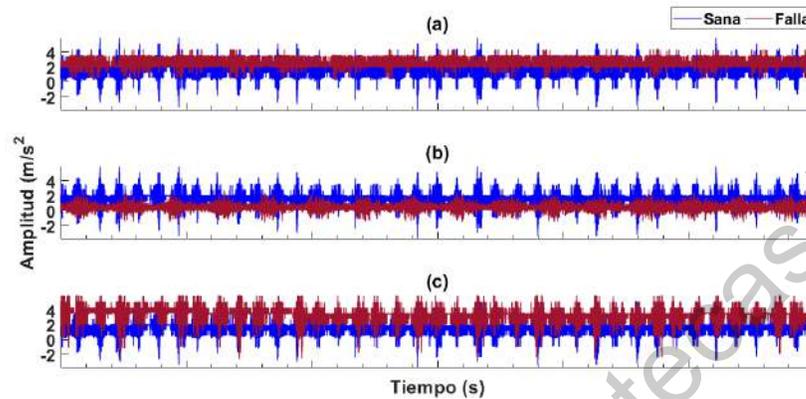


Figura 4.3 Señales de corriente adquiridas del motor de arranque del MCI durante su fase de puesta en marcha para la condición sana y tres severidades de falla de holgura en el tren valvular: (a)  $720^\circ$  de sobre-ajuste, (b)  $360^\circ$  de sobre-ajuste y (c)  $540^\circ$  de sub-ajuste.

Se puede observar una clara diferencia en la magnitud media del voltaje de referencia y las frecuencias producidas por el motor de arranque del MCI, la cual tiene una buena representación por estar asociada al mal funcionamiento del tren valvular y tendrá un patrón específico representativo.

Por otra parte, con las vibraciones también se puede observar una clara diferencia en el incremento y decremento de la amplitud en las vibraciones producidas por el MCI cuando se encuentra operando bajo la influencia del fallo inducido por estar relacionada al mal funcionamiento del tren valvular como se

muestra en la Figura 4.4 y las cuales también tendrán una caracterización específica.



**Figura 4.4** Señales de vibración en el eje “X” adquiridas del MCI durante su fase de puesta en marcha para la condición sana y tres severidades de falla de holgura en el tren valvular: (a) 720° de sobre-ajuste, (b) 360° de sobre-ajuste y (c) 540° de sub-ajuste.

Posteriormente, cada una de las señales de vibración y corriente adquiridas fue segmentada en partes iguales de 0.942 segundos que corresponden a un ciclo completo de seis cilindros del MCI a 127 rpm, con la finalidad de formar un conjunto de muestras consecutivas y que faciliten la identificación del cambio de modelo para su reconocimiento. Enseguida, se calcularon los cuatro indicadores estadísticos en el dominio del tiempo: valor eficaz (RMS-Root Mean Square), ecuación (2.3) la desviación estándar ( $\sigma$ ), de acuerdo a la ecuación (2.5), el sesgo ( $Sk$ ), con la ecuación (2.12), y la curtosis ( $Kur$ ), como se muestra la ecuación (2.13) para obtener una caracterización de las señales adquiridas, sobre cada uno de los segmentos de las señales. En la Figura 4.5 se muestra una de las representaciones visuales de los 4 indicadores estadísticos calculados para cada segmento de las diferentes condiciones de operación, sano y tres condiciones de fallo, para este caso, la gráfica corresponde a los indicadores de vibración en el eje “X” y para los indicadores de la señal de corriente la representación es similar.

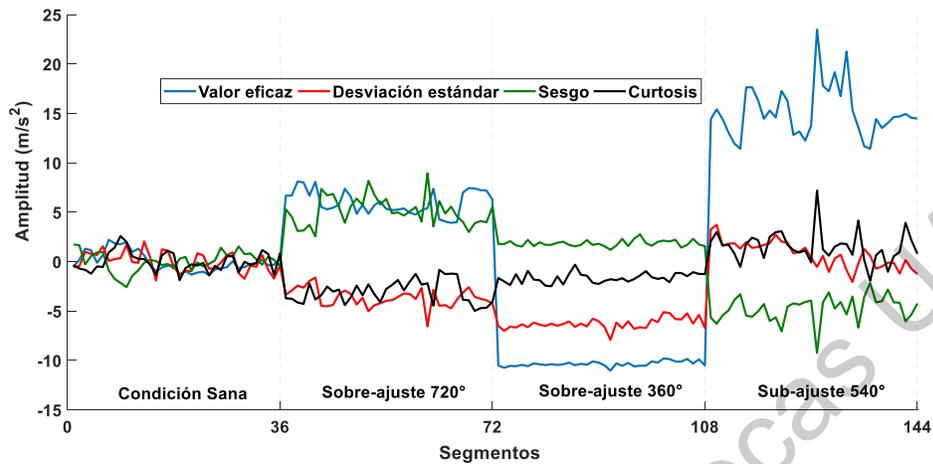


Figura 4.5 Indicadores estadísticos para vibraciones en el eje “X” en diferentes condiciones de operación.

## 4.2 Fusión de señales y evaluación de la severidad

El conjunto de indicadores estadísticos estimados fue sometido al proceso de reducción y transformación de base mediante la técnica PCA, con el objetivo de fusionar la información de cada uno de los indicadores estadísticos para conducir a una mejor caracterización de las condiciones de operación evaluadas en el tren valvular del MCI y obtener una representación visual (2D), y como resultado de este proceso, se obtuvieron las gráficas mostradas en la Figura 4.6, Figura 4.7 y Figura 4.8

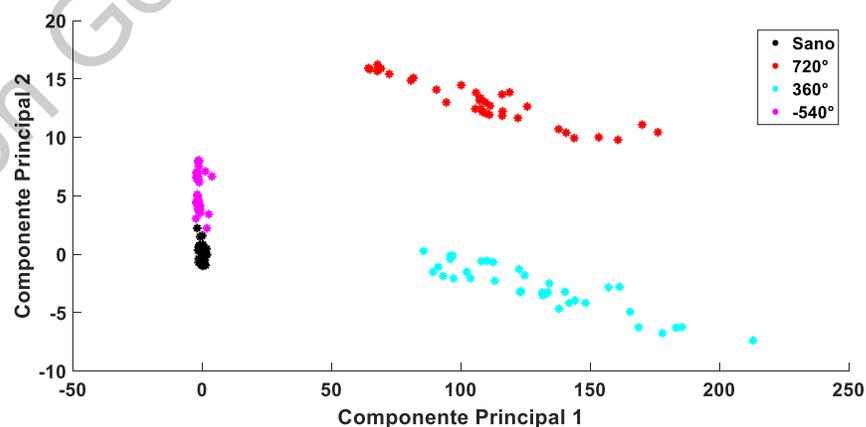
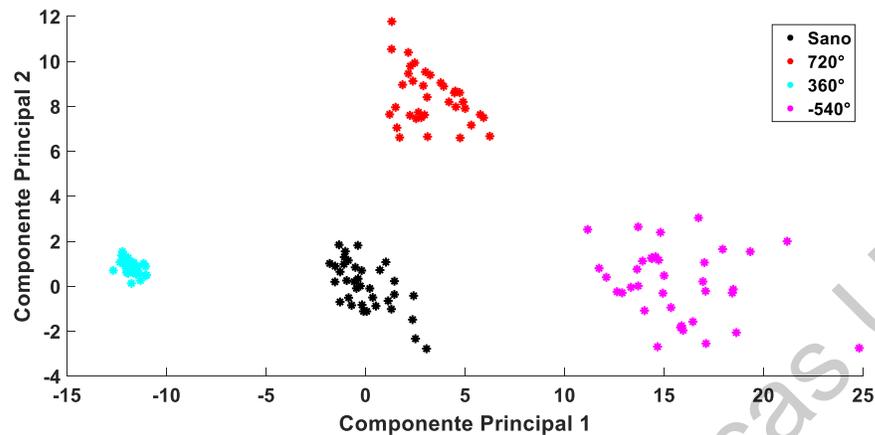


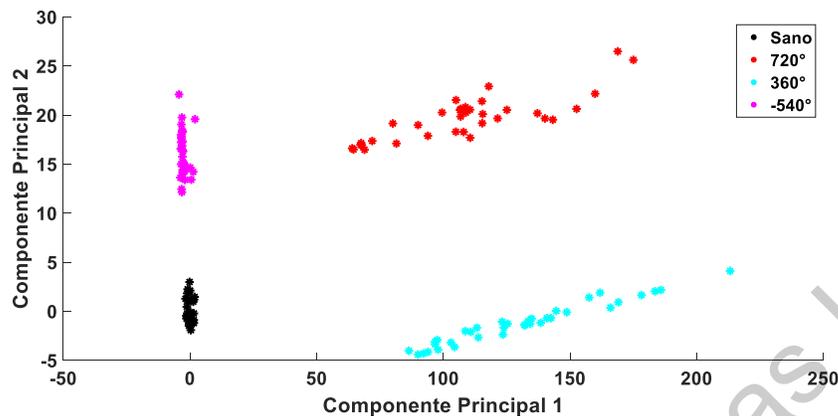
Figura 4.6 Proyección obtenida aplicando la técnica PCA al conjunto de indicadores estadísticos para las señales de corriente adquiridas del motor de arranque durante la fase de puesta en marcha del MCI para la condición sana y tres severidades de falla de holgura del tren valvular.



**Figura 4.7** Proyección obtenida aplicando la técnica PCA al conjunto de indicadores estadísticos para las señales de vibración en el eje "X" adquiridas en el MCI durante su fase de puesta en marcha para la condición sana y tres severidades de falla en la holgura del tren valvular.

En los resultados obtenidos al aplicar la reducción de indicadores para la condición sana y diferentes condiciones de severidad de falla en el tren valvular evaluados durante la fase de arranque del MCI a 127 rpm debe mencionarse que al aplicar la técnica de PCA; se mantuvo la variabilidad del conjunto de señales de corriente del motor de arranque y vibración de MCI como se muestra en la Figura 4.6 y la Figura 4.7 respectivamente y la separación de condiciones se obtiene debido a que existe una desviación en la varianza de los indicadores de cada condición evaluada, aunque en el caso de las señales de corriente esta desviación es mínima debido al rango de voltajes de referencia en el caso de las vibraciones es muy evidente.

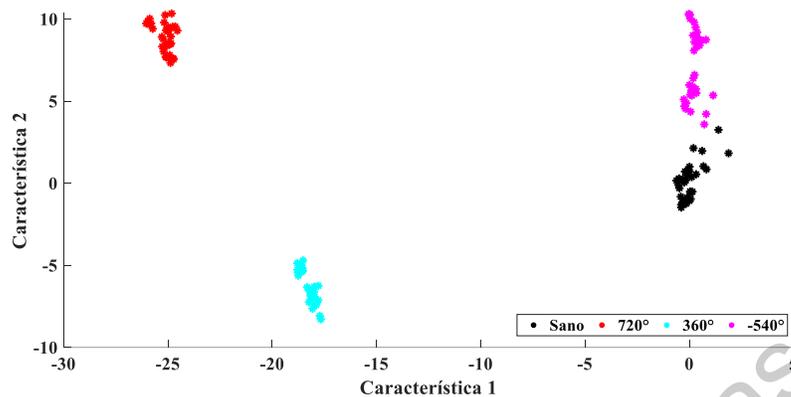
El uso de la técnica PCA permitió tomar información de los indicadores estadísticos usados en las diferentes condiciones de operación y que no necesariamente pertenecen solo a una condición, esta nueva información se fusionó dando como resultado una caracterización completa de las señales de corriente y vibración de las condiciones evaluadas del tren valvular como se muestra en la Figura 4.8.



**Figura 4.8** Proyección obtenida aplicando la técnica de PCA para fusionar indicadores estadísticos de las señales de corriente y vibración en el eje "X" adquiridas durante la fase de puesta en marcha del MCI para la condición sana y tres severidades de falla en la holgura del tren valvular.

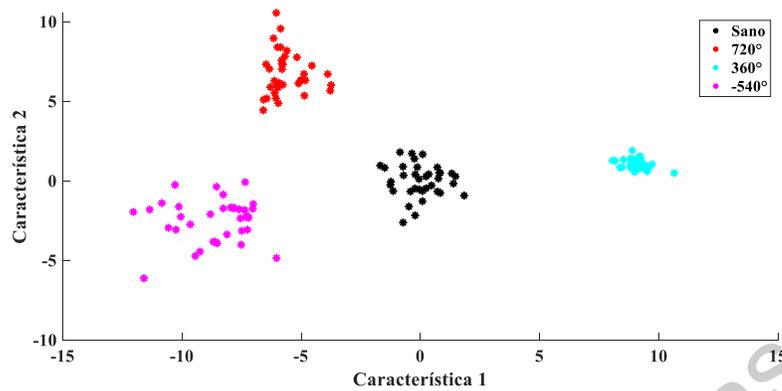
Por otra parte, los resultados al aplicar la técnica de LDA se muestran en la Figura 4.9, Figura 4.10 y Figura 4.11. Las proyecciones resultantes obtenidas al aplicar la LDA como técnica de reducción de indicadores muestra el comportamiento del conjunto de datos de corriente y vibración en el eje "X", que corresponden a la evaluación de la condición sana y diferentes severidades del fallo en la holgura del tren valvular en la fase de arranque del MCI a 127 rpm.

Al aplicar la técnica LDA al conjunto de indicadores estadísticos de las señales de corriente para la condición sana y las tres severidades de falla en el tren valvular, se obtiene la separación entre clases, es decir, una separación entre los datos de cada condición de operación. La condición de severidad de  $-540^\circ$  representa físicamente ruido en el tren valvular y una respuesta tardía en la apertura de las válvulas de admisión y escape pero la hermeticidad de los cilindros del MCI se mantiene, como resultado de esta condición, la amplitud de la señal de corriente resultante en el motor de arranque solo aumenta 2.52 % con respecto a la condición sana pero se mantiene la frecuencia de la señal solo con un ligero off-set de 0.02 segundos como se aprecia en la Figura 4.3 inciso (c). Este efecto causa que algunos datos de la condición de severidad de  $-540^\circ$  adviertan una cercanía con los datos de la condición sana, sin embargo, los centros de los datos de ambas clases se separan perfectamente como se muestra en la Figura 4.9



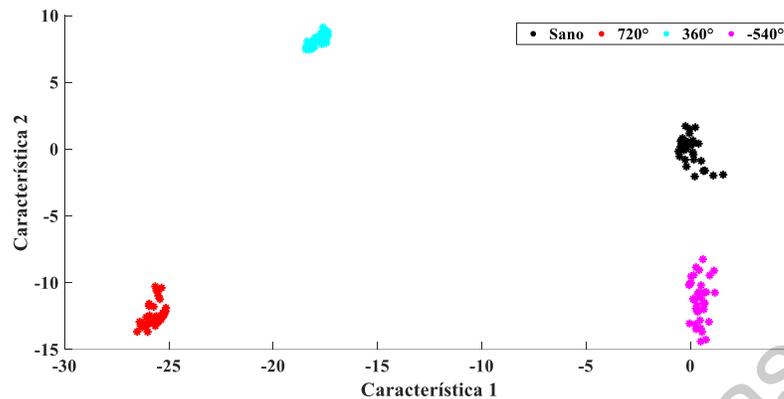
**Figura 4.9** Proyección obtenida aplicando la técnica LDA al conjunto de indicadores estadísticos para las señales de corriente adquiridas del motor de arranque durante la fase de puesta en marcha del MCI para la condición sana y tres severidades de falla de holgura del tren valvular.

En la Figura 4.10 se muestran los resultados al aplicar la misma técnica LDA pero ahora al conjunto de indicadores estadísticos de las señales de vibración en el eje “X” adquiridas del MCI con las condiciones anteriormente descritas. Comparando las clases de condición sana y sub-ajuste de 540° se nota una separación clara entre ambas a diferencia de lo que ocurre con las señales de corriente; como se explicó en el párrafo anterior, esto se debe a que el sub-ajuste de 540° implica físicamente un golpeteo en el tren valvular y por consecuencia una amplitud en la vibración de 85% mayor que la de condición sana como se aprecia en la Figura 4.4 inciso (c). En este caso se obtiene una maximización de la separación entre todas las clases y además una minimización de la distancia entre datos de cada condición.



**Figura 4.10** Proyección obtenida aplicando la técnica LDA al conjunto de indicadores estadísticos para las señales de vibración en el eje "X" adquiridas en el MCI durante su fase de puesta en marcha para la condición sana y tres severidades de falla en la holgura del tren valvular.

En el siguiente paso se fusionaron los datos de las señales de corriente y vibración cuyo proceso consistió en agrupar en una matriz los subconjuntos de indicadores en el dominio del tiempo, calculados para las señales de corriente y vibración en el eje "X" obtenidas de una condición sana y tres severidades de falla en el tren valvular, generando un conjunto final de indicadores estadísticos formados por el valor eficaz (RMS-Root Mean Square), la desviación estándar ( $\sigma$ ), el sesgo ( $S_k$ ) y la curtosis ( $K_{ur}$ ) para cada tipo de señal. Posteriormente, los dos subconjuntos de indicadores seleccionados fueron sometidos a un proceso de compresión y transformación de base aplicando la técnica LDA. Con esta técnica de extracción de indicadores se obtuvo un nuevo subconjunto de indicadores los cuales están integrados por una combinación ponderada de cada uno de los indicadores estadísticos previamente seleccionados. Como resultado del proceso de transformación de la base de este nuevo subconjunto, se obtuvo así, una fusión de los indicadores de corriente y los indicadores de vibración cuya representación visual de las condiciones evaluadas se proyectaron en un espacio 2D como se muestra en la Figura 4.11. Como puede observarse, al aplicar la técnica LDA se obtiene una separación máxima entre todas las clases pero manteniendo la distancia minimizada entre datos de cada condición.



**Figura 4.11** Proyección obtenida aplicando la técnica LDA para fusionar indicadores estadísticos de las señales de corriente y vibración en el eje "X" adquiridas durante la fase de puesta en marcha del MCI para la condición sana y tres severidades de falla en la holgura del tren valvular.

Estos resultados demuestran que el uso de las técnicas PCA y LDA son dos herramientas útiles que pueden ayudar a la detección de diferentes severidades de falla en los sistemas valvulares en un MCI ya que ambas se enfocan a la reducción de la dimensionalidad de la base de datos, incluso, el uso de estas técnicas también lleva a obtener una representación visual para proyectar un conjunto original de datos en 2D. Sin embargo, debido a que la PCA tiene como objetivo mantener la variabilidad (varianza) del conjunto original de datos, la reducción de los mismos y es una técnica en la que no se requiere conocer a que conjunto pertenecen las muestras, mientras que la LDA busca maximizar la separación entre clases, minimizar la distancia entre datos de cada clase, preservar la información discriminadora de los datos y además es una técnica en la que se requiere conocer las etiquetas de las clases, entonces ambas técnicas se pueden utilizar indistintamente para comparar cual genera mejores resultados. En el caso de aplicación de la técnica LDA, esta proporcionó mejores resultados debido a que se trata de una técnica enfocada a la solución de problemas de múltiples clases. Por otra parte, aunque la PCA también es capaz de separar las condiciones evaluadas, su rendimiento comenzará a decrementar en cuanto se incremente el número de condiciones.

### 4.3 Clasificación de la falla

Para la clasificación de **fallas**, se usó un clasificador basado en redes neuronales multicapas, el cual se entrenó bajo un esquema de validación cruzada de cuatro veces para probar el funcionamiento del método de diagnóstico propuesto en espera de obtener resultados estadísticos aceptables. La base de datos original constó de 144 muestras, es decir, cada condición con 36 muestras y además esta base de datos se dividió en dos partes, la primera con 108 muestras la cual se usó para el entrenamiento, 27 muestras por condición y la segunda parte con 36 muestras que se usó para la prueba, 9 muestras por condición.

En la Tabla 4.1 y la Tabla 4.2 se muestra un concentrado de las matrices de predicción que se obtuvieron durante el proceso de entrenamiento y prueba del clasificador respectivamente, estas matrices manifiestan la evaluación de las diferentes condiciones representadas por el conjunto de indicadores estadísticos extraído por la LDA. Es notorio que no se presentaron errores durante el entrenamiento y la prueba del clasificador por lo que se puede inferir que el método es capaz de evaluar diferentes condiciones de falla en el tren valvular independientemente del cilindro afectado.

Tabla 4.1 Matriz de predicción de la red neuronal bajo el esquema de validación cruzada durante el entrenamiento.

Clase estimada	Clase verdadera			
	SANO	720°	360°	-540°
SANO	27	0	0	0
720°	0	27	0	0
360°	0	0	27	0
-540°	0	0	0	27

Tabla 4.2 Matriz de predicción de la red neuronal bajo el esquema de validación cruzada durante la prueba.

Clase estimada	Clase verdadera			
	SANO	720°	360°	-540°
SANO	9	0	0	0
720°	0	9	0	0
360°	0	0	9	0
-540°	0	0	0	9

Cuando se aplicó el esquema de validación cruzada de cuatro veces se obtuvieron cuatro ratios de clasificación, esto como resultado de once iteraciones con particiones complementarias de la base de datos original de entrenamiento y prueba. Con este clasificador se pudo calcular y generar un mapa con regiones de clasificación que colabora con la interpretación del diagnóstico efectuado. En la Figura 4.12 y la Figura 4.13 se muestran las regiones de clasificación en conjunto con las proyecciones de las muestras, estas figuras corresponden a las primeras particiones de las base de datos utilizadas durante el proceso de entrenamiento y prueba del clasificador respectivamente con LDA.

Con la finalidad de obtener un comparativo del método propuesto con la técnica LDA y PCA, se procedió a evaluar el desempeño del clasificador con la misma base de datos y el mismo esquema de validación cruzada tal como se describió anteriormente pero utilizando PCA. En la Figura 4.14 y la Figura 4.15 se presentan los mapas de regiones del clasificador para el entrenamiento y validación respectivamente. Se puede observar que con la PCA el clasificador también fue capaz de separar las condiciones evaluadas aunque con mayor esfuerzo para mantener agrupados los datos de una misma clase, sin embargo su rendimiento comenzará a decrementar en cuanto se incremente el número de condiciones.

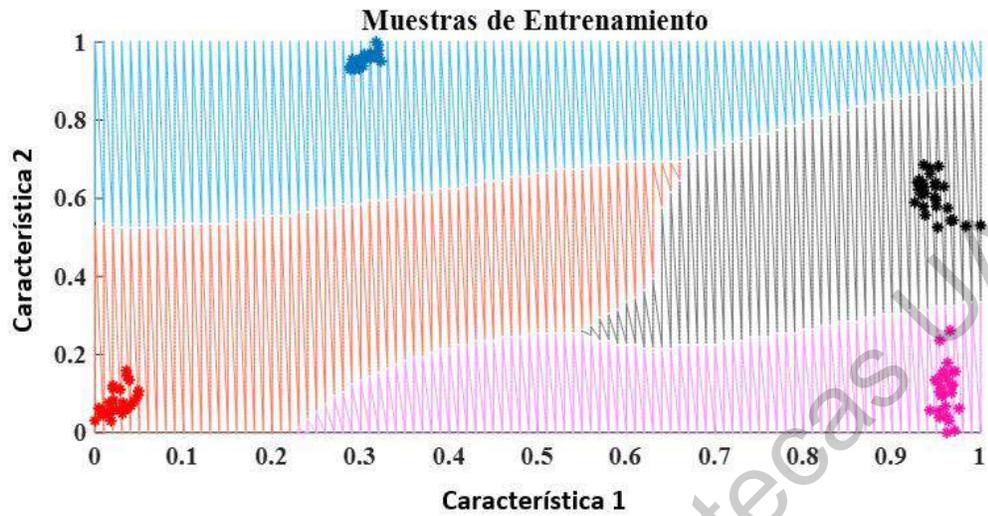


Figura 4.12 Muestras de entrenamiento para la clasificación automática de la Severidad de falla del Tren Valvular mediante una Red Neuronal para LDA.

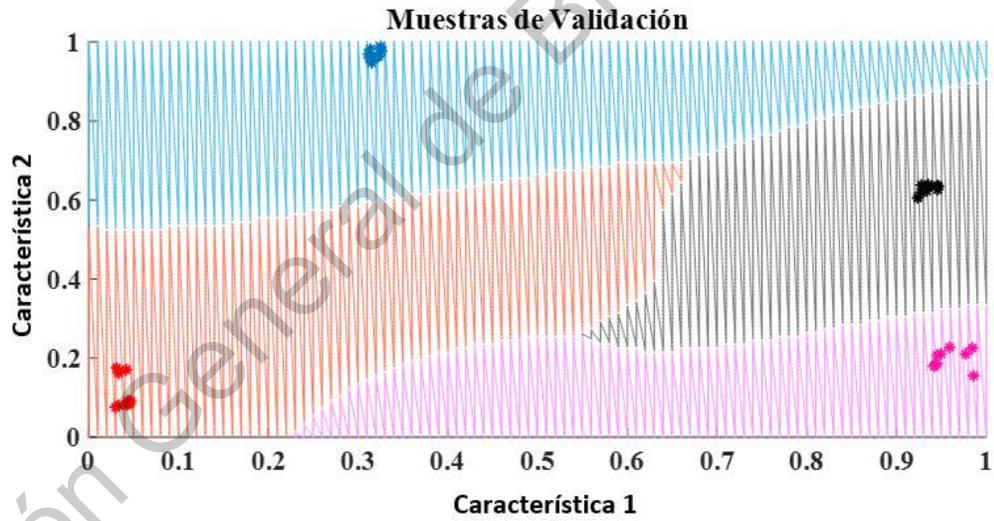


Figura 4.13 Muestras de validación para la clasificación automática de la Severidad de falla del Tren Valvular mediante una Red Neuronal para LDA.

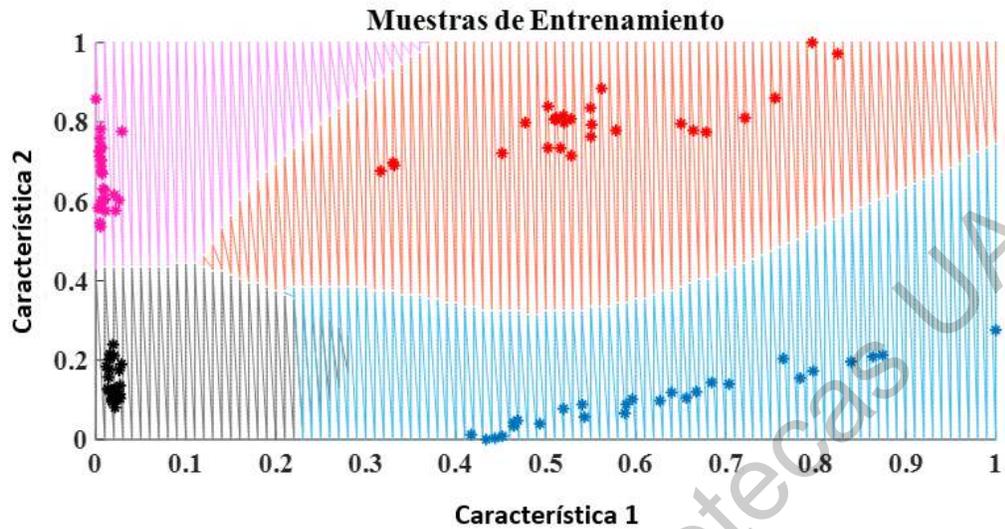


Figura 4.14 Muestras de entrenamiento para la clasificación automática de la Severidad de falla del Tren Valvular mediante una Red Neuronal para PCA.

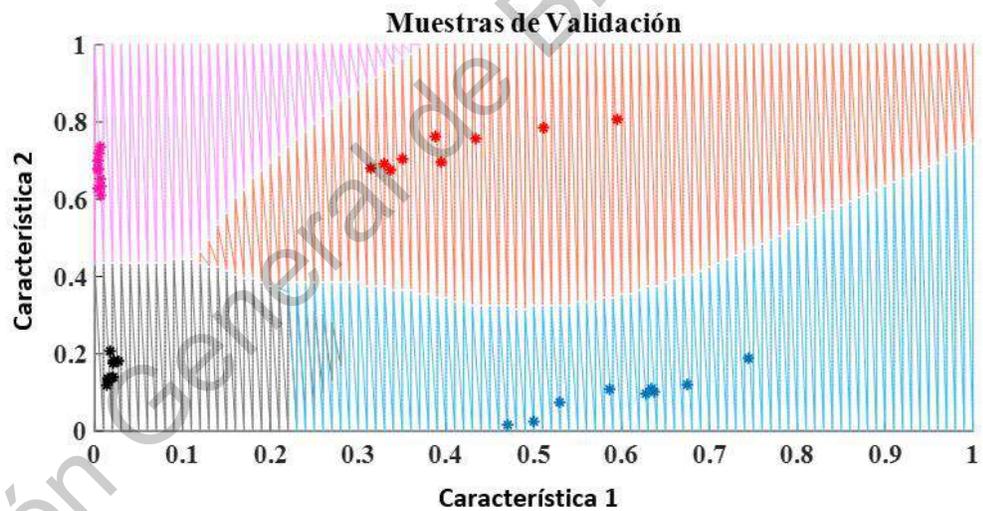


Figura 4.15 Muestras de validación para la clasificación automática de la Severidad de falla del Tren Valvular mediante una Red Neuronal para PCA.

#### 4.4 Evaluación de la fiabilidad

Para validar la aplicación del método propuesto, las mismas condiciones de falla en el tren valvular del MCI fueron evaluadas, pero afectando ahora el cilindro 1 y el cilindro 1 y 5 como se muestra en la Tabla 3.4 a una velocidad de giro 127 rpm durante la fase de arranque del MCI, por lo tanto, un conjunto de señales de

corriente y vibración fueron también adquiridas. Posteriormente, la metodología de diagnóstico fue aplicada como se explicó anteriormente y el conjunto de muestras correspondientes a estas severidades de falla fue proyectado sobre las representaciones visuales obtenidas tras aplicar la PCA y LDA respectivamente. Los resultados de la evaluación de la validación proyectada en el mismo plano de la condición sana y de las tres diferentes severidades fallo se muestran en la Figura 4.16 y la Figura 4.17 respectivamente. Así, como se puede observar en las mismas figuras, la metodología de diagnóstico y detección de falla en el sistema valvular de un MCI también es capaz de determinar que existe un área en las proyecciones resultantes en donde prevalece el comportamiento y se muestra la evolución de la aparición del fallo en el tren valvular del MCI.

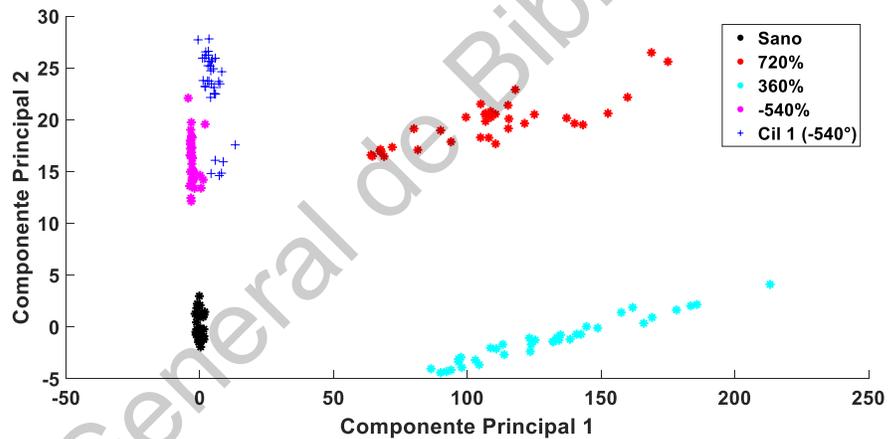
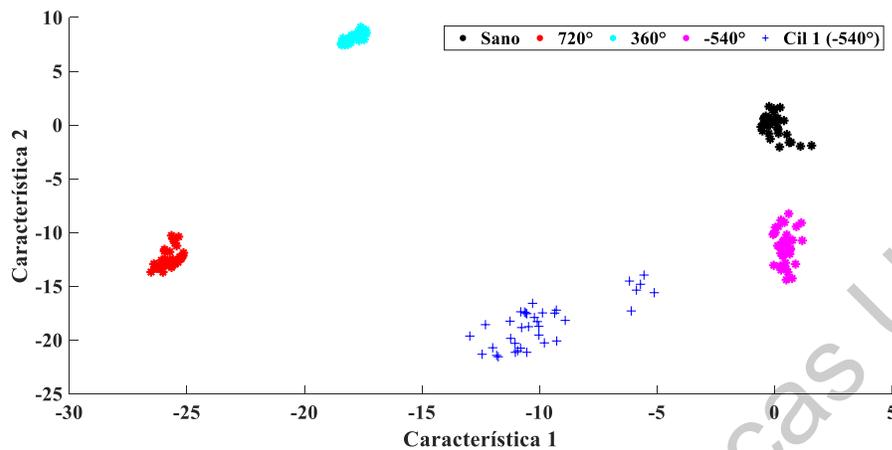


Figura 4.16 Proyección obtenida aplicando la técnica de PCA en indicadores estadísticos de las señales de corriente y vibración en el eje "X" adquiridas durante la fase de puesta en marcha del MCI para un sub-ajuste de 540° del cilindro 1 sobre el patrón de la condición sana y tres severidades de falla en la holgura del tren valvular.



**Figura 4.17** Proyección obtenida aplicando la técnica de LDA en indicadores estadísticos de las señales de corriente y vibración en el eje "X" adquiridas durante la fase de puesta en marcha del MCI para un sub-ajuste de 540° del cilindro 1 sobre el patrón de la condición sana y tres severidades de falla en la holgura del tren valvular.

En la sección de fundamentos teóricos se mencionó que el análisis de confiabilidad está basado en calcular el coeficiente alfa de Cronbach ( $\alpha$ ); por lo tanto, este coeficiente  $\alpha$  se calculó para medir la estabilidad interna de la clasificación de salida de cada una de las muestras que generaron las matrices de confusión obtenidas en los resultados de diagnóstico y clasificación de las diferentes condiciones de operación del tren valvular, ver sección 4.3.

Los clasificadores utilizados fueron evaluados bajo un esquema de validación cruzada de cuatro veces y para cada una de estas evaluaciones efectuadas se obtuvo un coeficiente  $\alpha$  mediante un programa basado en la ecuación (2.19) y desarrollado en el entorno de Matlab ®. Para los resultados de diagnóstico y clasificación obtenidos durante el proceso de entrenamiento y prueba del algoritmo de clasificación. Los valores obtenidos de los coeficientes de  $\alpha$  en la identificación y clasificación de las diferentes condiciones de operación del tren valvular fueron de 1 en cada una de las cuatro validaciones, y esto significa que la confiabilidad es excelente. En este sentido cabe mencionar que este resultado también se debe a la evidente distancia que existe entre clases cuando la red neuronal genera la clasificación, como se aprecia en la Figura 4.14 y en la Figura 4.15, evidentemente podemos inferir que los resultados del diagnóstico y clasificación automatizada de

fallas en el sistema valvular de un MCI obtenidos mediante la metodología propuesta son confiables.

Dirección General de Bibliotecas UAQ

## 5 CONCLUSIONES

En base a los resultados obtenidos se puede concluir que esta metodología tiene cuatro principales ventajas con respecto a otras estrategias reportadas en los trabajos de investigación referenciados en esta tesis.

Primera: Las técnicas para el cálculo de indicadores estadísticos en el dominio del tiempo PCA y LDA utilizadas en el procesamiento de datos ofrecen una menor complejidad durante el procesamiento disminuyendo el consumo de recursos computacionales, a diferencia de los métodos de análisis que utilizan técnicas basadas en el dominio de la frecuencia y tiempo-frecuencia como la transformada rápida de Fourier (FFT-Fast Fourier Transform), la transformada corta de Fourier (STFT-Short-Time Fourier Transform) y transformada Wavelet (CWT-Continuous Wavelet Transform), que exigen un conocimiento y dominio de su uso, de manera que, se vuelve más complicado conseguir caracterizaciones y resultados convincentes.

Segunda: Esta metodología tiene la cualidad de caracterizar diferentes condiciones de operación o niveles de severidad de fallo de un sistema valvular y pone a disposición la ventaja de poder adaptarse para analizar nuevas condiciones de fallo a diferencia de los métodos investigados que en su mayoría se enfocan a separar la condición sana de una condición anormal. Además, con el uso de las técnicas PCA y LDA se puede aportar más información a la estructura de un algoritmo de clasificación o identificación de un defecto, como por ejemplo una red neuronal artificial o un control difuso, en función de varias condiciones de operación del tren valvular de un MCI para la automatización del diagnóstico. Sin embargo la aplicación de la técnica LDA proporciona mejores resultados debido a que se trata de una técnica enfocada a la solución de problemas de múltiples clases, aunque la PCA también es capaz de separar las condiciones evaluadas, su rendimiento comenzará a decrementar en cuanto se incremente el número de condiciones.

Tercera: La estrategia de fusionar los indicadores de las señales de corriente y vibración utilizada en esta metodología resuelve posibles diagnósticos

difusos, es decir, diagnósticos de fallas con múltiples causas, ya que la caracterización de las señales de corriente confirmaran las causas de una condición de operación diagnosticada por la caracterización de las señales de vibración y viceversa, concluyendo por lo tanto, en un diagnóstico más preciso. También puede resolver el enmascaramiento dado por el ruido de fondo en señales de un solo tipo, sin afectar las características principales de las técnicas empleadas dejando asentadas las bases para contemplar la posibilidad de fusionar señales de vibración con señales de otra naturaleza y su adaptabilidad para el diagnóstico de fallas de mayor alcance.

Cuarta: En general y de manera práctica el método propuesto en esta tesis tiene la capacidad de detectar de forma precisa la aparición de diferentes severidades de falla en el sistema de válvulas, independientemente del cilindro afectado del MCI, se adapta a nuevas condiciones de fallo a diferencia de otros métodos y además los resultados de la metodología propuesta demuestran que puede representar una solución práctica capaz de proporcionar diagnósticos fiables y que ayuden a reducir las horas-hombre empleadas en el diagnóstico y detección de fallas en las válvulas de los MCI, cuando se usan métodos invasivos al desarmar componentes para su revisión o inspección visual.

En prospectiva, este trabajo de tesis permite dejar sentadas las bases para seguir en el ámbito de la investigación con el desarrollo de soluciones a nuevos problemas en el área automotriz y además el fundamento para el diseño de una interfaz adaptable a una herramienta que permita al personal de mantenimiento diagnosticar este sistema cuantitativamente. Por otra parte, esta metodología propuesta no se limita solamente al diagnóstico de fallas en el tren valvular de un MCI, sino que tiene la versatilidad de ampliarse en futuros trabajos de investigación para otros sistemas o subsistemas del MCI, como puede ser el sistema de inyección, el de distribución, entre otros.

## 6 REFERENCIAS

Agüero-Alva, H. L. 2002. Introducción a la Ingeniería Automotriz. Vicerrecto. (L. H. Huamán-Ureta, editor.). Grupo IDAT, Lima, Perú.

Chao, Y., H. Lu, G. Dong, J. Deng, y L. Li. 2019. Abnormal combustion diagnosis and combustion period based phase estimation with a modified form tandem ion current detection system on SI gasoline engines. *Energy Procedia*. 158:2098–2105. doi:10.1016/j.egypro.2019.01.483. Available from: <https://doi.org/10.1016/j.egypro.2019.01.483>

Cronbach, L. J. 1951. Coefficient alpha and the internal structure of tests. *Psychometrika*. 16:297–334. doi:10.1007/BF02310555.

Delvecchio, S., P. Bonfiglio, y F. Pompoli. 2018. Vibro-acoustic condition monitoring of Internal Combustion Engines: A critical review of existing techniques. *Mech. Syst. Signal Process.* 99:661–683. doi:10.1016/j.ymsp.2017.06.033.

Duda, R. O., P. E. Hart, y D. G. Stork. 2012. *Pattern Classification*. Second Edi. (J. Wiley & Son, editor.). John Wiley & Sons, New York, N.Y., U.S.A.

Flett, J., y G. M. Bone. 2016. Fault detection and diagnosis of diesel engine valve trains. *Mech. Syst. Signal Process.* 72–73:316–327. doi:10.1016/j.ymsp.2015.10.024. Available from: <http://dx.doi.org/10.1016/j.ymsp.2015.10.024>

Ftoutou, E., M. Chouchane, y N. Besbès. 2012. Internal combustion engine valve clearance fault classification using multivariate analysis of variance and discriminant analysis. *Trans. Inst. Meas. Control.* 34:566–577. doi:10.1177/0142331211408492.

Jafarian, K., M. Darjani, y Z. Honarkar. 2016. Vibration analysis for fault detection of automobile engine using PCA technique. 2016 4th Int. Conf. Control. Instrumentation, Autom. ICCIA 2016. 372–376. doi:10.1109/ICCIAutom.2016.7483191.

Jia, F., Y. Lei, J. Lin, X. Zhou, y N. Lu. 2016. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mech. Syst. Signal Process.* 72–73:303–315. doi:10.1016/j.ymssp.2015.10.025.

Mendonça, P. L., E. L. Bonaldi, L. E. L. de Oliveira, G. Lambert-Torres, J. G. Borges da Silva, L. E. Borges da Silva, C. P. Salomon, W. C. Santana, y A. H. Shinohara. 2017. Detection and modelling of incipient failures in internal combustion engine driven generators using Electrical Signature Analysis. *Electr. Power Syst. Res.* 149:30–45. doi:10.1016/j.epr.2017.04.007.

Merkisz, J., y M. Waligórski. 2014. Strategy of the combustion process diagnosis in direct injection engines. *Procedia Eng.* 96:294–301. doi:10.1016/j.proeng.2014.12.141.

Moosavian, A., G. Najafi, B. Ghobadian, M. Mirsalim, S. M. Jafari, y P. Sharghi. 2016. Piston scuffing fault and its identification in an IC engine by vibration analysis. *Appl. Acoust.* 102:40–48. doi:10.1016/j.apacoust.2015.09.002. Available from: <http://dx.doi.org/10.1016/j.apacoust.2015.09.002>

Russell, S., y P. Norvig. 2002. *Artificial Intelligence: A Modern Approach* (2nd Edition) SE - Prentice Hall series in artificial intelligence.

Saucedo-Dorantes, J. J. 2017. Metodologías para mejorar la confiabilidad del diagnóstico de fallas en cadenas cinemáticas basado en algoritmos inteligentes y fusión de datos. tesis de doctorado, mecatrónica, Universidad Autónoma de Querétaro, San Juan del Río, Querétaro, México.

Saucedo-Dorantes, J. J., M. Delgado-Prieto, R. A. Osornio-Rios, y R. De Jesus Romero-Troncoso. 2017. Multifault Diagnosis Method Applied to an Electric Machine Based on High-Dimensional Feature Reduction. *IEEE Trans. Ind. Appl.* 53:3086–3097. doi:10.1109/TIA.2016.2637307.

Siano, D., E. Frosina, y A. Senatore. 2017. Diagnostic Process by Using Vibrational Sensors for Monitoring Cavitation Phenomena in a Getoror Pump Used

for Automotive Applications. Energy Procedia. 126:1115–1122.  
doi:10.1016/j.egypro.2017.08.269. Available from:  
<https://doi.org/10.1016/j.egypro.2017.08.269>

Theodoridis, S., y K. Koutroumbas. 2006. Pattern Recognition. Third Edit.  
Academic Press, San Diego, California, U.S.A.

Warren, L., y J. H. Haynes. 1995. Chevrolet/GMC Camionetas. Manual de  
Reparación. (A. Sánchez, editor.). Haynes de Norte America, California, U.S.A.

Wu, J. Da, y J. C. Chen. 2006. Continuous wavelet transform technique for  
fault signal diagnosis of internal combustion engines. NDT E Int. 39:304–311.  
doi:10.1016/j.ndteint.2005.09.002.

Wu, J. Da, y C. Q. Chuang. 2005. Fault diagnosis of internal combustion  
engines using visual dot patterns of acoustic and vibration signals. NDT E Int.  
38:605–614. doi:10.1016/j.ndteint.2005.02.007.

Zhou, C., B. Hu, S. Chen, y L. He. 2017. An enhanced flexible dynamic  
model and experimental verification for a valve train with clearance and multi-  
directional deformations. J. Sound Vib. 410:249–268. doi:10.1016/j.jsv.2017.08.016.

Zhu, W., y H. Zhu. 2020. Multi-signal detection and parameter estimation  
fusion with an improved utility function. Digit. Signal Process. A Rev. J. 98:102641.  
doi:10.1016/j.dsp.2019.102641. Available from:  
<https://doi.org/10.1016/j.dsp.2019.102641>

## 7 APÉNDICE

### 7.1 Artículos publicados en revistas

**2020** *Análisis de falla de encendido en motores de combustión utilizando señales de vibración basado en el cálculo y reducción de indicadores estadísticos; Científica*, vol. 25, núm. 1, pp. 01-11, enero-junio 2021, ISSN 2594-2921, Instituto Politécnico Nacional MÉXICO, <https://doi.org/10.46842/ipn.cien.v25n1a07>.

### 7.2 Artículos de congreso

**2020** *Análisis de falla de encendido en motores de combustión utilizando señales de vibración basado en el cálculo y reducción de indicadores estadísticos; XIX Congreso Nacional de Ingeniería Electromecánica y de Sistemas (cnies 2020)*, Noviembre 2020, Ciudad de México, México.