

UNIVERSIDAD AUTÓNOMA DE ZACATECAS



IDENTIFICACIÓN DE FALLAS EN BUJÍAS POR DESGASTE DE ELECTRODOS EN AUTOMÓVILES A TRAVÉS DE LA EXTRACCIÓN DE CARACTERÍSTICAS DE AUDIOS Y CLASIFICACIÓN K-NN Y SVM.

Ing. Luis Rafael Salas Rodríguez.

Tesis de Maestría

presentada a la Unidad Académica de Ingeniería Eléctrica
de acuerdo a los requerimientos de la Universidad para obtener el Grado de

MAESTRO EN CIENCIAS DE LA INGENIERÍA.

Directores de tesis: Dr. Efrén González Ramírez y Dr. Daniel Alaniz Lumbreras

UNIDAD ACADÉMICA DE INGENIERÍA ELÉCTRICA

12 de Diciembre de 2019



CIRCULAR

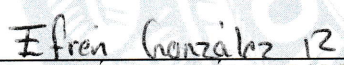
Se suplica de la manera más atenta a los señores Doctores que se citan al calce, se sirvan revisar y en su caso aprobar la impresión del **TRABAJO DE TESIS** que se anexa a la presente, del pasante de Maestría en Ciencias de la Ingeniería C. **Luis Rafael Salas Rodríguez** con matrícula 29101016.

ATENTAMENTE

Zacatecas, Zac. 05 de Diciembre 2019

DR. CARLOS ALBERTO OLVERA OLVERA
RESPONSABLE DEL PROGRAMA
MAESTRÍA EN CIENCIAS DE LA INGENIERÍA

REVISÓ Y APROBÓ


DR. EFRÉN GONZÁLEZ RAMÍREZ


DR. PEDRO DANIEL ALANIZ LUMBRERAS


DR. JOSÉ ISMAEL DE LA ROSA VARGAS


DR. JOSÉ DE JESÚS VILLA HERNÁNDEZ


DR. HAMURABI GAMBOA ROSALES



Universidad Autónoma de Zacatecas
Francisco García Salinas
Unidad Académica de Ingeniería Eléctrica
Posgrado en Ingeniería



C. LUIS RAFAEL SALAS RODRÍGUEZ.

P R E S E N T E:

De acuerdo al oficio de fecha 27 de Junio del 2019, en el cual solicita se le señale el tema a desarrollar para su trabajo de tesis del Programa de Maestría en Ciencias de la Ingeniería, le manifiesto a Usted lo siguiente:

Se aprueba su solicitud, designando como directores de tesis a los profesores **DR. EFRÉN GONZÁLEZ RAMÍREZ Y DR. PEDRO DANIEL ALANIZ LUMBRERAS**, mismo que acordaron acordes en fijar a usted el tema titulado:

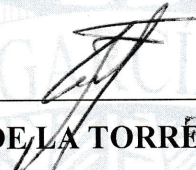
“Identificación de fallas en bujías por desgaste de electrodos en automóviles a través de la extracción de características de audios y clasificación K-NN Y SVM”

Le comunico a Usted que dispone de un plazo máximo de **SEIS MESES**, a partir de la presente fecha para la conclusión de su trabajo de tesis. Asimismo, le indico que, una vez concluido su documento de tesis, deberá remitir cinco copias del mismo para su revisión y aprobación por parte de la Comisión Revisora, que se nombrará en su oportunidad para su aprobación, o en su caso indicarle las correcciones que fueran pertinentes, antes de la impresión de la versión final.

A T E N T A M E N T E

Zacatecas, Zac. 05 de Diciembre del 2019




DR. JORGE DE LA TORRE Y RAMOS
DIRECTOR DE LA UNIDAD ACADÉMICA DE
INGENIERÍA ELÉCTRICA.



Universidad Autónoma de Zacatecas
Francisco García Salinas
Unidad Académica de Ingeniería Eléctrica
Posgrado en Ingeniería



C. LUIS RAFAEL SALAS RODRÍGUEZ.
P R E S E N T E.

La Dirección de la Unidad Académica de Ingeniería Eléctrica le notifica a Usted que la Comisión Revisora de su documento de Tesis de Maestría, está integrada por los profesores Dr. Efrén González Ramírez, Dr. Pedro Daniel Alaniz Lumbreras, Dr. José Ismael de la Rosa Vargas, Dr. José de Jesús Villa Hernández, y Dr. Hamurabi Gamboa Rosales, ha concluido la revisión del mismo y ha dado la aprobación para su respectiva presentación.

Por lo anterior, se le autoriza la impresión definitiva de su documento de Tesis de Maestría a fin de dar trámite a la sustentación de su Examen de Grado, a presentarse el 13 de Diciembre del 2019.

A T E N T A M E N T E .
Zacatecas, Zac., 05 de Diciembre 2019.


DR. JORGE DE LA TORRE Y RAMOS
DIRECTOR DE LA UNIDAD ACADÉMICA DE INGENIERÍA ELÉCTRICA U. A. Z.

IDENTIFICACIÓN DE FALLAS EN BUJÍAS POR DESGASTE DE ELECTRODOS EN AUTOMÓVILES A TRAVÉS DE LA EXTRACCIÓN DE CARACTERÍSTICAS DE AUDIOS Y CLASIFICACIÓN K-NN Y SVM.

Ing. Luis Rafael Salas Rodríguez.

Directores de tesis: Dr. Efrén González Ramírez y Dr. Daniel Alaniz Lumberras

RESUMEN

La falta de prevención por parte de los conductores lleva a revisar sus vehículos cuando presentan alguna falla que evita que el automóvil funcione. Algunas de estas fallas se presentan por falta de mantenimiento, desconocimiento o por descuido del propietario, así como elementos naturales tales como polvo y agua. Una de las fallas que se presenta es el desgaste de electrodos en bujías. En este trabajo se desarrolló una técnica no invasiva que detecta y clasifica puntualmente las fallas por desgaste de electrodos en bujías de automóviles para prevenir daños más graves, y un mayor consumo de combustible. Al ser una técnica no invasiva se reduce el tiempo en el que el automóvil se encuentra en mantenimiento.

El proyecto se desarrolló en tres etapas. En la primera se realizó la grabación de las señales acústicas provenientes de dos motores de automóviles (Honda Civic y Seat Ibiza) con desgaste en los electrodos de las bujías. Dichas grabaciones se sometieron a un análisis en donde se etiquetaron con el fin de tener tres clasificaciones posibles: ninguna falla, 1 falla y 2 fallas. En la segunda etapa se realizó un pre-procesamiento en la que se acortaron en duración las grabaciones, se obtuvieron los espectrogramas y se extrajeron tanto las características MFCC (Mel Frequency Cepstral Coefficients) como las características estadísticas de primer y segundo grado (Media, Mediana, Moda, desviación estándar, varianza, percentiles, etc) de las señales acústicas, para construir dos bases de datos. La detección de fallas se llevó a cabo mediante los clasificadores K-NN (K Nearest Neighbour) y SVM (Support Vector Machine). Las bases de datos se subdividieron en dos subconjuntos con el fin de entrenar y validar los modelos de clasificación. En la tercera etapa se utilizó el escáner ELM327 para determinar el consumo

de combustible en cada una de las pruebas realizadas a los dos automóviles. La clasificación utilizando las características de los espectrogramas produjeron una eficiencia del 100% en el entrenamiento y un 53% en la validación del modelo en el mejor de los casos. Cuando se utilizaron las características estadísticas y MFCC la eficiencia en el entrenamiento bajó al 95% y subió hasta el 100% en la validación. De acuerdo a los registros obtenidos del consumo de combustible se tiene que con la presencia de una bujía con electrodos desgastados el consumo incrementa un 2%, mientras que con la presencia de dos bujías con electrodos desgastados el consumo incrementa hasta un 8%. El uso de MFCC y características estadísticas incrementa la eficiencia de la clasificación de las señales acústicas.

IDENTIFICATION OF SPARK PLUG FAILURES DUE TO ELECTRODE WEAR IN CARS THROUGH THE EXTRACTION OF AUDIO CHARACTERISTICS AND K-NN AND SVM CLASSIFICATION.

Ing. Luis Rafael Salas Rodríguez.

Thesis supervisors: Dr. Efrén González Ramírez y Dr. Daniel Alaniz Lumbreras

ABSTRACT

The lack of prevention by drivers leads to check their vehicles when they have a fault that prevents the car from running. Some of these failures occur due to lack of maintenance, ignorance or carelessness of the owner, as well as natural elements such as dust and water. One of the failures that occurs is the wear of electrodes on spark plugs. In this work a non-invasive technique was developed that detects and classifies failures due to electrode wear in automobile spark plugs to prevent more serious damage, and greater fuel consumption. Being a non-invasive technique reduces the time in which the car is in maintenance.

The project was developed in three stages. In the first one the recording of the acoustic signals from two car engines (Honda Civic and Seat Ibiza) with wear on the electrodes of the spark plugs was made. These recordings were subjected to an analysis where they were labeled in order to have three possible classifications: no failures, 1 failures and 2 failures. In the second stage a preprocessing was carried out in which the recordings were shortened in duration, spectrograms were obtained and both the MFCC (Mel Frequency Cepstral Coefficients) characteristics and the first and second grade statistical characteristics (Mean, Median) were extracted, (Fashion, standard deviation, variance, percentiles, etc.) of the acoustic signals, to build two databases. Fault detection was carried out using the K-NN (K Neighbor Neighbor) and SVM (Support Vector Machine) classifiers. The databases were subdivided into two subsets in order to train and validate the classification models. In the third stage the ELM327 scanner was used to determine the fuel consumption in each of the tests performed on the two

cars. Classification using spectrogram characteristics produced an efficiency of 100 % in training and 53% in the validation of the model at best. When the statistical characteristics and MFCC were used, the efficiency in the training went down to 95% and rose to 100% in the validation. According to the records obtained from the fuel consumption, it is necessary that with the presence of a spark plug with worn electrodes the consumption increases by 2%, while with the presence of two spark plugs with worn electrodes the consumption increases up to 8%. The use of MFCC and statistical characteristics increases the efficiency of the classification of acoustic signals.

Esta tesis esta dedicada a:

A mi madre Ana María quien con su amor, paciencia y esfuerzo me ha permitido llegar a cumplir hoy una meta más, gracias por inculcar en mi el ejemplo de esfuerzo y de no temer a las adversidades. De igual manera a su esposo Hugo quien siempre me ha demostrado un apoyo importante en distintos proyectos emprendidos. A mis hermanas Dinorah y Fátima del Mar por su cariño y apoyo incondicional, durante todo este proceso, por estar conmigo en todo momento gracias. A toda mi familia cuyos consejos y palabras de aliento hicieron de mi una mejor persona y de una u otra forma me han acompañado a lo largo de mi vida. Finalmente quiero dedicar esta tesis a mi pareja Pati, por apoyarme cuando más lo necesito, por extender su mano en momentos difíciles y por el amor brindado cada día.

Agradecimientos

Agradezco la valiosa colaboración del Dr. Efrén González Ramírez y del Dr. Daniel Alaniz Lumbreras por sus amables recomendaciones en el desarrollo del presente trabajo que fueron clave para las conclusiones logradas. Así como al Dr. Carlos Eric Galván Tejada, al Dr. Hamurabi Gamboa Rosales y a la M.C. Vanessa del Rosario Alcalá Ramírez por su valiosa colaboración durante distintas etapas del presente trabajo.

Contenido General

	Pag.
Resumen	i
Abstract	iii
Lista de figuras	ix
Lista de tablas	xii
1 Introducción.	1
1.1 Planteamiento del Problema.	3
1.2 Justificación.	4
1.3 Objetivo General.	5
1.4 Objetivos Específicos.	5
1.5 Hipótesis.	6
1.6 Estado del Arte	6
1.6.1 Estudios centrados en el uso del sonido.	7
1.6.2 Estudios enfocados al análisis de sonidos en motores.	9
1.6.3 Estudios centrados en el consumo combustible.	11
1.7 Estructura de la tesis.	13
2 Detección y clasificación de señales acústicas de fallas en bujías por desgaste de electrodos.	14
2.1 Sistema de encendido de automóvil.	14
2.1.1 Sistema de bujías.	15
2.1.2 Fallas en sistema de bujías.	17
2.2 Técnicas de adquisición de sonido.	18
2.3 Reconocimiento de patrones en fuentes de sonido.	20
2.4 Técnicas de análisis de señales acústicas	21
2.4.1 Espectrogramas.	21
2.4.2 Coeficientes Cepstrales de las Frecuencias de Mel (MFCC).	22
2.5 Clasificadores.	24
2.5.1 Aprendizaje automático.	24
2.5.2 K-ésimo Vecino más Cercano (K-NN).	25
2.5.3 Máquina de Soporte Vectorial (SVM).	27

	Pag.
2.6 Rendimiento de combustible.	28
2.6.1 Sistema OBD2	29
2.6.2 Lectura de rendimiento de combustible (ELM327)	30
3 Implementación de clasificadores para la identificación de fallas por desgaste de electrodos en bujías.	32
3.1 Diseño experimental.	33
3.1.1 Materiales.	35
3.1.2 Automóviles.	35
3.1.3 Tarjeta de desarrollo Respeaker V2.0	36
3.2 Sistema de adquisición de señales acústicas.	37
3.3 Procesamiento de señales acústicas.	39
3.4 Extracción de características.	41
3.4.1 MATLAB.	41
3.4.2 R.	42
3.4.3 Base de datos a partir de Espectrogramas.	42
3.4.4 Base de datos a partir de MFCC y características estadísticas.	44
3.5 Clasificación de señales de bujías por desgaste de electrodos.	44
3.6 Análisis del rendimiento de combustible.	47
4 Resultados y Análisis.	48
5 Conclusiones y trabajo futuro.	52
5.1 Conclusiones.	52
5.1.1 Trabajo futuro y recomendaciones.	53
Apéndices	
Apéndice A: Hoja de datos de micrófonos.	54
Apéndice B: Imágenes de la ROC, AUC y Matriz de confusión.	57
Referencias	70

Lista de figuras

Figura	Pag.
2.1 Partes que componen el sistema de encendido.	15
2.2 Partes que componen una bujía.	16
2.3 Partes de los diferentes tipos de micrófonos.	19
2.4 Comparativa de una señal en tiempo y su espectrograma.	22
2.5 Proceso para la elaboración de un vector característico de MFCC.	23
2.6 Representación gráfica del algoritmo K-NN.	27
2.7 Puertos de comunicación del conector OBD2.	30
2.8 Dispositivo de comunicación OBD2.	30
2.9 PIC 18f2480 contenido en el dispositivo ELM327.	31
3.1 Metodología del proyecto.	32
3.2 Escáner ELM327 para el rendimiento de combustible.	34
3.3 Recorrido realizado para la pruebas de rendimiento de combustible.	34
3.4 Tarjeta de desarrollo Respeaker V2.0.	36
3.5 Toma de grabaciones de los vehículos de prueba.	37
3.6 Cambio de primer bujía con una falla en cilindro 1.	38
3.7 Cambio de la segunda bujía con falla en cilindro 4.	38
3.8 Orden de cilindros en motores con 4 de estos.	39
3.9 Software de edición de sonido “Audacity” y selección de segmentos de audio. . . .	40

Figura	Pag.
3.10 Comparativa de Espectrogramas con y sin fallas.	43
3.11 Interfaz de la aplicación “Classification Learner” en MATLAB.	46
B.1 Matriz de confusión, numero de observaciones del clasificador SVM.	57
B.2 Matriz de confusión, falsos positivos y falsos negativos del clasificador SVM.	58
B.3 Matriz de confusión, predictores positivos y falsos descubrimientos del clasificador SVM.	58
B.4 ROC y AUC, sin fallas del clasificador SVM.	59
B.5 ROC y AUC, 1 falla del clasificador SVM.	59
B.6 ROC y AUC, 2 fallas del clasificador SVM.	60
B.7 Matriz de confusión, numero de observaciones del clasificador KNN.	60
B.8 Matriz de confusión, falsos positivos y falsos negativos del clasificador KNN.	61
B.9 Matriz de confusión, predictores positivos y falsos descubrimientos del clasificador KNN.	61
B.10 ROC y AUC, sin fallas del clasificador KNN.	62
B.11 ROC y AUC, 1 falla del clasificador KNN.	62
B.12 ROC y AUC, 2 fallas del clasificador KNN.	63
B.13 Matriz de confusión, numero de observaciones del clasificador SVM.	64
B.14 Matriz de confusión, falsos positivos y falsos negativos del clasificador SVM.	64
B.15 Matriz de confusión, predictores positivos y falsos descubrimientos del clasificador SVM.	65
B.16 ROC y AUC, sin fallas del clasificador SVM.	65
B.17 ROC y AUC, 1 falla del clasificador SVM.	66
B.18 ROC y AUC, 2 fallas del clasificador SVM.	66
B.19 Matriz de confusión, numero de observaciones del clasificador KNN.	67

Figura	Pag.
B.20 Matriz de confusión, falsos positivos y falsos negativos del clasificador KNN. . . .	67
B.21 Matriz de confusión, predictores positivos y falsos descubrimientos del clasificador KNN.	68
B.22 ROC y AUC, sin fallas del clasificador KNN.	68
B.23 ROC y AUC, 1 falla del clasificador KNN.	69
B.24 ROC y AUC, 2 fallas del clasificador KNN.	69

Lista de tablas

Tabla	Pag.
1.1 Hábitos de una conducción común (SENER 2019).	2
1.2 Estado mecánico del automóvil (SENER 2019).	2
3.1 Número de grabaciones por clase motor (Sin fallas).	39
3.2 Número de grabaciones por clase motor (1 falla).	40
3.3 Número de grabaciones por clase motor (2 fallas).	40
3.4 Estructuras de bases de datos probadas en los clasificadores para entrenamiento y validación.	45
4.1 Resultados utilizando la arquitectura de subconjuntos de base de datos 70/30 para el vehículo Honda Civic 2006.	48
4.2 Resultados utilizando la arquitectura de subconjuntos de base de datos 80/20 para el vehículo Honda Civic 2006.	48
4.3 Resultados utilizando la arquitectura de subconjuntos de base de datos 70/30 para el vehículo Seat Ibiza 2015.	49
4.4 Resultados utilizando la arquitectura de subconjuntos de base de datos 80/20 para el vehículo Seat Ibiza 2015.	49
4.5 Consumos de combustible por trayectoria en cada vehículo.	49
4.6 Consumos promedio de combustible instantáneo en cada vehículo.	50
4.7 Consumos promedio de combustible por cada 100 km en cada vehículo.	50
4.8 Porcentajes de incrementos de combustible con cada una de las fallas en cada automóvil.	50

Capítulo 1

Introducción.

El presente capítulo muestra una introducción al tema de "Identificación de fallas en bujías por desgaste de electrodos en automóviles a través de la extracción de características de audios y clasificación K-NN y SVM". Se explican los antecedentes, planteamiento del problema y justificación. Además se da una descripción de las hipótesis, objetivos generales y específicos, y estado del arte.

Los automóviles se encuentran actualmente posicionados como una de las herramientas más valiosas en el día a día de la población mexicana. Tal es así, que cuando ocurre una falla que no ha sido prevista los compromisos y planes hechos se ven comprometidos.

Actualmente la gran mayoría de los automóviles llevan consigo sistemas de gestión electrónica. Para un diagnóstico se emplea un escáner que se conecta a la ECU (Unidad de Control Electrónico) el personal técnico basándose en su conocimiento debe interpretar los resultados reportados, si esta persona no cuenta con la experiencia requerida, o el escáner no reporta falla alguna, la reparación puede llegar a ser compleja (Adrian and Vargas 2017). Una persona con experiencia en el ramo automotriz, es capaz de reconocer un desperfecto en el motor de cualquier vehículo con solo escuchar el ruido y percibiendo las vibraciones producidas. Para el propietario de un carro es sencillo detectar cualquier cambio fuera de lo común en el motor y, eventualmente, detectar alguna falla. Sin embargo, identificar qué tipo de falla produce ciertos ruidos y vibraciones en el motor no es tarea simple (Andrés et al. 2009). El hacer caso omiso a un automóvil

en el que se detectan fallos a partir de los ruidos que emite puede tener un impacto directo en la economía del dueño del automóvil. Ya sea por la refacciones que sean necesarias cambiar o por el consumo de combustible extra de combustible. Existen además hábitos en los conductores por los que pueden haber variaciones entre lo indicado por el fabricante del automóvil y las condiciones reales de operación para el rendimiento de combustible entre los que se encuentran, principalmente:

Hábitos Comunes	Efecto
Calentar el motor del automóvil por más de un minuto (funcionamiento en vacío)	Un automóvil consume 100ml por cada 10 minutos funcionando en vacío.
Acelerar rápidamente desde un alto	Se consume hasta 50% más de combustible en comparación con una aceleración gradual.
Viajar a altas velocidades	Un automóvil que circula a 110 km/h consume alrededor de 20% más de combustible que si viajara a 90 km/h.
Usar inmoderadamente el aire acondicionado	Consume 10% más de combustible
Cargar cosas inútiles en la cajuela	Por cada 50kg. adicionales se incrementa en 2% el consumo de combustible.

Tabla 1.1: Hábitos de una conducción común (SENER 2019).

Otro aspecto fundamental que afecta sensiblemente el rendimiento son las condiciones del automóvil, que ocasionan:

Hábitos Comunes	Efecto
Filtro de aire sucio	Puede aumentar hasta en 10% el consumo de gasolina.
Automóvil con un mantenimiento deficiente	Puede aumentar en 30% el consumo de combustible.
Presión de las llantas incorrecta	Aumenta el consumo de combustible en 5% y reduce la vida y seguridad de estas.

Tabla 1.2: Estado mecánico del automóvil (SENER 2019).

Estos hábitos pueden afectar sin importar que el modelo del auto sea reciente. Siempre se requiere de hábitos y un mantenimiento que permita al automóvil ofrecer un servicio óptimo, seguro y eficiente (SENER 2019). Una consecuencia directa del consumo extra de combustible en los vehículos ya sea por malos hábitos o mantenimientos deficientes es la contaminación que estos provocan. Existen hoy en día varios tipos de contaminación que siguen alterando el medio ambiente de la tierra. La población muestra una gran preocupación por los efectos de la alteración ambiental y exige que se tomen medidas efectivas. Como medida contra la contaminación del aire, algunos institutos de investigación y agencias gubernamentales están en el proceso de establecer nuevos estándares para regular la emisión de gases de escape de los dispositivos, particularmente los motores de combustión interna de vehículos, que convierten los combustibles fósiles en energía (Shimasaki, Kanehiro, and Baba 1993).

1.1 Planteamiento del Problema.

La falta de cultura de prevención de los conductores lleva a revisar sus vehículos cuando presentan alguna falla que evita que el automóvil funcione. Algunas de estas fallas se presentan por falta de mantenimiento, desconocimiento o por descuido del propietario, así como elementos naturales tales como polvo y agua que se introducen en piezas importantes para el funcionamiento del vehículo. Un indicativo del buen funcionamiento de un automóvil es la ausencia de sonidos anormales. Por ejemplo cuando la gasolina se enciende en forma prematura en la cámara de combustión, se produce un sonido explosivo, que puede ser a causa de daños en los pistones (Magazine 2018). Existen diversos reportes de personas que son capaces de detectar fallas en automóviles tomando en cuenta solamente el sonido generado por los motores. Hasta la fecha no ha sido posible clasificar adecuadamente sonidos que permitan identificar y localizar desperfectos en motores automotrices como lo hacen personas con esa habilidad (Mannes 2017). Facilitaría para lograr detectar posibles averías en un vehículo que repercuten directamente en el gasto de combustible el desarrollar una técnica que sea capaz de analizar y caracterizar el sonido emitido por piezas dañadas. Sin embargo, para la detección de

fallas puntuales de algunas piezas automotrices existen métodos que requieren entrar en contacto directo con las partes, método invasivo, a evaluar para realizar un diagnóstico oportuno. Esto eleva el tiempo durante el cual el conductor se encuentra desprovisto de su automóvil. ¿Es posible entonces, desarrollar una técnica no invasiva que detecte puntualmente fallas por desgaste en de electrodos bujías de automóviles para prevenir daños más graves, lo cual contribuya a un ahorro en el gasto de combustible? Los automóviles hoy en día son herramientas de desplazamiento esencial en el acontecer diario de muchas personas. Los desperfectos que puedan acaecer al vehículo es posible que eleven el uso de combustible que por ende se ven reflejado en un costo mayor que impacta el bolsillo del propietario del automóvil. Los mexicanos gastan en promedio un 3.86% de sus ingresos, unos \$5 mil 336 M.N, en comprar 376.49 litros de gasolina al año, que es el promedio que utiliza un conductor en el país. Este indicador se da en el caso de México con un precio promedio de \$20.79 M.N por litro de combustible, y un ingreso promedio de \$538 M.N por conductor (Bloomberg 2019).

1.2 Justificación.

La presente investigación se enfoca en desarrollar una técnica que mediante la caracterización de sonido emitido por los motores de automóviles que permita identificar bujías con fallas debido al desgaste de los electrodos. Al ser una técnica que utiliza solo el sonido se reduce el tiempo en el que el automóvil se encuentra en mantenimiento. Además de tener un impacto en el ahorro de tiempo y combustible al mantener en óptimas condiciones el automóvil. Como se mencionó anteriormente, los mexicanos gastan en promedio un 3.86% de sus ingresos, unos \$5 mil 336 M.N, en comprar 376.49 litros de gasolina al año, que es el promedio que utiliza un conductor en el país. Este indicador se da en el caso de México con un precio promedio de \$20.79 M.N por litro de combustible, y un ingreso promedio de \$538 M.N por conductor (Bloomberg 2019). En el momento en el que se escribe el presente documento la gasolina tiene un precio promedio de \$19.30 pesos por litro (Regular/Magna), y de \$20.74 pesos por litro (Premium) (Milenio 2019).

1.3 Objetivo General.

El objetivo principal de esta tesis de grado es desarrollar una técnica no invasiva que identifique mediante el uso de un arreglo de micrófonos los desperfectos en automóviles producidos por bujías con desgaste en electrodos a partir de la extracción de características acústicas y establecer en qué medida existe un mayor gasto de combustible.

1.4 Objetivos Específicos.

- Caracterizar y etiquetar los sonidos que contengan fallas en las bujías por desgaste de electrodos.
 - Investigar acerca de algoritmos para obtener los coeficientes cepstrales de Mel, así como algoritmos y funciones para obtener características estadísticas.
 - Obtener grabaciones de automóviles prueba para una y dos bujías en mal estado mediante un arreglo de micrófonos.
 - Hacer un pre-procesamiento de la señal estableciendo una duración máxima para cada archivo de audio.
 - Implementar en las grabaciones obtenidas los algoritmos y funciones para la extracción de características estadísticas, de coeficientes cepstrales de Mel y espectrogramas.
 - Obtener y acondicionar una base de datos a partir de las características obtenidas de los algoritmos.
- Clasificar y determinar el mal funcionamiento de las bujías.
 - Investigar algoritmos de clasificación tales como:
 - * Clasificador K-ésimo vecino más cercano (K-NN).
 - * Clasificador Máquina de Soporte Vectorial (SVM).
 - Preparar la base de datos en dos subconjuntos, entrenamiento y validación.

- Implementar algoritmos de clasificación en tres etapas.
 - * Entrenar de los clasificadores antes mencionados.
 - * Exportar el modelo de clasificador entrenado.
 - * Validar modelo de clasificación.
- Determinar el fallo en un automóvil.
- Comprobar el ahorro de combustible, antes y después de reparada la falla detectada.
 - Calcular el rendimiento de combustible antes y después de reparar la falla en las bujías.
 - * Registrar el gasto de combustible en litros, el consumo de combustible en kilómetros por litro y los litros por cada cien kilómetros, mediante el dispositivo ELM327.
 - * Calcular el consumo de combustible a partir del registro obtenido del vehículo sin fallas.

1.5 Hipótesis.

Es posible a partir de un arreglo de micrófonos y técnicas de *machine learning* analizar, caracterizar e identificar las fallas producidas por motores de automóviles con desperfectos en las bujías por desgaste de electrodos con una precisión mayor al 90%, esto a través de la extracción de características acústicas. Los desperfectos en las bujías además, están relacionados de manera directa al consumo de combustible.

1.6 Estado del Arte

En los últimos años se han desarrollado herramientas y algoritmos para la detección de fallas en motores. En el diagnóstico automotriz los sentidos juegan un papel muy importante al momento de detectar alguna falla. Las personas encargadas de reparar mecánicamente los daños, en especial, las personas con más experiencia en el ramo automotriz detectan fallas a través de los ruidos, el olor, la percepción visual y los demás sentidos. Existen, además

diversos reportes de personas que son capaces de detectar fallas en automóviles tomando en cuenta solamente el sonido generado por los motores. Estos sonidos pueden ser de maneras tan variadas como características.

1.6.1 Estudios centrados en el uso del sonido.

Dentro de los estudios enfocados al análisis de sonido en el trabajo “Insulation fault identification of vacuum circuit breakers based on improved MFCC and SVM” (Luo, Liu, and Yan 2019) propone un método para monitorear el estado del aislamiento a través de la recolección incorporada en el circuito interruptor automático. Cuando el aislante tiene problemas serios, la superficie aparecerá como descarga corona o descarga parcial, y el dispositivo de grabación recogerá el sonido generado por la descarga. Se utiliza el algoritmo MFCC para extraer los parámetros característicos de la señal de descarga. Se construye el SVM de una clase para identificar si la señal es una descarga superficial o no. Los vectores característicos de la señal de audio de descarga tienen una similitud intrínseca, y la distribución puede concentrarse, lo que es significativamente diferente de otros sonidos anormales. Se obtiene una precisión en la clasificación del 92.15% para muestras de descarga superficial y hasta un 94.43% para muestras de no descarga (Luo, Liu, and Yan 2019).

Algunos estudios, como el de “Research on Transformer Audio Fault Identification Method Based on Neural Network” (Lin et al. 2019) se propone un nuevo método para monitorear la salud de los transformadores. Basado en la biblioteca de código abierto para aprendizaje automático *tensorflow*, el modelo de red neuronal multicapa se entrena utilizando un vector de características usando MFCC proveniente de la señal de audio del transformador en funcionamiento. El algoritmo de “Back-Propagation” (BP) se utiliza para entrenar iterativamente toda la red neuronal e inicializar aleatoriamente los valores iniciales. El parámetro se ajusta por el error entre la salida y la etiqueta hasta la convergencia global. Se obtiene una tasa de error del 5% y una precisión del 95% (Lin et al. 2019).

Existe otro estudio presentado en el trabajo titulado “Noise-Robust Sound-Event Classification System with Texture Analysis” (Choi et al. 2018) que se enfoca en un sistema resistente al ruido para la clasificación de datos de sonido. En este método, primero convertimos las

señales de sonido unidimensionales en imágenes bidimensionales de nivel de gris mediante la normalización, y luego extraemos las imágenes de textura mediante la técnica de estructura de vecindad dominante (DNS). Finalmente, validamos experimentalmente el enfoque resistente al ruido mediante el uso de cuatro clasificadores (red neuronal convolucional (CNN), máquina de vectores de soporte (SVM), vecinos más cercanos a k (k-NN) y C4.5). En este experimento, se colocó un sensor de sonido (SHURE SM137) frente a una máquina de punto de ferrocarril para recoger el sonido generado cuando una máquina de punto de ferrocarril cambiaba. Los resultados experimentales mostraron un rendimiento de clasificación superior en condiciones ruidosas en comparación con otros métodos. La precisión supera el 98,80% en datos ferroviarios y el 96,57% en datos ganaderos (Choi et al. 2018).

Además, se propone en el trabajo “Multi-view stacking for activity recognition with sound and accelerometer data” (Garcia-Ceja, Galván-Tejada, and Brena 2018) el uso de un método de apilamiento de múltiples vistas para fusionar los datos de tipos heterogéneos de sensores para el reconocimiento de la actividad. Específicamente, utiliza datos de sonido y un acelerómetro recopilados con un teléfono inteligente y una pulsera (Microsoft Band 2) mientras se realizaban tareas domésticas. El método consiste en entrenar un modelo (Random Forests y HAR tasks) para cada una de las tomas del sensor y combinarlas con el apilamiento. Los resultados obtenidos clasifican las tareas con una precisión de hasta el 94.1% (Garcia-Ceja, Galván-Tejada, and Brena 2018).

Otros estudios hacen uso del sonido tal como el titulado “Analysis of a multiclass classification problem by Lasso Logistic Regression and Singular Value Decomposition to identify sound patterns in queenless bee colonies” (Robles-Guerrero et al. 2019). Que presenta un análisis de un problema de clasificación multi-clase para identificar estados sin reina mediante el monitoreo del sonido de las abejas en dos casos posibles; una colonia fuerte y saludable que perdió a su reina y una población reducida sin reina. Los patrones de sonido se compararon con los patrones de colonias saludables de reina. Se monitorearon cinco colonias de abejas melíferas *Carniola* utilizando un sistema basado en una Raspberry Pi 2 y micrófonos omnidireccionales colocados dentro de las colmenas. La extracción de características se realizó mediante el método de coeficientes cepstrales de frecuencia de Mel (MFCC). Para la selección

y regularización de características, se utilizó un modelo de regresión logística Lasso. El modelo puede lograr una alta tasa de clasificación, más del 95% de las muestras se clasificaron correctamente (Robles-Guerrero et al. 2019).

El Grupo de Electrónica Digital Aplicada (GEDA) del Instituto Tecnológico de Buenos Aires, Argentina; en su trabajo de investigación titulado para el VI Congreso Iberoamericano de Acústica-FIA 2008 “Localización y separación de fuentes de audio mediante el uso de un arreglo de micrófonos” (Chavanne, Martinez, and Suarez 2008) aborda básicamente que, la detección y separación consiste en que dado un conjunto de fuentes de sonido dentro de una sala, como pueden ser personas hablando o altoparlantes, es posible detectar el ángulo (medido con el arreglo de micrófonos y utilizando este último como sistema de referencia) del provienen cada una de dichas fuentes. Expresa además que el arreglo de micrófonos es lineal y los micrófonos son equidistantes y cómo se captan distintas versiones de la misma señal incidente, es decir con un cierto atraso o adelanto. Acentúan dentro del mismo artículo que para la detección de fuentes se opta por el algoritmo MUSIC (Multiple Signal Classification), cual trabajando con la matriz de covarianza de las señales captadas por los micrófonos del arreglo, calcula los ángulos de donde provienen. En el caso de la separación de fuentes hacen uso de la técnica beamforming (Chavanne, Martinez, and Suarez 2008).

1.6.2 Estudios enfocados al análisis de sonidos en motores.

En el trabajo de investigación “Severity Analysis of Motorcycle Faults Based on Acoustic Signals” (Veerappa and Ramesh 2018) aborda la detección y localización de fuentes de fallas en motocicletas basadas en “firmas acústicas”. La investigación se aborda en 3 etapas: la detección de fallas, localización de la fuente de fallas y análisis de severidad de fallas. Hace uso de la distribución de energías en las primeras cinco sub-bandas de un paquete Wavelet y se consideran como características establecidas para el procesamiento y análisis de señales. El modelo se prueba con varios clasificadores, incluidos ANN, DTW, k-NN y k-Means. Se emplea el mismo conjunto de características y clasificadores en cada etapa del proceso. Se evalúan tres niveles de gravedad de la falla: alta, media y baja. Se observa una precisión de

clasificación de hasta el 92% para la detección de fallas y la etapa de localización, mientras que se observa una precisión del 90% para el análisis de gravedad (Veerappa and Ramesh 2018).

Dentro del trabajo de investigación “Separation Method of Impulsive Fault Component for Gasoline Engine Based on Acoustic Signal Analysis” (Dayong et al. 2019) se desarrolla “método superpuesto de dislocación” (DSM) para extraer automáticamente el componente de las señales impulsos de las señales de ruido anormales provocados por el golpeteo en el cilindro de un motor a gasolina en un rango de velocidad de 1800 rpm sobre la base del DSM inicial. El motor sobre el que se hicieron las pruebas es de 4 cilindros en línea y 1.4 L. Este método consta de tres pasos: usar un análisis de correlación para seleccionar un punto de superposición de inicio apropiado, se superponen señales de sonido anormales para mejorar la relación señal / ruido e interceptar señales superpuestas para separar el componente de falla. Los resultados experimentales muestran que el DSM desarrollado puede extraer efectivamente las características de falla del golpeteo del cilindro y del golpe del rodamiento de la biela (Dayong et al. 2019).

El investigador Luis Andrés Méndez Ortega menciona en su trabajo “Análisis y Clasificación de Sonidos de Motores de Carros, para Diagnosticar Fallas, con Ayuda de Redes Neuronales” (Andrés et al. 2009), que la detección de posibles fallas en un motor de automóvil en funcionamiento pueden ser capturadas a través de la identificación de los cambios en la vibración. Esta técnica se basa en utilizar “Coeficientes Cepstrales de Predicción Lineal (LPCC)” como extractor principal de características acústicas, así como el “Análisis de Componentes Principales” (PCA) obteniendo un 95.58% de reconocimiento cuando se diagnosticaron 3 fallas en el motor. Un oído acostumbrado detecta rápidamente la diferencia existente entre los ruidos producidos que podríamos llamar normales y una serie de ruidos anormales, tales como silbidos, golpeteos en la máquina, el castaño de los engranes que vibran, etcétera (Andrés et al. 2009).

En el desarrollo del proyecto “Fault diagnosis of rotating machinery based on multiple probabilistic classifier” (Zhong, Wong, and Z. X. Yang 2018) se propone un nuevo marco de diagnóstico de fallas que consta de tres etapas: En la primera se realiza el procesamiento de señales y extracción de características mediante la descomposición empírica en modo conjunto (EEMD) se descompone la señal adquirida en un conjunto de funciones de modo intrínseco

(IMF) que encuentra componentes redundantes y problemas de datos. Se aplican además los métodos de coeficiente de correlación (CC) y descomposición de valor singular (SVD). En la segunda etapa se lleva a cabo el diagnóstico de fallas combinando los resultados de clasificación a través de un método de conjunto probabilístico. Para mejorar el rendimiento del diagnóstico de fallas basado en un solo clasificador y aumentar el número de fallas detectables, se propone un nuevo método de “Máquina de Comité Probabilístico” (PCM), en el que múltiples máquinas de aprendizaje extremo bayesianas dispersas acopladas por pares son entrenados individualmente usando la ración de aire, patrón de encendido y señal de sonido del motor. Como tercera etapa se realiza optimización de parámetros y evaluación de desempeño. Los resultados de la evaluación muestran que el marco propuesto es superior al clasificador único existente en términos de fallas tanto simples como simultáneas en el motor automotriz. El marco de diagnóstico propuesto logra las mejores precisiones para fallas simples (92.62%) y fallas simultáneas (85.73%) (Zhong, Wong, and Z. X. Yang 2018).

Otro método propuesto dentro de la literatura es el uso de espectrograma como visualizador del dominio de tiempo frecuencia para el análisis de diferentes fallas en el motor de combustión interna. A partir de la información obtenida de la representación del espectrograma de diferentes fallas, se calculan varias características estadísticas como la curtosis, la varianza, la inclinación, el factor de forma, la raíz cuadrada del valor cuadrático medio, la media absoluta, la tasa de cruce por cero, el pico máximo. Estas características estadísticas se utilizaron para la clasificación de fallas utilizando una red neuronal. Las señales acústicas fueron adquiridas bajo siete condiciones distintas, las cuales incluían seis estados de falla y una de operación normal. Para la captación de señales cuatro micrófonos fueron puestos en diferentes localizaciones del motor de combustión interna. Menciona este trabajo que la información captada a la salida de cada micrófono fue analizada utilizando el método propuesto de espectrograma y red neuronal (Sandeep Kumar Yadav 2010).

1.6.3 Estudios centrados en el consumo combustible.

En el caso del estudio del consumo de combustible el trabajo “Determinación del consumo de combustible de vehículos con base a los ciclos de conducción EPA FTP75 Y EPA HWFET,

en dinamómetro de chasis” (Erraez and Fajardo 2018) propone determinar el consumo de combustible en dos de los vehículos más comercializados en la ciudad de Cuenca (Chevrolet Aveo Activo 2011 y Kia Picanto 2006). Para ello se utilizó un dinamómetro de chasis y ciclos de conducción establecidos por la EPA (FTP75 y HWFET). También se hace uso del sistema OBD2 con el dispositivo ELM327 y del flujómetro KVM 2012. Los resultados mostraron que para el vehículo Chevrolet Aveo, el OBD2 presenta un 31.7% mayor de consumo de combustible en relación al del fabricante y un 14.4% mayor al obtenido por el flujómetro en el ciclo HWFET, y para el ciclo FTP75, existe una diferencia de 10.46% mayor al del fabricante y 15.79% mayor al obtenido por el flujómetro. En cuanto al vehículo Kia Picanto, el consumo de combustible obtenido por el OBD 2 es 38.28% mayor al del fabricante y 14.5% mayor al obtenido por el flujómetro en el ciclo de conducción HWFET, y para el ciclo FTP75, hay una diferencia de 18.35% mayor al del fabricante y 17.7% mayor al obtenido por el flujómetro (Erraez and Fajardo 2018).

Los dispositivos de medición a bordo se han utilizado en investigaciones anteriores para recopilar datos de actividad de vehículos, pero la cantidad de datos a veces es limitada. El trabajo “Real-world driving cycles and energy consumption informed by large-sized vehicle trajectory data Ruoyun” (Ma et al. 2019) utiliza datos de trayectorias GPS segundo a segundo de 459 automóviles de pasajeros privados, que cubren más de 17,000 días de muestreo, utiliza además técnicas de minería de datos grandes para estudiar las variaciones en los ciclos de manejo del mundo real. El trabajo se lleva a cabo en China. Se desarrolla un método de cadena de Markov para generar ciclos de conducción típicos que tienen características representativas de la conducción en el mundo real. Como estudio de caso, dos ciclos típicos, el ciclo en horas de tráfico y el ciclo de horas sin tráfico se construyen a partir de seis subciclos que representan diferentes tipos de carreteras y períodos de viaje. Los resultados mostraron que el consumo de combustible (valor medio) del ciclo de horas sin tráfico y del ciclo en horas de tráfico fue más alto que el nivel de aprobación de tipo Europeo en un 29,3% y un 37,5%, respectivamente (Ma et al. 2019).

1.7 Estructura de la tesis.

El presente trabajo está desarrollado en las siguientes 5 secciones. El capítulo 1 contiene una introducción al trabajo desarrollado, incluyendo la problemática, justificación, hipótesis, objetivos, etcétera. Durante el capítulo 2 se habla de un panorama general sobre la detección y clasificación de señales acústicas captadas de los motores con fallas producidas por bujías con desgaste en electrodos, a su vez se explican las herramientas y conceptos utilizados para el desarrollo de esta investigación. Más tarde, en el capítulo 3 se explica la metodología y experimentación que se llevó a cabo a lo largo del desarrollo de la presente tesis. En un capítulo 4 se abarca los resultados obtenidos y un apartado de discusión sobre los resultados generales del trabajo. Por último, en el capítulo 5 se aborda las conclusiones y una propuesta de trabajo futuro.

Capítulo 2

Detección y clasificación de señales acústicas de fallas en bujías por desgaste de electrodos.

En el presente capítulo se describe el diseño metodológico a partir de un enfoque de investigación experimental y cuantitativo. Se aborda de manera general las características principales del sistema de encendido y bujías de vehículos. Se describe además, técnicas y herramientas de análisis de señales acústicas a partir de las cuales se pueden extraer características estadísticas de espectrogramas así como coeficientes cepstrales de Mel (MFCC) de las señales. Los clasificadores que se describen son el k-ésimo vecino más cercano (K-NN) y máquina de soporte vectorial (SVM). En una última sección se aborda lo correspondiente al rendimiento de combustible.

2.1 Sistema de encendido de automóvil.

El sistema de encendido del motor de un automóvil implica la producción de una chispa en las bujías y su distribución en los cilindros del motor en el correspondiente orden de funcionamiento. A continuación se enlista los componentes del sistema de encendido (Motor 2018).

1.- Bobinas de encendido. A diferencia del sistema de encendido electrónico, en el que se utiliza una sola bobina de encendido para generar alta tensión, el sistema de encendido sin




Figura 2.1: Partes que componen el sistema de encendido.

distribuidor utiliza un número de bobinas de encendido, es decir, cada bobina por bujía de encendido que generan alta tensión individualmente para cada bujía de encendido.

2.- Bujía. Se utiliza para generar chispa en el interior del cilindro.

3.- Módulo de control de encendido (MIC) o unidad de control de encendido. Es la instrucción programada dada al conjunto de chips que es responsable de ajustar el circuito de la bobina primaria a encendido o apagado.

4.- Interruptor de encendido. Controla el encendido y apagado del vehículo a través de un interruptor accionado por llave.

5.- Batería. Se utiliza como fuente de energía para alimentar eléctricamente los elementos del automóvil.

6.- Dispositivo de disparo del cigüeñal. Se utilizado para detectar la posición o la carrera del pistón.

7.- Dispositivo de activación del árbol de levas. Este dispositivo es utilizado para la detección de la sincronización de válvulas (Motor 2018).

2.1.1 Sistema de bujías.

Los motores de gasolina presentan un ciclo de cuatro tiempos, estos también son llamados motores de ciclo *Otto*: En el tiempo de compresión se inicia la combustión de la mezcla comprimida de combustible y aire, mediante una chispa eléctrica. La misión de la bujía de

encendido es generar esa chispa. La chispa se produce gracias a la alta tensión generada por la bobina de encendido y salta entre los electrodos. Partiendo de la chispa, se expande un frente de llamas por toda la cámara de combustión, hasta que se ha quemado la mezcla. El calor liberado aumenta la temperatura y la presión en el cilindro, presionando así el pistón hacia abajo. El movimiento es transmitido por la biela al cigüeñal – el cigüeñal propulsa al vehículo a través del embrague y los semiejes.

Para que el motor pueda funcionar sin problemas, a plena potencia y respetando a la vez el medio ambiente, deben cumplirse varias condiciones: debe existir la cantidad necesaria de mezcla óptima de aire y combustible en el cilindro, la chispa de encendido rica en energía debe saltar entre los electrodos en el momento exacto determinado por la computadora del automóvil. Las bujías de encendido deben ofrecer las máximas prestaciones: Entre unas 500 y 3,500 veces por minuto, la bujía debe suministrar una potente chispa de encendido -incluso a la máxima potencia durante horas o con un tráfico de parada y arranque. Incluso a -20°C deben asegurar que se alcance rápidamente la temperatura adecuada para el encendido. Las bujías de alta tecnología proporcionan un encendido poco nocivo y un aprovechamiento óptimo del combustible -sin fallos de encendido que pueden provocar la entrada de combustible no quemado al catalizador y daños en el mismo (Aktiengesellschaft 2015).




Figura 2.2: Partes que componen una bujía.

2.1.2 Fallas en sistema de bujías.

Tal como se muestra en la Figura 2.2 una bujía está compuesta de diversos elementos que suelen estar sometidos a diversas temperaturas provenientes de la alta tensión generada por las bobinas. Es normal que se presenten algunos depósitos marrones o grises en los electrodos después de cierto tiempo de uso. Un buen mantenimiento consta de que estén limpias las bujías, que se respete la distancia entre los electrodos (calibración) y que se reemplacen según indique el fabricante. Esto permitirá un óptimo rendimiento del sistema sin alteraciones en el consumo de combustible o en el funcionamiento del motor (RO-DES 2018).

A continuación se muestran algunas de las fallas más comunes en el sistema de bujías:

- Punta de encendido cubierta de carbón. Cuando circulamos mucho tiempo a baja velocidad, el sistema de encendido presenta algún fallo o la mezcla de combustible y aire, los restos de carbonilla, cubren la punta de la bujía.
- Punta de encendido engrasada y negra. Cuando los aros del pistón tienen fugas, los cilindros están deteriorados, o las proporciones de aceite son muy elevadas en motores de dos tiempos, la punta se ennegrece y recubre de este fluido.
- Aislador de porcelana vidrioso y blanco. Se funden sedimentos en la cerámica cuando el octanaje es muy bajo, el sistema de refrigeración no está funcionando correctamente, o la mezcla de aire y combustible es muy pobre.
- Aislador y electrodos quemados o con residuos granulados: Este recalentamiento es provocado por un tiempo de encendido demasiado adelantado o por causas similares al caso anterior.
- Electrodo fundido. Someter el sistema a elevadas temperaturas, como conducir frecuentemente a altas velocidades, problemas en la refrigeración o un foco de recalentamiento en la cámara de combustión, puede llegar a fundir los electrodos o el aislador de porcelana a causa de la pre-ignición.


- Electrodo verdoso u oxidado. Si el clima es demasiado húmedo, el vehículo pasa largos periodos sin uso o usamos frecuentemente combustibles de mala calidad, la corrosión y el óxido acabarán con nuestras bujías.
- Aislador roto. Cuando la punta de porcelana está visiblemente rajada es probable que se deba a un choque térmico. Si se llega a desprender, puede dañar cilindros, válvulas o pistones.
- Aislador y electrodos con incrustaciones blancas: Suele ser consecuencia de usar combustible de baja calidad o pérdidas de aceite por los aros del pistón. Estos residuos se solidifican en la punta de la bujía, y será difícil de limpiar
- Desgaste excesivo del electrodo central. Este fallo se produce principalmente a causa del uso cotidiano de la bujía, al no ser remplazada en el tiempo recomendado produce traqueteos en el motor (especialmente en la aceleración del vehículo) debido al aumento considerable de la distancia entre electrodos y además probables fallas en el encendido (RO-DES 2018).

La clasificación de las señales acústicas provenientes de los motores que presentan fallas producidas por el desgaste de electrodos es el objeto de estudio para el presente trabajo debido a que sus causas no van más allá del desgaste común y sus efectos pueden ser perjudiciales para el motor y su correcto encendido, por lo que la convierte en una de las fallas más frecuentes en automóviles.


2.2 Técnicas de adquisición de sonido.

La manera de grabar señales acústicas es a través de micrófonos los cuales consisten se encargan de transformar un sonido en una señal eléctrica para que esta pueda ser amplificada, procesada y transmitida. Para realizar este proceso todo micrófono cuenta con un elemento muy importante el transductor que se encarga de detectar y convertir las ondas sonoras en señales eléctricas. Los micrófonos se pueden dividir en dos grandes tipos: *Dinámicos* y *Condensadores*.

- Micrófono dinámico. Este tipo de micrófono es el más utilizado. Su diseño consiste de un diafragma, una bobina y un imán. Es muy parecido a la construcción de un parlante.
- Micrófono condensador. Utilizan un diafragma más delgado, con una platina cargada eléctricamente por detrás. Cuando el diafragma vibra, altera el espacio que existen entre este mismo y la platina, creando una señal eléctrica (Infinity Recording Studio 2017).



(a) Micrófono dinámico.



(b) Micrófono de condensador.

Figura 2.3: Partes de los diferentes tipos de micrófonos.

Existen registradas en la literatura diversas técnicas de adquisición de señales acústicas. La más común es situar los micrófonos sobre un equipo tipo pedestal a una distancia relativamente cerca, esto depende de la localización así como la estructura y morfología del objeto a grabar. En el caso de la adquisición de señales acústicas provenientes de partes de automóviles los micrófonos se ubican, puesto que están dentro de una estructura, lo más cerca a la parte a grabar. En el trabajo *Vibro-Impact Analysis of Manual Transmission Gear Rattle and Its Sound Quality Evaluation* (G. Wu and H. Wu 2018) menciona que los experimentos con vehículos se llevaron a cabo en carreteras planas, rectas y entornos abiertos. El micrófono se situó a unos 30 cm. de la parte central de la carcasa de la transmisión manual de un Vehículo utilitario deportivo (SUV). Consideran además que la disposición del micrófono se hace sobre una superficie grande y plana, alejada de partes del vehículo donde la temperatura pueda ser alta. Simultáneamente el ruido de ambiente debe ser menor que el sonido generado por el mismo vehículo (G. Wu and H. Wu 2018).

Algunos proyectos como el de *Acoustic transfer function in gasoline engines* (Mahroogi and Narayan 2018) realizan la adquisición de sonido utilizando un micrófono de condensador

de estudio (*Behringer ECM8000*). Las grabaciones son hechas para un motor de gasolina de un cilindro (KPKN2520) en donde se escogen tres partes distintas del motor para adquirir las señales acústicas. Esto lo realizan para tres distintas revoluciones y dos capacidades de carga para el motor. Otra técnica empleada para la adquisición de sonido es mediante el uso de arreglos de micrófonos, estos son dispositivos que recolectan el sonido de acuerdo a una topología específica a través de una serie de micrófonos. En comparación con un solo micrófono, los arreglos de micrófonos tienen la ventaja de poder ser utilizados para la localización de fuentes de sonido, la eliminación del ruido ambiental y el seguimiento de objetivos (Ruili, Rong, and Lei 2018).

2.3 Reconocimiento de patrones en fuentes de sonido.

Se han propuesto varios sistemas en el campo de reconocimiento de patrones acústicos desde hace pocos años. Dependiendo del problema que se ha intentado resolver, un punto en común de estos enfoques se centra en un análisis espectral detallado de la señal acústica. En el proyecto *Bayesian Subspace Methods for Acoustic Signature Recognition of Vehicles* (Munich 2004) se hace uso de Coeficientes Cepstrales de Frecuencias de Mel para el análisis acústico, modelos de Mezcla Gaussiana (GMM, por sus siglas en inglés) y modelos ocultos de Markov (HMM), combinados con Métodos de Sub-espacio Bayesiano aplicado al reconocimiento automático de características acústicas de vehículos. Se utiliza principalmente en operaciones militares para propósitos de vigilancia, registrando una precisión del 83% (Andrés et al. 2009). Otra manera de reconocer patrones de fuentes de sonido es a través de la máxima verosimilitud. En particular, se utiliza un enfoque de maximización de expectativas (EM) para estimar las ubicaciones y las intensidades de la fuente de sonido, interpretándose la presión medida por un micrófono como una mezcla de señales latentes emitidas por las fuentes. Este trabajo también considera dos tipos de incertidumbres que impregnan el proceso de propagación y medición del sonido: ubicaciones inciertas del micrófono y número de onda incierto. Luego, las ubicaciones y las fortalezas de la fuente se pueden estimar utilizando una variante del algoritmo EM, conocido como el algoritmo Evidencial EM (E2M) (Wang 2015).

Uno de los objetivos principales de encontrar patrones de sonido es poder clasificar señales acústicas. En el presente trabajo los patrones representan características de estas señales que están asociadas a fallas. Estos patrones se establecen como particularidades que contrastan al compararlos entre sí. Un humano puede detectar la diferencia entre un camión y un automóvil o un motor diésel o de gasolina fácilmente y esto es debido a que el cerebro almacena cierto patrones que permiten diferenciar distintos sonidos. Pedirle a una computadora que haga la misma tarea presenta algunos problemas. Las computadoras son rápidas en el cálculo, pero no son particularmente buenas para extraer inferencias a partir de datos incompletos. Los tipos específicos de algoritmo de búsqueda que tienen valor en este contexto son los clasificadores Bayesianos (NBC) y las redes neuronales artificiales (ANN) (Johnstone 2013).

2.4 Técnicas de análisis de señales acústicas

2.4.1 Espectrogramas.

El espectrograma consiste en la representación gráfica del espectro de frecuencias de una señal acústica o de una emisión sonora. El espectrograma puede revelar rasgos, como altas frecuencias o modulaciones de amplitud, que no pueden apreciarse incluso aunque estén dentro de los límites de frecuencia del oído humano (20Hz hasta 20kHz). Usualmente, un espectrograma representa el tiempo sobre el eje horizontal, la frecuencia sobre el eje vertical y la amplitud de las señales mediante una escala de grises o de colores tal como se muestra en la Figura 2.4 (Arturo, Mascorro, and Torres 2013).

Otra manera de describir un espectrograma es la representación tridimensional con el nivel de energía en cada momento de la señal. En este sentido el espectrograma puede ser visto como una gráfica de intensidades (usualmente en una escala logarítmica como lo es los dB) de la magnitud de la Transformada Corta de Fourier (STFT). La STFT es simplemente una secuencia de Transformadas de Fourier de segmentos de datos ventaneados, donde las ventanas generalmente se superponen en tiempo, generalmente en un 25-50% (CCRRMA 2019).

$$STFT\{x(t)\} \equiv X(\tau, \omega) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\omega t} dt \quad (2.1)$$




Figura 2.4: Comparativa de una señal en tiempo y su espectrograma.

donde $w(t)$ es la función ventana y $x(t)$ la señal a ser transformada, $X(\tau, \omega)$ es esencialmente la Transformada de Fourier de $x(t)w(t - \tau)$, una función compleja que representa la fase y la magnitud de la señal sobre tiempo y frecuencia. Para el caso discreto, la información a ser transformada debe ser dividida en tramas (que como ya se mencionó anteriormente se traslapan para tratar de eliminar irregularidades en las fronteras).

$$STFT\{x[n]\} \equiv X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n]w[n - m]e^{-j\omega n} \quad (2.2)$$

Análogamente $x[n]$ es la señal y $w[n]$ es la ventana.

2.4.2 Coeficientes Cepstrales de las Frecuencias de Mel (MFCC).

Los Coeficientes Cepstrales en la Escala de Mel (MFCC) representan la amplitud del espectro del habla de manera compacta, esto los ha vuelto la técnica de extracción de características más usada en reconocimiento del habla.

Primeramente para obtener un vector de características, se aplica un filtro de pre-énfasis a la señal y posteriormente se divide la misma en tramas y se aplica una función de ventaneo, el ventaneo es una función matemática que sirve para eliminar los bordes de la señal y darle una acentuación a la parte central de la trama para su análisis. Algunas de las funciones ventana

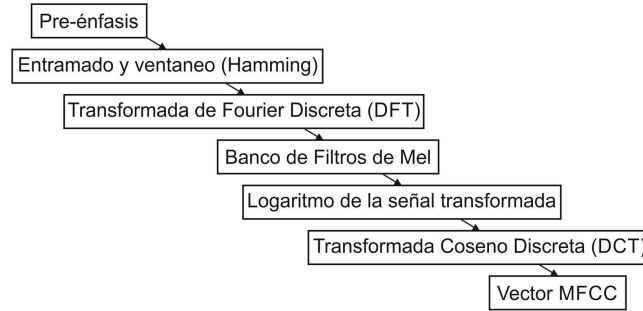


Figura 2.5: Proceso para la elaboración de un vector característico de MFCC.

más utilizadas son las ventanas Hanning y Hamming:

$$v(n) = a_0 - a_1 \cos\left(\frac{2\pi n}{N-1}\right) \quad (2.3)$$

donde N es el tamaño de la trama, a_0 y a_1 son 0.5 para el caso de la ventana Hanning y $a_0 = 0.53836$, $a_1 = 0.46164$ en el caso de la ventana Hamming. Posteriormente se obtiene la Transformada Discreta de Fourier (DFT) de cada trama se utiliza la amplitud del espectro,

$$X_k = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi j}{N} kn} \quad k = 0, \dots, N-1 \quad (2.4)$$

donde X_k son números complejos que representan la amplitud y la fase de diferentes componentes sinusoidales de la señal entramada de entrada $x(n)$. Esta información es pasada al dominio de Mel mediante un Banco de Filtros. La escala Mel se basa en mapear entre la frecuencia actual al *pitch* que percibe un escucha humano simulado, esta escala es lineal por debajo de 1kHz y logarítmica por encima de este umbral.

$$Mel(f) = 2595 \log\left(1 + \frac{f}{700}\right) \quad (2.5)$$

Después se obtiene el logaritmo de la señal para finalmente aplicar la Transformada de Coseno Discreta (DCT). De este vector obtenido se toman la cantidad de coeficientes deseados por trama (Arturo, Mascorro, and Torres 2013).

$$C(u) = \alpha(u) \sum_{x=0}^{N-1} f(x) \cos\left(\frac{(2x+1)u\pi}{2N}\right) \quad (2.6)$$

donde:

$$\begin{aligned} \alpha(u) &= \sqrt{\frac{1}{N}} & \text{para } u = 0 \\ \alpha(u) &= \sqrt{\frac{2}{N}} & \text{para } u = 1, 2, \dots, N - 1 \end{aligned} \quad (2.7)$$

Con esto se obtiene un vector de coeficientes en la escala de Mel que posteriormente puede ser utilizado para caracterizar y clasificar patrones.

2.5 Clasificadores.

2.5.1 Aprendizaje automático.

El aprendizaje automático o *Machine Learning* refiere a la capacidad de adquirir conocimientos o habilidades por parte de un ente autónomo como lo puede ser una computadora. El objetivo primordial del aprendizaje automático es la creación de un sistema capaz de dar una solución satisfactoria cuando se le introduce información acerca de un fenómeno. En función de la retroalimentación que reciba el sistema se distinguen varios tipos de aprendizaje (Di Deco Sampedro 2012).

Como entrada a los algoritmos de *machine learning*, se tienen características y etiquetas sobre un conjunto de muestras. Las características son todas aquellas medidas o datos que se encuentran en todas las muestras, estas se pueden encontrar en crudo o con alguna transformación matemática, por otro lado, las etiquetas hacen referencia a lo que el modelo pretende predecir (salida del modelo). El siguiente paso es hacer que el modelo aprenda ya sea a través del aprendizaje no supervisado, aprendizaje supervisado o aprendizaje reforzado, dependiendo del problema que se presente, una vez entrenado el algoritmo se hacen predicciones y validaciones con datos nuevos (Alcala 2019).

Los métodos de aprendizaje se clasifican en los siguientes tipos:

- **Supervisados.** Este método se basa en etiquetas o ejemplos proporcionados como entrada y son *necesarios* para cumplir las metas de aprendizaje, se hace la analogía de aprender con un profesor.
- **No Supervisados.** Este método de aprendizaje es diseñado para desarrollar nuevos conocimientos mediante el *descubrimiento* de regularidades o patrones en los datos.

- **Reforzado.** Este tipo de aprendizaje se encuentra en un punto medio de los dos anteriores. Al sistema se le presenta una problemática a resolver. El aprendizaje se realiza únicamente con una señal de refuerzo proporcionada por un “profesor” o por el entorno como indicador de si se ha resuelto correctamente el problema (Moreno et al. 1994).

2.5.2 K-ésimo Vecino más Cercano (K-NN).

El K-NN es un algoritmo de aprendizaje supervisado, es decir, que a partir de un conjunto de datos inicial su objetivo será el de clasificar correctamente todas las instancias nuevas. Este algoritmo utiliza “características similares” para predecir los valores de los nuevos datos, lo que significa que al nuevo punto de datos se le asignará un valor en función de cuán cercanamente coincide con los puntos del conjunto de entrenamiento.

Como primer paso tenemos que para implementar cualquier algoritmo se necesita un conjunto de datos a clasificar. Así que, durante este primer paso se carga el conjunto de entrenamiento así como el de validación o prueba. Ahora, se escoge un valor para k que representa el número de vecinos más cercanos a un punto de prueba, cabe señalar que k es un valor entero. Para cada punto del conjunto de datos se hace lo siguiente:

- Se calcula la distancia entre los datos de prueba y cada fila de los datos de entrenamiento con la ayuda de los métodos: distancia euclidiana, de Manhattan o de Hamming. El método más utilizado para calcular la distancia es el euclidiano.
- Ahora basados en los valores de las distancias, estos se ordenan ascendentemente.
- Después se escogerán las k filas superiores de la matriz ordenada.
- Por último se asignará una clase al punto de prueba basado en la clase más frecuente de estas filas. Así es como un nuevo punto de prueba se asigna a una clase.

Este algoritmo presenta dos propiedades a tener en cuenta:

- **Lazy learning algorithm.** Esto quiere decir que no tiene una fase de entrenamiento especializada como tal y utiliza todos los datos para el entrenamiento mientras clasifica.

- Non-parametric learning algorithm. Esto quiere decir que este algoritmo de aprendizaje no asume nada sobre los datos subyacentes, por lo que es llamado no paramétrico (ponit 2019).

Pensemos en un conjunto de datos donde cada instancia se corresponde con un cliente de una entidad financiera. Para cada cliente conocemos una serie de atributos, como sus ingresos, gastos, patrimonio, edad, etc., también para cada cliente tenemos un atributo objetivo o clase que trataremos predecir: es o no apto para un préstamo personal.

Sea D nuestro conjunto de datos en el que distinguimos la siguiente estructura:

$$D_{m,n} = \begin{bmatrix} d_1 = a_{1,1} & \cdots & a_{1,n} & c_1 \\ d_2 = a_{2,1} & \cdots & a_{2,n} & c_2 \\ \vdots & \vdots & \vdots & \vdots \\ d_m = a_{m,1} & \cdots & a_{m,n} & c_m \end{bmatrix} \quad (2.8)$$

Donde d_m indica cada una de las instancias del conjunto de datos (los clientes), a_{mn} indica cada uno de los atributos descriptivos (ingresos, gastos, patrimonio, edad, etc.) y c indica el atributo objetivo o clase a predecir (es o no apto para un préstamo personal). Para crear el modelo, partimos nuestro conjunto de datos D en dos partes aleatorias: una compuesta por el 70% que usaremos para entrenar, y otra por el 30% restante que usaremos para validar el modelo.

En este punto, merece la pena comentar que puede llegar a producirse el efecto del sobre-entrenamiento del modelo (overfitting), lo que provoca que el modelo que se construye, en lugar de describir las estructuras subyacentes del conjunto de datos, lo que acaba describiendo sea, exclusivamente, el conjunto de datos de entrenamiento no siendo extrapolable a otros conjuntos de datos. Fijamos un valor para k , habitualmente pequeño, y hacemos que el algoritmo compute una instancia d del conjunto de datos de prueba. Fruto de este proceso, el algoritmo selecciona las k instancias del conjunto de datos de entrenamiento más cercanas (de acuerdo con la métrica de similitud utilizada) y se asigna la instancia d a la clase más frecuente de entre las k instancias seleccionadas como más cercanas (TECH and ANALYTICS 2017).




Figura 2.6: Representación gráfica del algoritmo K-NN.

En el presente trabajo se plantea utilizar un clasificador de este tipo, cuyas entradas, serán las variaciones en un intervalo de frecuencias del espectro de potencia correspondiente a las grabaciones de los automóviles, así como parámetros característicos de las señales separadas, escalograma, espectrograma, etcétera.

2.5.3 Máquina de Soporte Vectorial (SVM).

Una máquina de soporte vectorial (SVM) es un algoritmo de aprendizaje para la clasificación de patrones. El principio básico de entrenamiento detrás de SVM es encontrar el hiperplano lineal óptimo de tal manera que se minimice el error de clasificación esperado para muestras de prueba no vistas. De acuerdo con el principio inductivo de minimización del riesgo estructural, una función que clasifica los datos de entrenamiento con precisión y que pertenece a un conjunto de funciones con la dimensión más baja se generalizará mejor independientemente de la dimensionalidad del espacio de entrada. Basado en este principio, un SVM lineal utiliza un enfoque sistemático para encontrar una función lineal con la dimensión más baja. Para datos no separables linealmente, los SVM pueden (no linealmente) asignar la entrada a un espacio de características de mayor dimensión donde se puede encontrar un hiperplano lineal. Aunque no hay garantía de que siempre exista una solución lineal en el espacio de mayor dimensión, en la práctica es bastante factible construir una solución.

Dado un conjunto etiquetado M de muestras entrenadas (x_i, y_i) , donde $x_i \in R^N$ y y_i es la etiqueta asociada $y_i \in \{-1, 1\}$ un clasificador SVM encuentra el hiperplano óptimo que separa (clasifica) correctamente la fracción más grande de puntos de datos mientras maximiza la distancia de cualquier clase desde el hiperplano *margin*. El hiperplano es definido por el

conjunto de niveles de:

$$f(x) = \sum_{i=1}^M y_i \alpha_i \cdot k(x, x_i) + b \quad (2.9)$$

donde $k(\cdot, \cdot)$ es la función núcleo (kernel function) y el signo de $f(x)$ determina la pertenencia de x . Construir un hiper plano óptimo es equivalente a encontrar todos los valores distintos de cero de α_i . Cualquier vector x_i que corresponda a los valores distintos de cero de α_i puede ser llamado como un *supported vector (SV)* (vector de soporte) del hiper plano óptimo (Moghaddam, Electric, and M.-h. Yang n.d.).

2.6 Rendimiento de combustible.

A continuación se describe los conceptos de rendimiento de combustible y rendimiento combinado.

- Rendimiento de combustible. Es la distancia recorrida por unidad de combustible, expresada en kilómetros por litro (km/l).

$$Rc = \frac{Df - Di}{Cu} \quad (2.10)$$

Donde Rc es el rendimiento de combustible, Df y Di es la diferencia entre el kilómetro final e inicial, es decir, la distancia recorrida. Cu es el combustible usado durante la distancia recorrida.

- Rendimiento de combustible combinado. Es el promedio ponderado de los rendimientos de ciudad y carretero, donde la ponderación es 55% el rendimiento de ciudad más el 45% del rendimiento en carretera. Lo cual se describe con la siguiente fórmula.

$$RC = 0.55Rc_{ciudad} + 0.45Rc_{carretera} \quad (2.11)$$

Donde RC es el rendimiento combinado, Rc_{ciudad} y $Rc_{carretera}$ son los rendimientos de combustible en ciudad y carretera (SENER 2018).

Es importante señalar que el mismo catálogo de rendimientos de combustible especifica que las pruebas realizadas son hechas en condiciones de laboratorio, y que si bien parecen factibles

estas fórmulas para registrar en algunos viajes el rendimiento de combustible deben tomarse solo como una referencia para saber cómo se obtienen los valores contenidos en catálogos oficiales. Por lo que si algún conductor quisiera medir su rendimiento de combustible es necesario utilizar otras técnicas para medirlo, ya sea mediante un sensor medidor de flujo o como en el caso del presente trabajo un escáner conectado mediante el sistema OBD2.

2.6.1 Sistema OBD2

OBD (On Board Diagnostics) es un sistema de diagnóstico a bordo en vehículos (coches y camiones). Actualmente se emplean los estándares OBD-II (Estados Unidos) que aportan un monitoreo y control completo del motor y otros dispositivos del vehículo. OBD II es la segunda generación del sistema de diagnóstico a bordo detecta fallos eléctricos, químicos y mecánicos que pueden afectar al nivel de emisiones del vehículo. Por ejemplo, con OBD I, el conductor no se daría cuenta de un fallo químico del catalizador. Con OBD II, los dos sensores de oxígeno, uno antes y el otro después del catalizador, garantizan el buen estado químico del mismo.

El sistema verifica el estado de todos los sensores involucrados en las emisiones, como por ejemplo la inyección o la entrada de aire al motor. Cuando algo falla, el sistema se encarga automáticamente de informar al conductor encendiendo una luz indicadora de fallo, también conocida como Check Engine o Service Engine Soon). Cada fallo tiene un código asignado. El mecánico puede leer los registros con un dispositivo que envía comandos al sistema OBD II llamados PID (Parameter ID). Actualmente se puede conectar con la máquina de diagnóstico de diferentes maneras, mediante Bluetooth, WiFi, USB, cayendo en desuso el protocolo de conexión por el puerto serie (RS232). Este enlace, unido a un software ejecutándose desde un ordenador o un terminal móvil permite la monitorización en tiempo real de códigos de error y diversos parámetros directamente de la central del motor tales como las revoluciones del motor, el consumo de combustible en tiempo real (sin que el automóvil lleve equipado ordenador de abordo) o la temperatura del aceite, entre muchos otros parámetros dependiendo del modelo (KitoSDev-CMS 2017).

Terminales del Conector OBDII



1 - Sin uso	9 - Sin uso
2 - J1850 Bus positivo	10 - J1850 Bus negativo
3 - Sin uso	11 - Sin uso
4 - Tierra del Vehículo	12 - Sin uso
5 - Tierra de la Señal	13 - Tierra de la señal
6 - CAN High	14 - CAN Low
7 - ISO 9141-2 - Línea K	15 - ISO 9141-2 - Línea L
8 - Sin uso	16 - Batería - positivo

Figura 2.7: Puertos de comunicación del conector OBD2.

2.6.2 Lectura de rendimiento de combustible (ELM327)

Para la lectura del rendimiento de combustible a través del protocolo de comunicación OBD2 se hace uso del controlador ELM327 que es el más extendido para establecer enlaces entre la central del motor y el dispositivo. La Interfaz del dispositivo ELM327 es una herramienta para el diagnóstico de vehículos equipados con sistemas OBD II – EOBD – CAN como el de la Figura 2.8 normalmente encontrados en vehículos americanos, europeos y asiáticos fabricados a partir de 1996 y que tengan el conector de diagnóstico de 16 pines como se muestra en la Figura 2.7. Además, esta interfaz permite la conexión a la computadora del vehículo para leer y borrar códigos de error (DTC), la famosa Luz “CHECK ENGINE” y mejor llamada MIL (Malfunction Indicator Lamp). Así mismo nos permite visualizar los valores de sensores y actuadores del motor en pleno funcionamiento (KitoSDev-CMS 2019).



Figura 2.8: Dispositivo de comunicación OBD2.

El dispositivo es originalmente un PIC 18F2480 (Peripheral Interface Controller) y es programada por ELM Electronics tal como el que se muestra en la Figura 2.9. Actúa como una

interfaz entre RS232 (conexión serial) y OBD2 para sistemas que utilizan varios protocolos de comunicación que cada fabricante de automóviles designa para sus modelos. Específicamente tiene un microcontrolador de 38 pines que soporta todos los protocolos de OBD. Este automáticamente identifica e interpreta el protocolo, también es un dispositivo construido con tecnología de bajo consumo energético CMOS (complementary metal-oxide-semiconductor) que permite conexiones de alta velocidad con la habilidad de ser programado haciendo uso de comandos AT (comandos Hayes con los que se comprueba la disponibilidad de un dispositivo) (Tahat et al. 2012).



Figura 2.9: PIC 18f2480 contenido en el dispositivo ELM327.

Capítulo 3

Implementación de clasificadores para la identificación de fallas por desgaste de electrodos en bujías.

En el presente capítulo se desarrolla el diseño experimental a partir de los recursos obtenidos en la literatura y se hace uso además de las herramientas metodológicas de algoritmos explicadas en el capítulo previo. En la figura 3.1 se muestra los pasos generales del presente proyecto. Donde la primer etapa corresponde a la obtención de las grabaciones de los vehículos. Más tarde se hace un procesamiento con dos distintas técnicas y adecuación de datos para después ser almacenados como una base de datos y posteriormente clasificarlos.

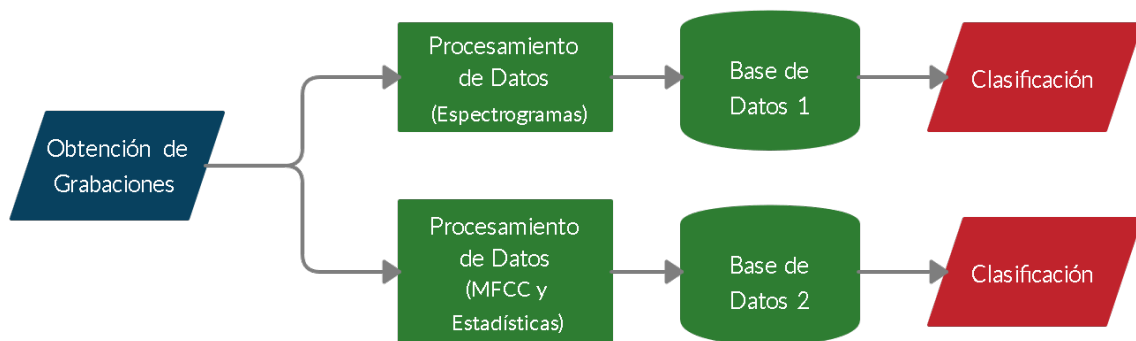


Figura 3.1: Metodología del proyecto.

3.1 Diseño experimental.

Para la detección de fallas en el sistema de bujías debido al gasto de electrodos en motores con cuatro cilindros se propone el diseño experimental siguiente. Haciendo uso de la tarjeta de sonido *Respeaker studio*, esta cuenta con un arreglo circular de 4 micrófonos, se propone situarla a una distancia de un 1 m, tomando en cuenta la suma de la distancia del motor a la estructura del automóvil y de la estructura a la tarjeta de micrófonos. La altura del motor y la tarjeta con respecto del suelo es también aproximadamente 1m. Se propone además tomar muestras de grabaciones con duración de 60 segundos a una frecuencia de muestreo de 48kHz. Posteriormente se grabarán señales del motor en condiciones de operación normales y dos más con fallas en las bujías de los cilindros 1 y 4 a velocidades desde 1000 rpm (ralentí) hasta 3000 rpm (1000, 1500, 2000, 2500 y 3000) rpm (J. D. Wu and Chuang 2005).

Las fallas se introducen alargando la distancia entre electrodos de las bujías lo cual evita que se produzca una chispa adecuada para la ignición de la bujía. Esto simula la condición de electrodos desgastados además de que el pistón relacionado a esa bujía opera anormalmente. Después se procede a introducir una segunda bujía con las mismas características de la primera, creando una condición de de dos pistones en operación anormal. Ambas fallas se provocan en pistones hermanos. Se prevé que las emisiones acústicas y vibraciones se incrementen al faltar pistones operando con normalidad esto debido al cambio de balance en el motor y las explosiones irregulares dentro de los cilindros de combustión. Una distancia mayor entre los electrodos de la bujía aumenta la pérdida en el núcleo de la flama al incendiar el combustible dentro de los cilindros (Shu-yi et al. 2016). Entonces se tiene como fin tener tres clases de clasificación a identificar, sin falla, 1 falla y 2 fallas.

Para el caso del diseño experimental concerniente al rendimiento de combustible se propone llevar a cabo un recorrido en una zona urbana haciendo uso del escáner ELM327 conectado a los vehículos Honda Civic (2006) y Seat Ibiza (2015) a través del puerto OBD2. Este dispositivo cuenta con interfaz bluetooth registrando así las mediciones de los parámetros de velocidad (km/h), consumo de combustible instantáneo(km/l), consumo de combustible por

viaje (l), consumo de combustible instantáneo de litros por cada 100km (l/100km) (Ganti et al. 2010).



Figura 3.2: Escáner ELM327 para el rendimiento de combustible.

Se establece como punto de referencia (salida) el campus Siglo XXI de la Universidad Autónoma de Zacatecas ubicada en el municipio de Zacatecas y como punto de retorno a una distancia de 14.7km la compañía Nissan (Torres Corzo) ubicada en Guadalupe. Por lo que una jornada de viaje completo se establece en aproximadamente 30 km (ida y regreso).

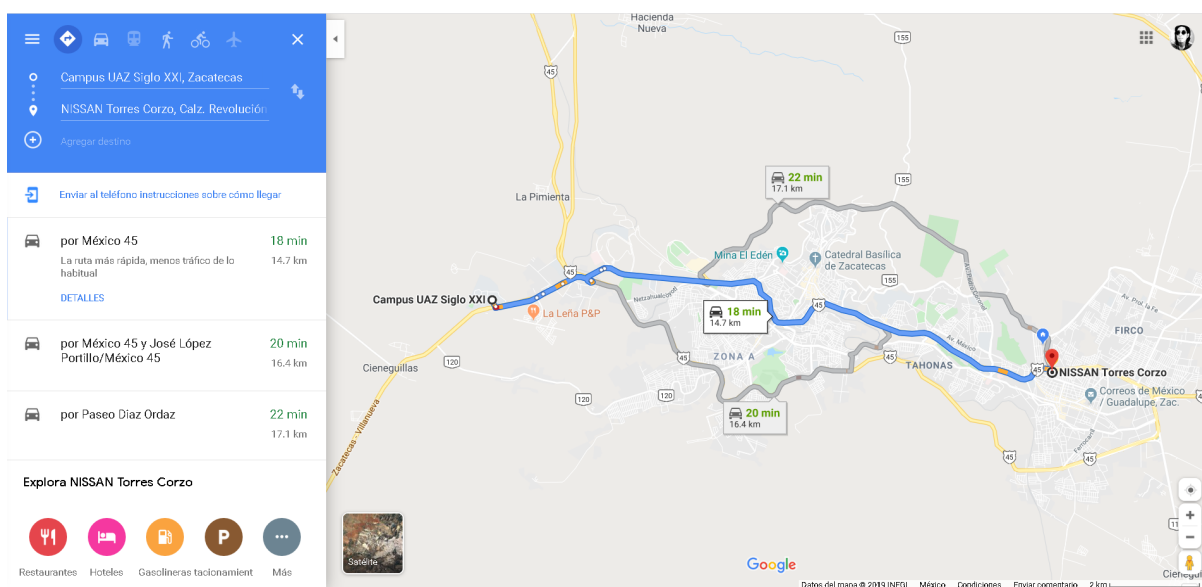


Figura 3.3: Recorrido realizado para la pruebas de rendimiento de combustible.

El experimento se lleva a cabo en tres jornadas de viajes para cada vehículo, las cuales serán:

1. Primer viaje sin ninguna bujía dañada.
2. Segundo viaje con 1 bujía dañada en el primer pistón.
3. Tercer viaje con 2 bujías dañadas en los pistones 1 y 4.

Además, se determinan las mismas condiciones para ambos vehículos en cada viaje. Estos son el mismo conductor, la misma carga de 3 pasajeros y una velocidad constante aproximadamente 75 a 80 km/h, excepto en curvas de retorno e incorporación donde se modula la velocidad hasta 20 a 30 km/h.

3.1.1 Materiales.

Físicamente se consideró importante que el diseño experimental contara con ciertos elementos para la adquisición de datos tales como:

- Trípodes fotográficos.
- Computadora Hp Envy (intel core i7, HDD 2TB, 16GB RAM, NVIDIA GTX950).
- Extensiones de conexiones eléctricas.
- Herramienta mecánica (Llave de carraca y dados).
- Bujías de prueba.

3.1.2 Automóviles.

Como se describe en la parte del diseño experimental se hizo uso de dos vehículos de prueba: Honda Civic 2006 y Seat Ibiza 2015.

- Honda Civic 2006. Este vehículo cuenta con un motor de 4 cilindros en línea a gasolina con desplazamiento de 1.8 L que produce una potencia de 140 caballos de fuerza a 6300

rpm y un par máximo de 173 Nm a 4300 rpm. Cuenta además con una transmisión automática de 5 velocidades (Auto-abc 2015).

- Seat Ibiza 2015. Este vehículo cuenta con un motor de 4 cilindros en línea a gasolina de 2.0 L que produce una potencia de 115 caballos de fuerza y un par máximo de 170 Nm a 2400 rpm. Cuenta además con una transmisión manual de 5 velocidades (Garcia and Pasion 2014).

3.1.3 Tarjeta de desarrollo Respeaker V2.0

La placa Respeaker V2.0 es un dispositivo desarrollado por la empresa “Seed Studio” que contiene un arreglo de 4 micrófonos de campo lejano capaz de detectar voces a una distancia de hasta 5 m incluso con la presencia de ruido de fondo. Su conectividad es mediante micro-usb que permite conectarse al software de edición *Audacity* y grabar simultáneas pistas (Studio 2018).




Figura 3.4: Tarjeta de desarrollo Respeaker V2.0.

En el **Apéndice A** se muestra los detalles técnicos de los micrófonos de condensador que contiene la tarjeta Respeaker.

3.2 Sistema de adquisición de señales acústicas.

Como se menciona en la sección de diseño experimental se toman muestras acústicas provenientes de los motores encendidos haciendo uso de la tarjeta de desarrollo Respeaker V2.0. Primero se enlaza la tarjeta con su software, se hace uso del programa de edición de audio “Audacity”. Las grabaciones tomadas tienen una duración de 60 segundos.



(a) Seat Ibiza 2015.



(b) Honda Civic 2006.

Figura 3.5: Toma de grabaciones de los vehículos de prueba.

La tarjeta de desarrollo Respeaker se montan sobre un trípode fotográfico que se mantienen a una distancia de 82 cm con respecto del motor del automóvil. Además de estar situada a una altura de 113 cm con respecto del suelo.

Cada automóvil comparte similitudes en cuanto a capacidad de cilindraje y motor refiere. Se realiza una grabación previa en condiciones de funcionamiento normal, es decir, todas las bujías trabajan en sus respectivos cilindros con normalidad en ralentí (1000 rpm). Se toman cuatro muestras más de 60 segundos a distintas revoluciones (1500, 2000, 2500 y 3000 rpm). Después se procede a apagar el vehículo e introducir una bujía con falla en cualquier pistón y se enciende el automóvil de nueva cuenta para grabar los sonidos de las señales acústicas a las mismas revoluciones antes mencionadas.



Figura 3.6: Cambio de primer bujía con una falla en cilindro 1.

Para la última prueba se introduce la segunda bujía desgastada en el cilindro hermano con la primera bujía introducida, tal como se muestra en la Figura 3.7. Estos cilindros hermanos, para el caso de los motores de cuatro cilindros son uno y cuatro (cilindros de los extremos), dos y tres (cilindros intermedios).




Figura 3.7: Cambio de la segunda bujía con falla en cilindro 4.

Se puede escoger cualquier par de cilindros mientras trabajen en sincronía cuando el motor esté encendido. En el caso de los experimentos realizados se escogieron los pistones 1 y 4. Este mismo procedimiento se lleva a cabo en ambos vehículos. El esquema de la Figura 3.8 sirve como referencia para todos los vehículos de 4 cilindros. En caso de que el vehículo fuera de más cilindraje (6 o más cilindros) tiene que revisarse el esquema correspondiente para el motor.

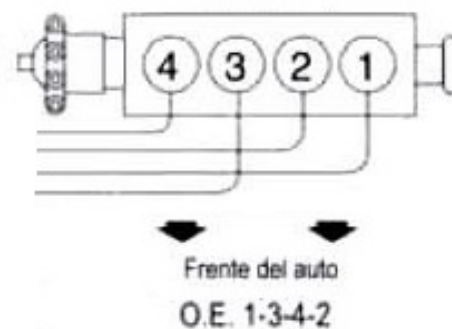


Figura 3.8: Orden de cilindros en motores con 4 de estos.

3.3 Procesamiento de señales acústicas.

Tras grabar las distintas revoluciones por minuto del motor. Las grabaciones se almacenan como archivos *.wav* a partir de los cuales se hace el procesamiento de las distintas señales. Cada micrófono muestra un canal de datos independiente. Teniendo en cuenta que la tarjeta tiene un número de 4 micrófonos y que se grabó a 5 distintas revoluciones, tenemos que hay un total de 60 grabaciones de audio, con información de las fallas de los experimentos. Después del almacenamiento se ordenan por carpetas los distintos archivos de audio teniendo la siguiente clasificación:

Micrófono	1	2	3	4
RPM	Ralentí (1000)	Ralentí (1000)	Ralentí (1000)	Ralentí (1000)
	1500	1500	1500	1500
	2000	2000	2000	2000
	2500	2500	2500	2500
	3000	3000	3000	3000

Tabla 3.1: Número de grabaciones por clase motor (Sin fallas).

Micrófono	1	2	3	4
RPM	Ralentí (1000)	Ralentí (1000)	Ralentí (1000)	Ralentí (1000)
	1500	1500	1500	1500
	2000	2000	2000	2000
	2500	2500	2500	2500
	3000	3000	3000	3000

Tabla 3.2: Número de grabaciones por clase motor (1 falla).

Micrófono	1	2	3	4
RPM	Ralentí (1000)	Ralentí (1000)	Ralentí (1000)	Ralentí (1000)
	1500	1500	1500	1500
	2000	2000	2000	2000
	2500	2500	2500	2500
	3000	3000	3000	3000

Tabla 3.3: Número de grabaciones por clase motor (2 fallas).

A través del software de edición “Audacity” de código libre se seleccionan las 60 pistas de audio almacenadas. Algunas de las grabaciones muestran algunas irregularidades como el viento chocando con la membrana de los micrófonos o inestabilidad al acelerar a y mantener las revoluciones más altas en el vehículo al momento de grabar.

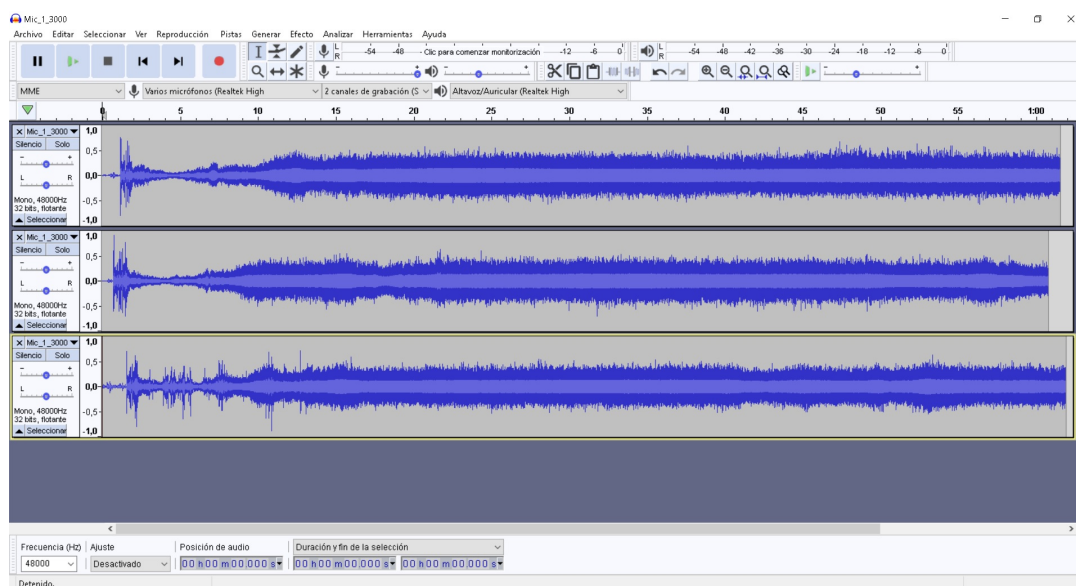


Figura 3.9: Software de edición de sonido “Audacity” y selección de segmentos de audio.

Después de hacer una búsqueda de intervalos de estabilidad y ausencia de viento o ruido en cada una de las 60 pistas se toman muestras en las que se reducen a 50 segundos de grabación y se vuelven a almacenar. Las pistas resultantes tienen un contenido neto de 50s a una frecuencia de muestreo de 48k Hz.

3.4 Extracción de características.

Como se muestra en la Figura 3.1 se hace uso de dos metodologías distintas para la extracción de características. En la primera se emplea la técnica de obtener medidas estadísticas de espectrogramas haciendo mano del software de programación MATLAB, mientras que en la segunda se emplea la técnica de obtener MFCC y medidas estadísticas de las señales grabadas haciendo uso del software de programación R.

3.4.1 MATLAB.

MATLAB es el acrónimo de *MATrix LABoratory* y es un lenguaje de alto desempeño diseñado para realizar cálculos técnicos. MATLAB añade a su interfaz de cálculo, visualización y programación un ambiente sencillo de comprender e interpretar para la solución de problemas, siempre de la mano de la notación matemática, es importante señalar que además es un sistema interactivo cuyo elemento básico de datos es el arreglo que no requiere de dimensionamiento previo, esto permite resolver muchos problemas computacionales de manera más simple en especial los que utilizan vectores y matrices, ahorrando mucho tiempo en procesamiento computacional y la escritura de programas (Esqueda 2002). MATLAB puede ser usado para resolver un gran abanico de problemas relacionados con matemática, desde la evaluación simple de una función hasta la resolución numérica de sistemas de ecuaciones diferenciales parciales, esto por poner algunos ejemplos.


3.4.2 R.

R es un lenguaje y entorno para computación estadística y gráficos, es un proyecto GNU (proyecto colaborativo de software libre). R proporciona una amplia variedad de técnicas estadísticas como lo son modelos lineales y no lineales, pruebas estadísticas clásicas, análisis de series de tiempo, clasificación, etc. Además de gráficas, una de las fortalezas de R es la facilidad con la que se pueden producir trazados bien diseñados con calidad de publicación, incluidos símbolos matemáticos y fórmulas cuando sea necesario (The R Foundation 2019).


3.4.3 Base de datos a partir de Espectrogramas.

Básicamente el espectrograma es una imagen de una señal acústica donde el eje vertical refiere a las frecuencias en Hertz contenidas, mientras que el eje horizontal representa el tiempo de la grabación en segundos. Existe una tercera característica de estas imágenes y esta es el color. Al igual que en una cámara infrarroja se utilizan los colores para acentuar ciertas intensidades percibidas por la lente en un espectrograma y un escalograma los colores varían dependiendo de la intensidad de la señal. En el caso del espectrograma los colores vienen indicados por cálculo del contenido frecuencial dada por la Transformada corta de Fourier de las muestras en cada segundo, tal como se mostró en la Figura 2.4.

En las Figuras 3.10 se muestra el análisis en frecuencias. La primera extracción se realiza en bajas frecuencias ya que la mayoría de los sonidos de los vehículos provienen de partes rotatorias, que rotan y se intercambian en baja frecuencia, principalmente a menos de 600 Hz. Por esto, los dos primeros miles de Hertz permiten ver con mayor certeza las posibles fallas en los vehículos de prueba (Aljaafreh and Dong 2010). Se importan dentro del software de programación MATLAB las 60 grabaciones. Después, se seleccionan de un mismo micrófono las grabaciones que contienen las etiquetas de ninguna falla, 1 falla y 2 fallas para cada una de las revoluciones por minuto y se guardan en dos variables. Tales variables son la frecuencia de muestreo y la señal de audio, ambas son introducidas en un función llamada *pspectrum* cuyas salidas son las tres dimensiones que conforman un espectrograma. Una matriz con la potencia del espectro (Transformada corta de Fourier), un vector de tiempo con los instantes



(a) Espectrograma de motor en Ralentí sin fallas- (b) Espectrograma de motor en Ralentí con 1 falla.



(c) Espectrograma de motor en Ralentí con 2 fallas.

Figura 3.10: Comparativa de Espectrogramas con y sin fallas.

de cada valor de la potencia del espectro y un vector con las frecuencias contenidas de la señal de audio. Posteriormente, se procede a tomar mediciones estadísticas tales como la media, la mediana, la desviación típica, la energía de la señal y la varianza de las matrices que contienen los datos de los espectrogramas, esto con el fin de utilizarlas como características para la clasificación de las señales acústicas que contienen las fallas. Estos datos son almacenados en variables con un formato de tabla y son ordenados por micrófono, revoluciones por minuto (rpm), frecuencia y numero de fallas. Más tarde estos datos son normalizados con el método Z-score (normalización Z) se selecciona este método porque hace una transformación de los datos con una distribución estándar de 1 y media 0. Es utilizada también en datos que generalmente no están definidos en la misma escala numérica. Una vez normalizados se obtienen 61440 observaciones con 7 características y 3 clases que son exportados en un formato de .csv.

En esta etapa se tienen dos bases de datos, una para el automóvil Honda Civic modelo 2006 y otra para el automóvil Seat Ibiza 2015.

3.4.4 Base de datos a partir de MFCC y características estadísticas.

En el caso de la base de datos construida a partir de los MFCC y características estadísticas se hace uso del software R en el cual se comienza por declarar una serie de librerías y paqueterías como son “tuneR”, “e1071”, “caTools”. Estas se encargan del uso adecuado de archivos de audios y de la extracción de estadísticas así como la segmentación de la Base de Datos. Más adelante se busca dentro de los directorios donde se encuentran almacenadas por carpetas las 60 grabaciones de 50 segundos de duración y se importan al programa para trabajar con estas.

Entonces se segmentan los 60 audios en 5 partes de 10 segundos cada uno, haciendo un total de 300 observaciones. Se obtiene de todas estas señales características estadísticas tales como sesgo, media, mediana, desviación estándar, varianza, curtosis y algunos percentiles (0.01, 0.05, 0.25, 0.5, 0.75, 0.95, 0.99). Estas se almacenan dando como resultado 18 características. Más tarde se toman todas las grabaciones segmentadas y se les aplica los MFCC obteniendo un vector de 120 características que se adjunta a las 18 antes obtenidas.

Análogamente al caso de los espectrogramas en este punto se normalizan bajo el método de Z-score todas las características extraídas teniendo entonces una base de datos de 300 observaciones con 138 características y 3 clases. Al igual que la base de datos obtenida en MATLAB esta nueva base de datos se guarda como un archivo con extensión *.csv*. Se obtienen así dos bases de datos.

3.5 Clasificación de señales de bujías por desgaste de electrodos.

En esta sección se aborda la manera en la que se implementan las bases de datos obtenidas. Se utilizó para la clasificación dos tipos de clasificadores no lineales que se abordaron previamente en el capítulo dos del presente trabajo estos son KNN y SVM. Se hace uso de un pequeño algoritmo para segmentar en subconjuntos las bases de datos con el fin de tener dos subconjuntos con 70% y 80% de los datos para el entrenamiento de los clasificadores, y otro

con el 30% y 20% restante respectivamente para las pruebas de validación de los modelos entrenados por los clasificadores tal como se muestra en la Tabla 3.4.

Honda Civic 2006 y Seat Ibiza 2015		
Características	Estructura 1	Estructura 2
Espectrograma	Entrenamiento 70%	Entrenamiento 80%
	Validación 30%	Validación 20%
MFCC y Estadísticas	Entrenamiento 70%	Entrenamiento 80%
	Validación 30%	Validación 20%

Tabla 3.4: Estructuras de bases de datos probadas en los clasificadores para entrenamiento y validación.

Una vez tratados los subconjuntos de las bases de datos para entrenamiento y validación se procede a importarlas en los clasificadores los cuales están embebidos en una aplicación llamada “Classification Learner” dentro de software MATLAB. Esta aplicación contiene múltiples clasificadores para poder entrenar distintos tipos de estructuras, entre los cuales destacan los clasificadores

- Decision trees.
- Support vector machines.
- Discriminant analysis.
- KNN classifiers.

Se hace selección de los “KNN classifiers” y los “Support Vector Machines” para entrenar los datos, el modo de importación a la aplicación es relativamente simple ya que solo requiere de señalar la ruta o el archivo cargado dentro de la interfaz de MATLAB como una variable.

La aplicación se encarga de contabilizar las observaciones y poner en variables las características de los subconjuntos, también separa las clases para la clasificación. Nuevamente se despliega una nueva interfaz que muestra los datos de los clasificadores seleccionados a entrenar. La Figura 3.11 muestra la interfaz completa correspondiente a la clasificación de la base de datos con espectrogramas. Una vez entrenados los clasificadores se exportan como modelos para la predicción o validación de los datos clasificados. Estos modelos se pueden almacenar como variables con extensión *.m* además permite utilizar más tarde los modelos

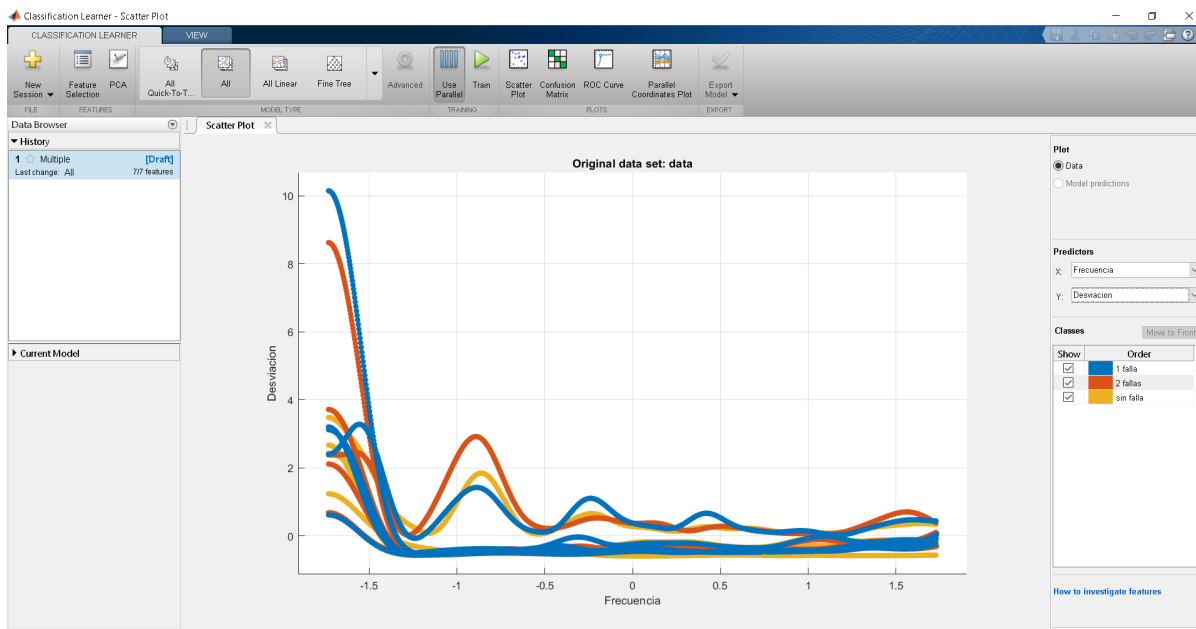


Figura 3.11: Interfaz de la aplicación “Classification Learner” en MATLAB.

aunque las variables sean borradas del programa. Basta con utilizar el comando *load* para importar de nueva cuenta el modelo entrenado. La aplicación contiene varios apartados en los cuales permite observar la matriz de confusión, la ROC (Receiver Operating Characteristic) y AUC (Area Under Curve) los cuales resumen el rendimiento o efectividad de los clasificadores además de dar cuenta acerca de hasta qué punto es capaz el clasificador entrenado de detectar correctamente las clases.

Una vez exportados y guardados los modelos entrenados por los clasificadores se importa dentro de otro algoritmo los subconjuntos de bases de datos para la validación, se emplea para validar la expresión $y_{fit} = \text{trainmodel.predictFcn}(\text{data})$; esta devuelve un vector de cadenas de caracteres con la clases que el modelo clasifica. Estas estructuras se comparan dentro del algoritmo igualándolo con el subconjunto de base de datos de validación original. Las muestras que sean iguales se toman como una clasificación correcta y se les asigna un 1 las que no lo son se les asigna un 0 dentro de otro vector, así se suma el total de muestras correctas y se calcula el porcentaje de éxito.

3.6 Análisis del rendimiento de combustible.

Tal como se describió en la parte del diseño experimental para el rendimiento de combustible se hace uso del dispositivo ELM327 conectado mediante OBD2 en tres jornadas de viajes probando primero los vehículos sin ninguna falla en un recorrido de 30 km. Se tomó en cuenta que el recorrido fuera continuo, sin tráfico y sin ninguna perturbación en el camino como pueden ser reductores de velocidad o “topes”. Además de la misma carga en cada vehículo y una velocidad constante exceptuando los retornos e incorporaciones.

El dispositivo tiene asociado una aplicación en Android llamada *Torque Pro*, esta permite registrar parámetros del consumo de combustible por conexión bluetooth con un smartphone. Permite detectar fallas por testigos y códigos de error que manda la ECU. Es así como los registros del combustible por recorrido se guardan en la memoria interna del smartphone. Se guardan 6 registros en total, 3 por viaje en cada vehículo, con un formato *.csv* los cuales se exportan al software MATLAB en donde se extraen las columnas de datos que corresponden a los consumos y rendimientos de combustible. Se procede a obtener un promedio de los casos de los rendimientos de combustible, mientras que para el consumo por trayectoria solo hace falta extraer el último de los valores registrados. Las características registradas con las que se calculan los promedios son: consumo instantáneo de combustible (km/l), consumo por trayectoria (l) y consumo por cada 100 km (l/100 km).

Capítulo 4

Resultados y Análisis.

En este capítulo se presentan el análisis y resultados obtenidos en la investigación mediante el entrenamiento y la validación de los clasificadores expuestos en el capítulo anterior. Dichos resultados fueron recabados mediante la exportación de los modelos entrenados.

En las Tablas 4.1 y 4.2 se muestran los resultados obtenidos del entrenamiento de los clasificadores así como la validación de cada una de las arquitecturas de subconjuntos para el vehículo Honda Civic 2006.

Espectrogramas (70/30)			Estadísticas y MFCC (70/30)		
Clasificadores	Eficiencia Entrenamiento	Eficiencia Validación	Clasificadores	Eficiencia Entrenamiento	Eficiencia Validación
K-NN (k=1)	100 %	43.83 %	K-NN (k=1)	95.2 %	100 %
SVM (cubic kernel)	100 %	53.88 %	SVM	95.2 %	95.6 %

Tabla 4.1: Resultados utilizando la arquitectura de subconjuntos de base de datos 70/30 para el vehículo Honda Civic 2006.

Espectrogramas (80/20)			Estadísticas y MFCC (80/20)		
Clasificadores	Eficiencia Entrenamiento	Eficiencia Validación	Clasificadores	Eficiencia Entrenamiento	Eficiencia Validación
K-NN (k=1)	100 %	53.25 %	K-NN (k=1)	93.8 %	100 %
SVM (cubic kernel)	100 %	53.21 %	SVM	92.5 %	100 %

Tabla 4.2: Resultados utilizando la arquitectura de subconjuntos de base de datos 80/20 para el vehículo Honda Civic 2006.

En las Tablas 4.3 y 4.4 se muestran los resultados obtenidos del entrenamiento de los clasificadores así como la validación de cada una de las arquitecturas de subconjuntos para el vehículo Seat Ibiza 2015.

Espectrogramas (70/30)			Estadísticas y MFCC (70/30)		
Clasificadores	Eficiencia Entrenamiento	Eficiencia Validación	Clasificadores	Eficiencia Entrenamiento	Eficiencia Validación
K-NN (k=1)	100 %	48.40 %	K-NN (k=1)	95.7 %	100 %
SVM (cubic kernel)	99.8 %	53.72 %	SVM	95.2 %	100 %

Tabla 4.3: Resultados utilizando la arquitectura de subconjuntos de base de datos 70/30 para el vehículo Seat Ibiza 2015.

Espectrogramas (80/20)			Estadísticas y MFCC (80/20)		
Clasificadores	Eficiencia Entrenamiento	Eficiencia Validación	Clasificadores	Eficiencia Entrenamiento	Eficiencia Validación
K-NN (k=1)	100 %	48.21 %	K-NN (k=1)	97.5 %	100 %
SVM (cubic kernel)	100 %	42.14 %	SVM	97.5 %	96.7 %

Tabla 4.4: Resultados utilizando la arquitectura de subconjuntos de base de datos 80/20 para el vehículo Seat Ibiza 2015.

En la parte concerniente al consumo y rendimiento de combustible se calculó además del consumo instantáneo de combustible (km/l), consumo por trayectoria (l) y consumo por cada 100 km (l/100 km), se hace el cálculo del incremento del consumo de combustible en cada trayectoria.

Vehículo	Modelo	Cilindros	Cons. por trayectoria (Sin fallas)	Cons.por trayectoria (1 falla)	Cons. por trayectoria (2 fallas)
Honda Civic	2006	4	1.55 l	1.57 l	1.58 l
Seat Ibiza	2015	4	1.48 l	1.61 l	1.61 l

Tabla 4.5: Consumos de combustible por trayectoria en cada vehículo.

Vehículo	Modelo	Cilindros	Cons. instantáneo (Sin fallas)	Cons. instantáneo (1 falla)	Cons. instantáneo (2 fallas)
Honda Civic	2006	4	30.017 km/l	29.745 km/l	29.522 km/l
Seat Ibiza	2015	4	35.566 km/l	31.116 km/l	30.123 km/l

Tabla 4.6: Consumos promedio de combustible instantáneo en cada vehículo.

Vehículo	Modelo	Cilindros	Cons. por cada 100 km (Sin fallas)	Cons. por cada 100 km (1 falla)	Cons. por cada 100 km (2 fallas)
Honda Civic	2006	4	8.123 l/100 km	8.231 l/100 km	8.862 l/100 km
Seat Ibiza	2015	4	6.286 l/100 km	6.348 l/100 km	6.801 l/100 km

Tabla 4.7: Consumos promedio de combustible por cada 100 km en cada vehículo.

Vehículos	Incremento de combustible con 1 falla	Incremento de combustible con 2 fallas
Seat Ibiza	1.29 %	1.94 %
Honda Civic	8.78 %	8.78 %

Tabla 4.8: Porcentajes de incrementos de combustible con cada una de las fallas en cada automóvil.

Se puede observar que en el caso de las características extraídas con espectrogramas existe un sobre ajuste. En términos de machine learning la diferencia de ajuste entre los subconjuntos de bases de datos es llamada *variance* un clasificador puede tener un bajo valor de *bias* (error al adaptarse en el entrenamiento a los datos), ya que es flexible y adaptable a cierto tipo de datos en el entrenamiento pero tiene un valor alto de *variability* lo cual resulta en un bajo ajuste en la validación. Un caso ideal sería en el que tiene un bajo valor de *bias* y de *variability*.

Sucede lo contrario en los subconjuntos de de bases de datos con características estadísticas y MFCC donde el entrenamiento es un valor relativamente alto y la validación en los dos clasificadores se adapta hasta en un 100%. Estamos hablando de que en los casos menores al 100% pero superiores al 95% son clasificaciones en las que el modelo no acertó en uno o dos casos. En el **Apéndice B** del presente trabajo se encuentran las imágenes que contienen la matriz de confusión, la ROC (Receiver Operating Characteristic) y AUC (Area Under Curve) de cada una de las tablas anteriores.

La diferencia entre ambos subconjuntos de datos se debe principalmente a que las características extraídas de los espectrogramas presentan es que el modelo entrenado se ajusta específicamente a los valores obtenidos. Por tanto, nuestro algoritmo estará considerando como válidos sólo los datos idénticos a los de nuestro conjunto de entrenamiento, incluidos sus defectos, y siendo incapaz de distinguir entradas buenas como fiables si se salen un poco de los rangos ya pre-establecidos.

En términos de consumo en cada trayectoria se puede observar que se consume más cantidad de combustible cuando una o las dos fallas en las bujías se encuentran presentes en el motor. En la Tabla 4.8 se muestran los porcentajes de incremento para cada falla. Como se muestra en las Tablas 4.6 y 4.7 en caso de tener las fallas por desgaste en las bujías se puede recorrer una cantidad menor de kilómetros por cantidad de combustible en litros. Mientras que, en el caso de cantidad de combustible por cada 100 km tenemos que al tener fallas presentes se necesita de más litros de combustible para recorrer esa distancia.

Capítulo 5

Conclusiones y trabajo futuro.

Para concluir con el trabajo de tesis, en el presente capítulo se mostrarán las conclusiones obtenidas así como el trabajo futuro considerado a partir de las dificultades presentadas a lo largo del trabajo. Lo anterior con el fin de que este proyecto pueda eventualmente tener continuidad, así como exponer los beneficios obtenidos y los objetivos alcanzados.

5.1 Conclusiones.

El objetivo de esta tesis fue clasificar mediante el uso de un arreglo de micrófonos los desperfectos producidos por bujías en mal estado y establecer en qué medida existe un mayor gasto de combustible. Este objetivo se alcanzó en primera instancia para tener una técnica que ayudara en el diagnóstico de motores con falla en las bujías, además este diagnóstico sería no invasivo ya que solo se requiere grabar por aproximadamente un minuto el motor para que los modelos sean capaces de definir si ese automóvil presenta específicamente fallas en bujías.

De acuerdo con los resultados obtenidos y registrados en el presente trabajo es posible clasificar con la adecuada extracción de características provenientes de los sonidos de motores bujías con falla. La mejor estructura de subconjunto de base de datos se concluye que es la 70/30, 70% entrenamiento y 30% validación. La clasificación utilizando las características de los espectrogramas produjeron una eficiencia del 100% en el entrenamiento y un 53% en la validación del modelo en el mejor de los casos. Cuando se utilizaron las características estadísticas y MFCC la eficiencia en el entrenamiento bajó al 95% y subió hasta el 100% en la validación. De acuerdo a los registros obtenidos del consumo de combustible se tiene que con

la presencia de una bujía con electrodos desgastados el consumo incrementa un 2%, mientras que con la presencia de dos bujías con electrodos desgastados el consumo incrementa hasta un 8%. El uso de MFCC y características estadísticas incrementa la eficiencia de la clasificación de las señales acústicas.

5.1.1 Trabajo futuro y recomendaciones.

Como trabajo futuro se propone la condensación y el complemento del presente trabajo en el sentido de establecer más modelos capaces de clasificar más señales acústicas que contengan distintas fallas, esto con el fin de desarrollar un dispositivo de bajo costo que sea capaz de con solo unos instantes de grabación determinar múltiples fallas, así como sugerir mediante una interfaz simple tratamientos correctivos y preventivos al usuario del vehículo en diagnóstico. Se proyecta el trabajo como una oportunidad de emplear las técnicas desarrolladas y trabajadas en otras áreas fuera y dentro del ámbito de la ingeniería. También es conveniente recomendar una etapa previa a la clasificación en la que se haga una selección de coeficientes mediante algoritmos genéticos para clasificar solo aquellos que sean de mayor relevancia para y peso para la clasificación.


Apéndice A: Hoja de datos de micrófonos.



MP34DT01-M

MEMS audio sensor omnidirectional digital microphone

Datasheet - production data



- VoIP
- Speech recognition
- A/V eLearning devices
- Gaming and virtual reality input devices
- Digital still and video cameras
- Antitheft systems

Description

The MP34DT01-M is an ultra-compact, low-power, omnidirectional, digital MEMS microphone built with a capacitive sensing element and an IC interface.

The sensing element, capable of detecting acoustic waves, is manufactured using a specialized silicon micromachining process dedicated to produce audio sensors.

The IC interface is manufactured using a CMOS process that allows designing a dedicated circuit able to provide a digital signal externally in PDM format.

The MP34DT01-M has an acoustic overload point of 120 dB SPL with a 61 dB signal-to-noise ratio and -26 dBFS sensitivity.

The MP34DT01-M is available in a top-port, SMD-compliant, EMI-shielded package and is guaranteed to operate over an extended temperature range from -40 °C to +85 °C.

Features

- Single supply voltage
- Low power consumption
- 120 dB SPL acoustic overload point
- 61 dB signal-to-noise ratio
- Omnidirectional sensitivity
- -26 dBFS sensitivity
- PDM output
- HCLGA package
 - Top-port design
 - SMD-compliant
 - EMI-shielded
 - ECOPACK[®], RoHS, and "Green" compliant

Applications

- Mobile terminals
- Laptop and notebook computers
- Portable media players

Table 1. Device summary

Order codes	Temperature range [°C]	Package	Packing
MP34DT01-M	-40 to +85	HCLGA (3 x 4 x 1.06) mm 4LD	Tray
MP34DT01TR-M			Tape and reel

2 Acoustic and electrical specifications

2.1 Acoustic and electrical characteristics

The values listed in the table below are specified for Vdd = 1.8 V, Clock = 2.4 MHz, T = 25 °C, unless otherwise noted.

Table 3. Acoustic and electrical characteristics

Symbol	Parameter	Test condition	Min.	Typ. ⁽¹⁾	Max.	Unit
Vdd	Supply voltage		1.64	1.8	3.6	V
Idd	Current consumption in normal mode	Mean value		0.6		mA
IddPdn	Current consumption in power-down mode ⁽²⁾			20		μA
Sc	Short-circuit current		1		10	mA
AOP	Acoustic overload point			120		dB SPL
So	Sensitivity		-29	-26	-23	dBFS
SNR	Signal-to-noise ratio	A-weighted at 1 kHz, 1 Pa		61		dB
PSR	Power supply rejection	Guaranteed by design		-70		dBFS
Clock	Input clock frequency ⁽³⁾		1	2.4	3.25	MHz
Ton	Turn-on time ⁽⁴⁾	Guaranteed by design			10	ms
Top	Operating temperature range		-40		+85	°C
V _{IOL}	Low level logic input/output voltage	I _{out} = 1 mA	-0.3		0.35xVdd	V
V _{IOH}	High level logic input/output voltage	I _{out} = 1 mA	0.65xVdd		Vdd+0.3	V


1. Typical specifications are not guaranteed.
2. Input clock in static mode.
3. Duty cycle: min = 40% max = 60%.
4. Time from the first clock edge to valid output data.

Table 4. Distortion specifications

Parameter	Test condition	Value
Distortion	100 dB SPL (1 kHz)	< 1% THD+N
Distortion	115 dB SPL (1 kHz)	< 2% THD+N
Distortion	120 dB SPL (1 kHz)	< 10% THD+N

2.2 Frequency response

Figure 2. Typical frequency response normalized at 1 kHz



Apéndice B: Imágenes de la ROC, AUC y Matriz de confusión.

A continuación las imágenes almacenadas de la aplicación "Classification Learner" en donde se muestra los parámetros de eficiencia del entrenamiento de los datos de los clasificadores K-NN y SVM.

- ROC y AUC.
- Matriz de confusión.
 - Falsos positivos y falsos negativos.
 - Número de observación.
 - Predictores positivos y falsos descubrimientos.

B.1 Vehículo Seat Ibiza estructura 70/30.

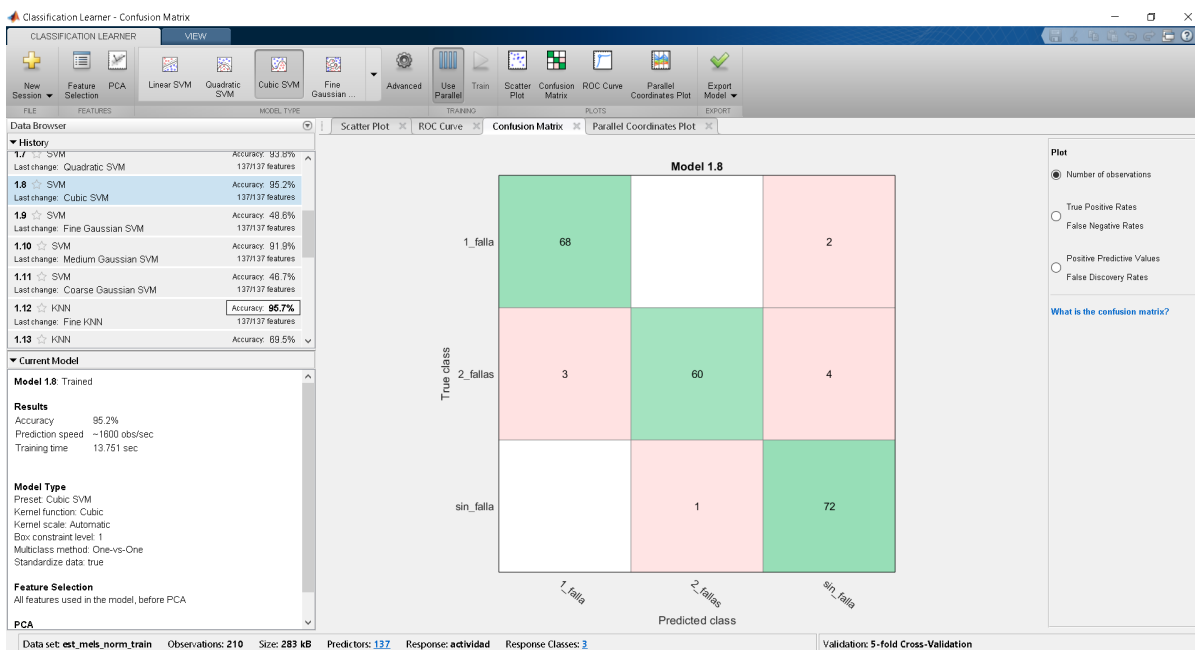


Figura B.1: Matriz de confusión, numero de observaciones del clasificador SVM.

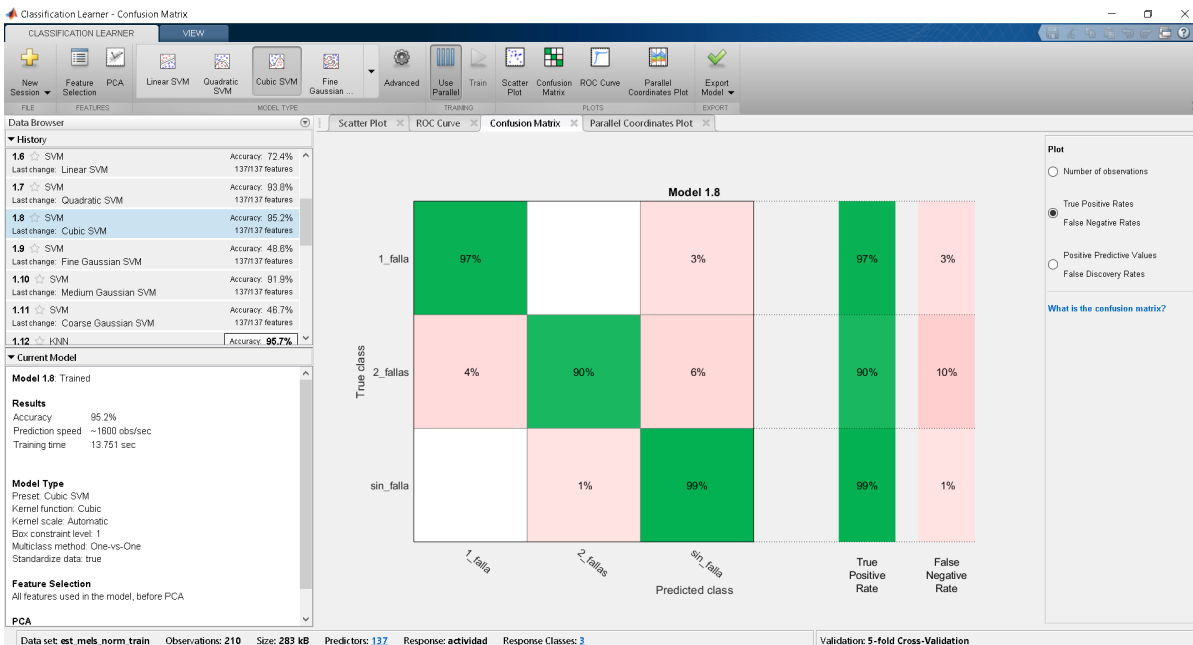


Figura B.2: Matriz de confusión, falsos positivos y falsos negativos del clasificador SVM.

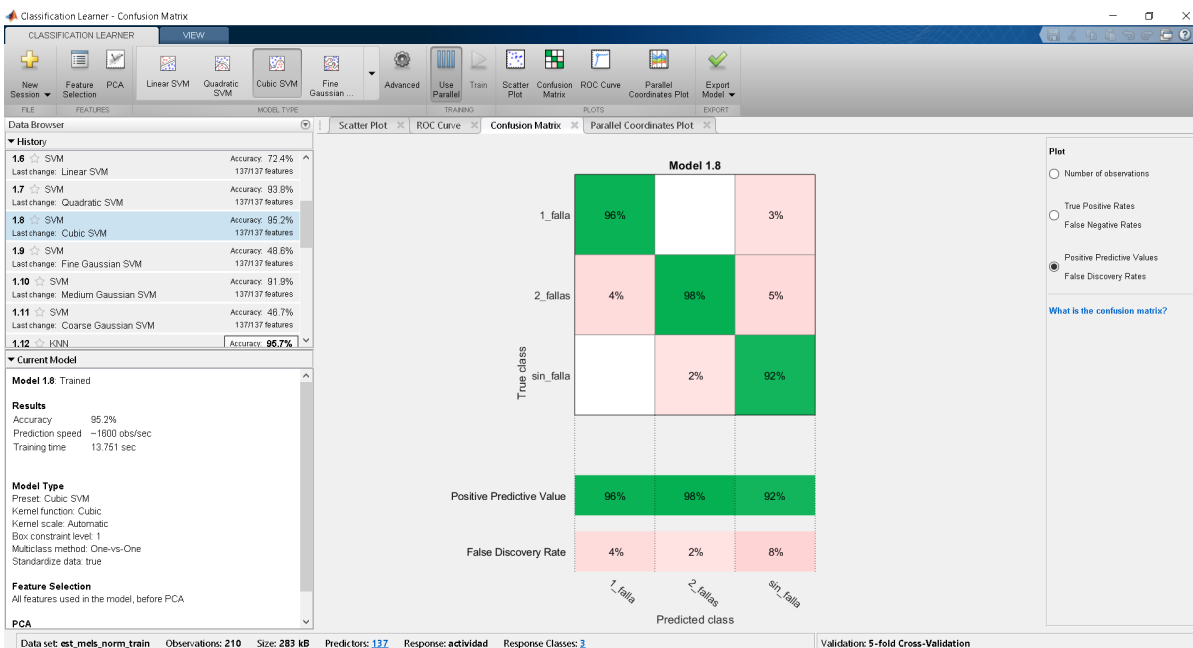


Figura B.3: Matriz de confusión, predictores positivos y falsos descubrimientos del clasificador SVM.

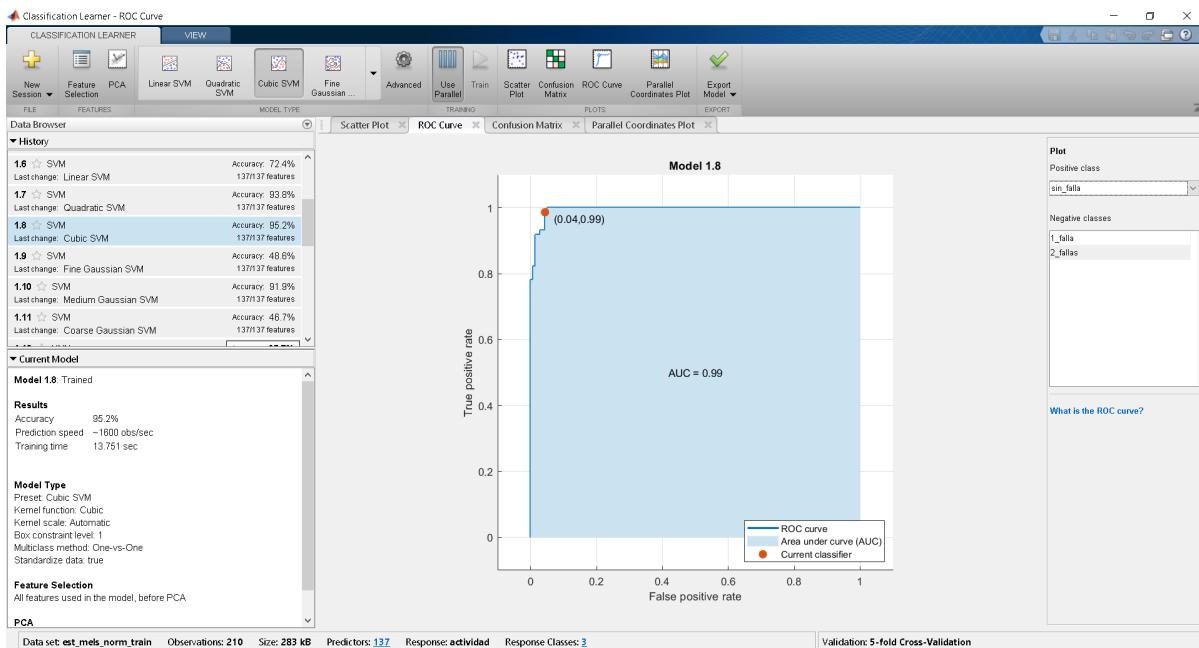


Figura B.4: ROC y AUC, sin fallas del clasificador SVM.

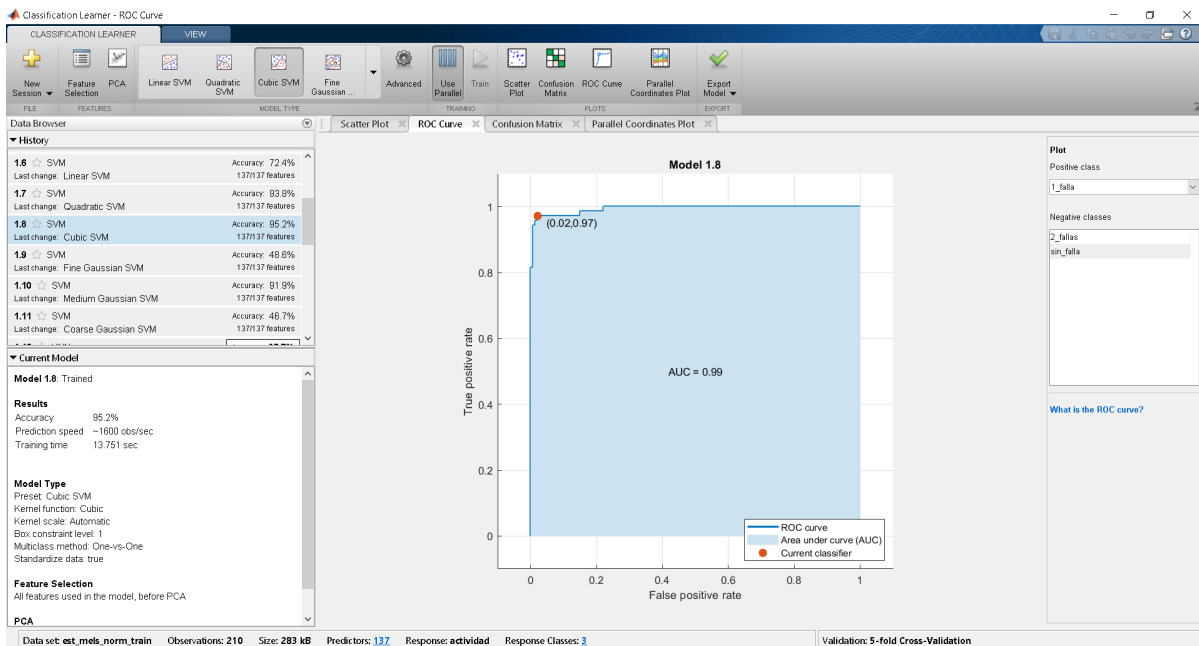


Figura B.5: ROC y AUC, 1 falla del clasificador SVM.

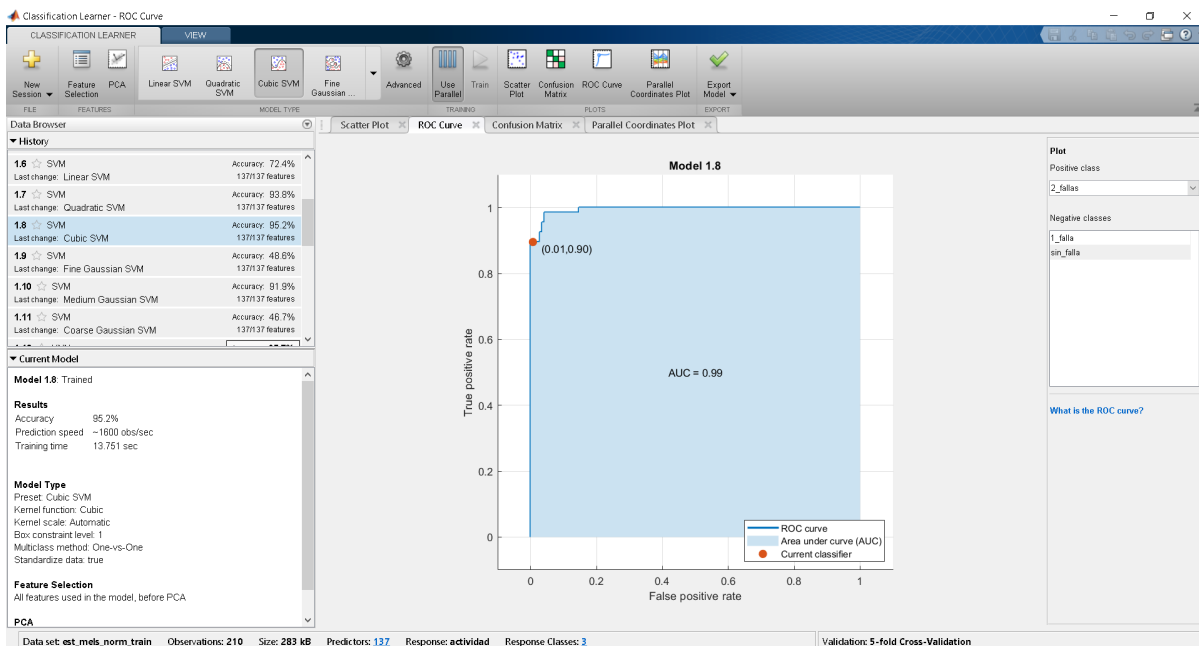


Figura B.6: ROC y AUC, 2 fallas del clasificador SVM.

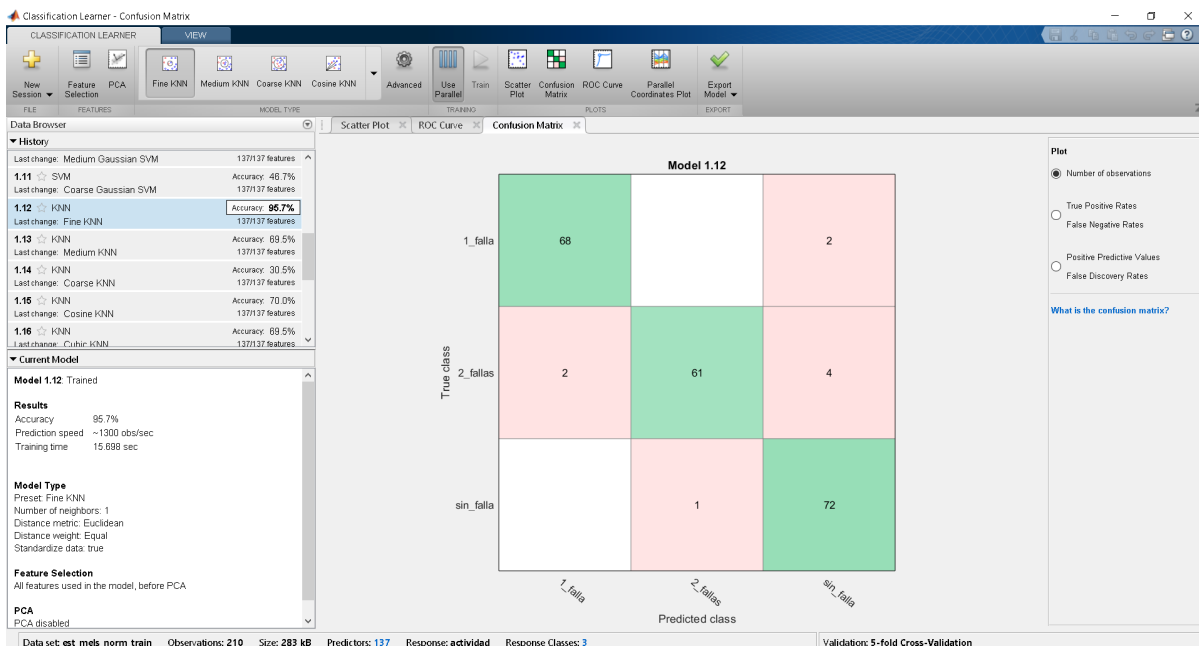


Figura B.7: Matriz de confusión, numero de observaciones del clasificador KNN.

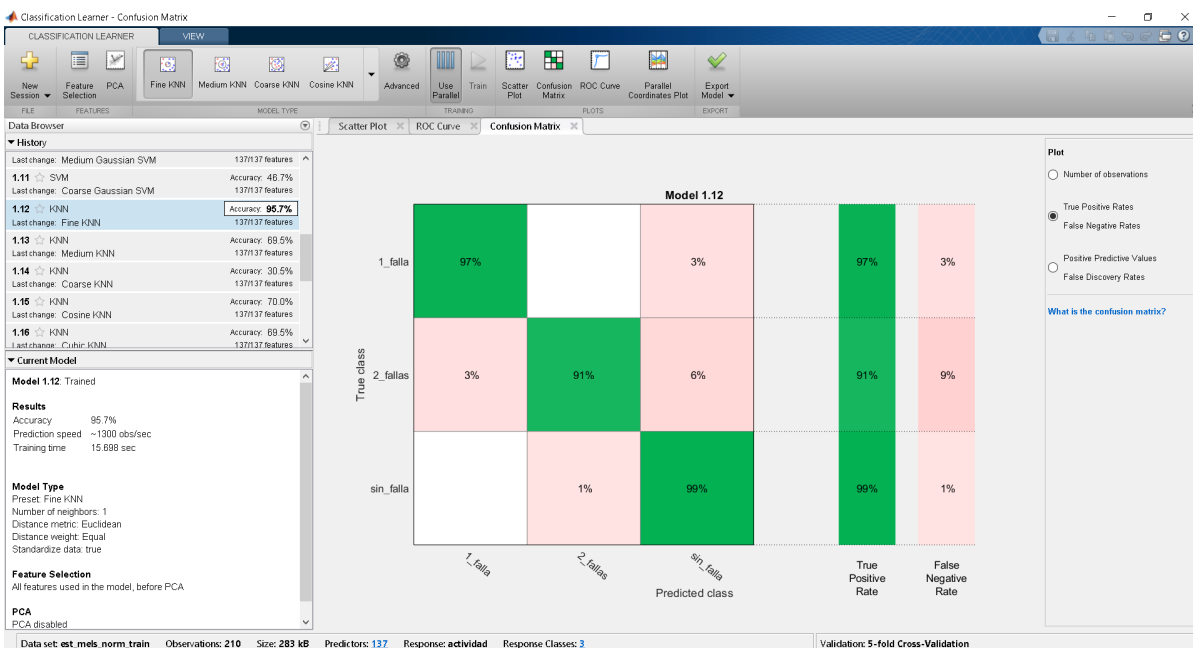


Figura B.8: Matriz de confusión, falsos positivos y falsos negativos del clasificador KNN.

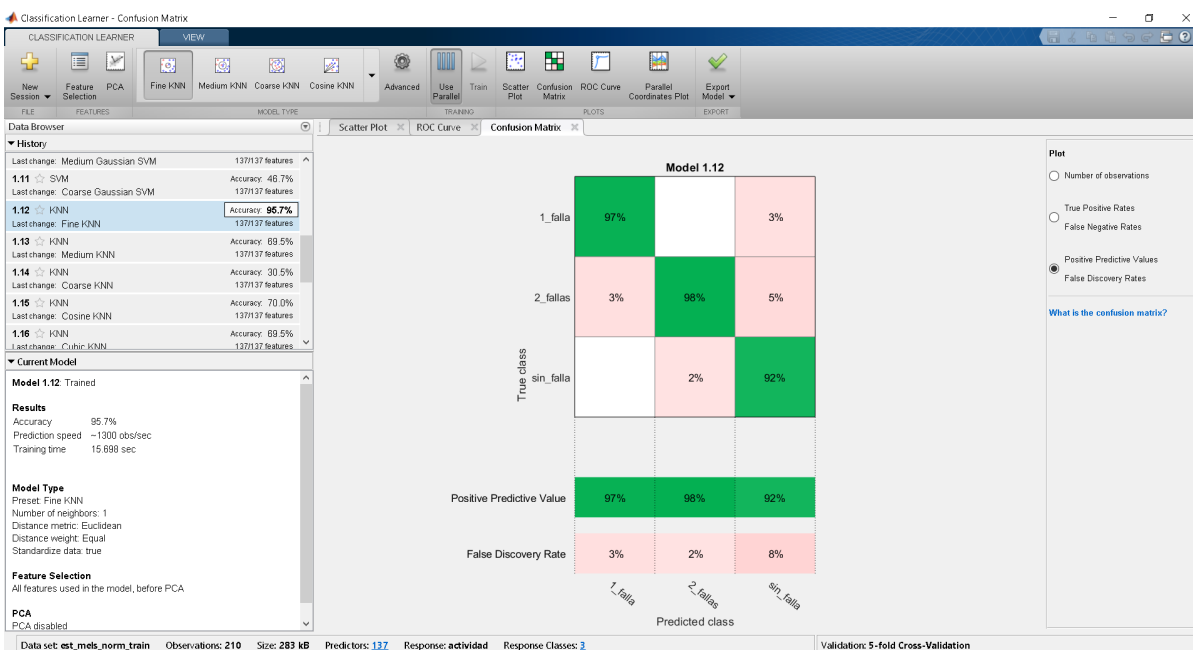


Figura B.9: Matriz de confusión, predictores positivos y falsos descubrimientos del clasificador KNN.

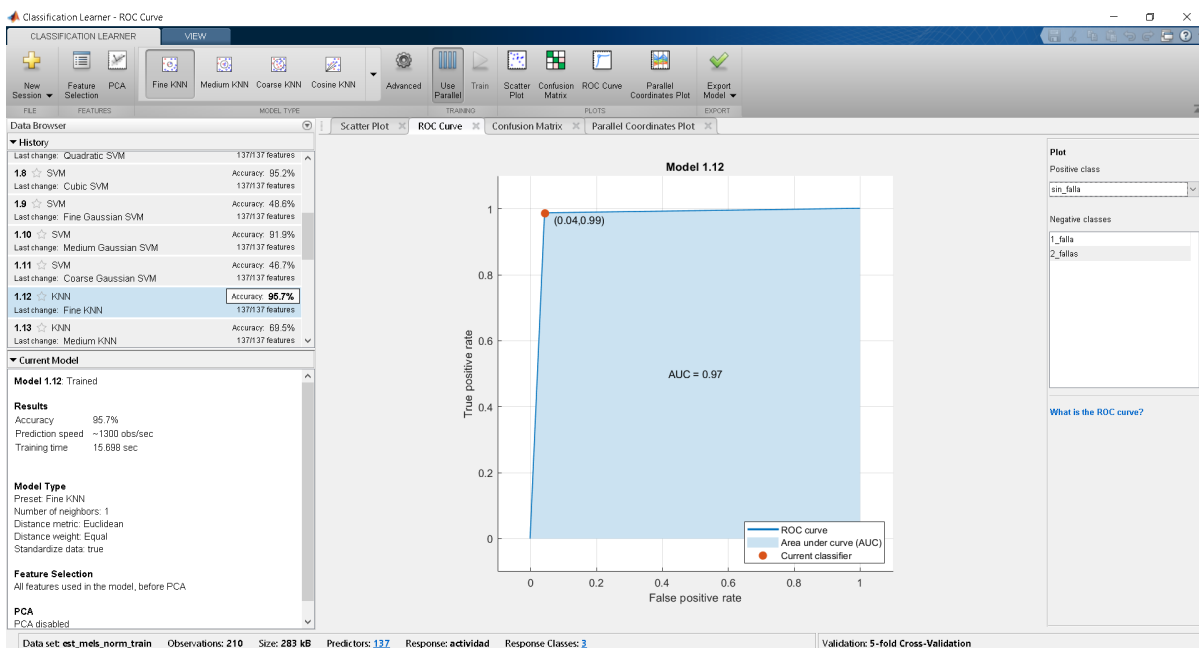


Figura B.10: ROC y AUC, sin fallas del clasificador KNN.

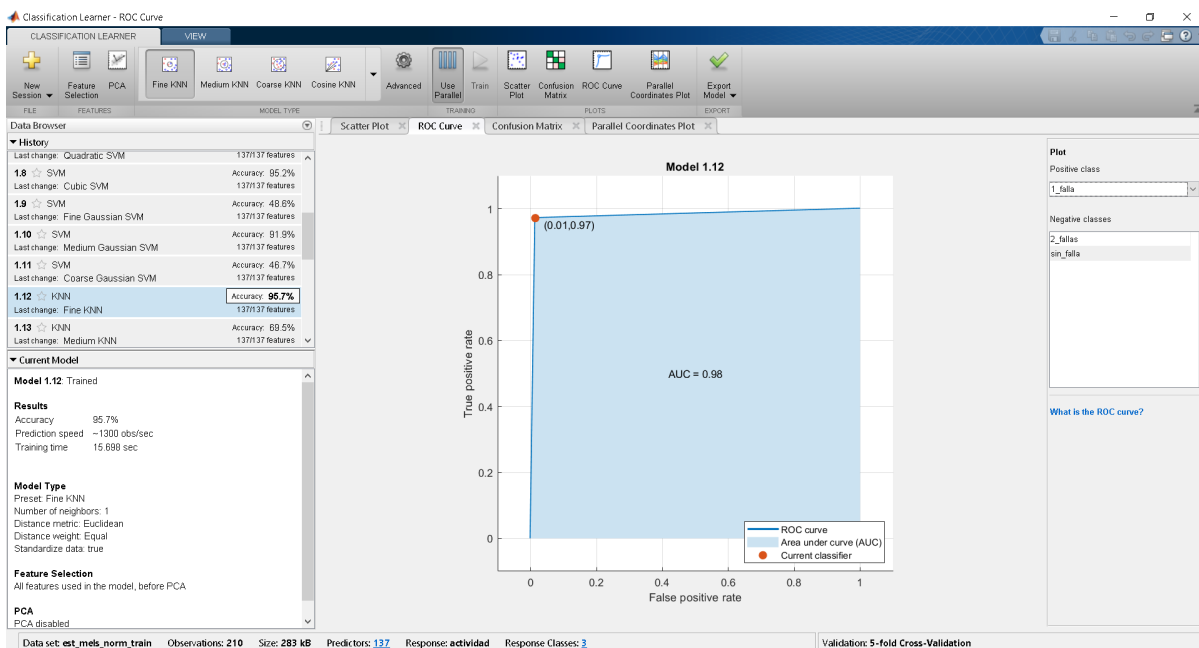


Figura B.11: ROC y AUC, 1 falla del clasificador KNN.

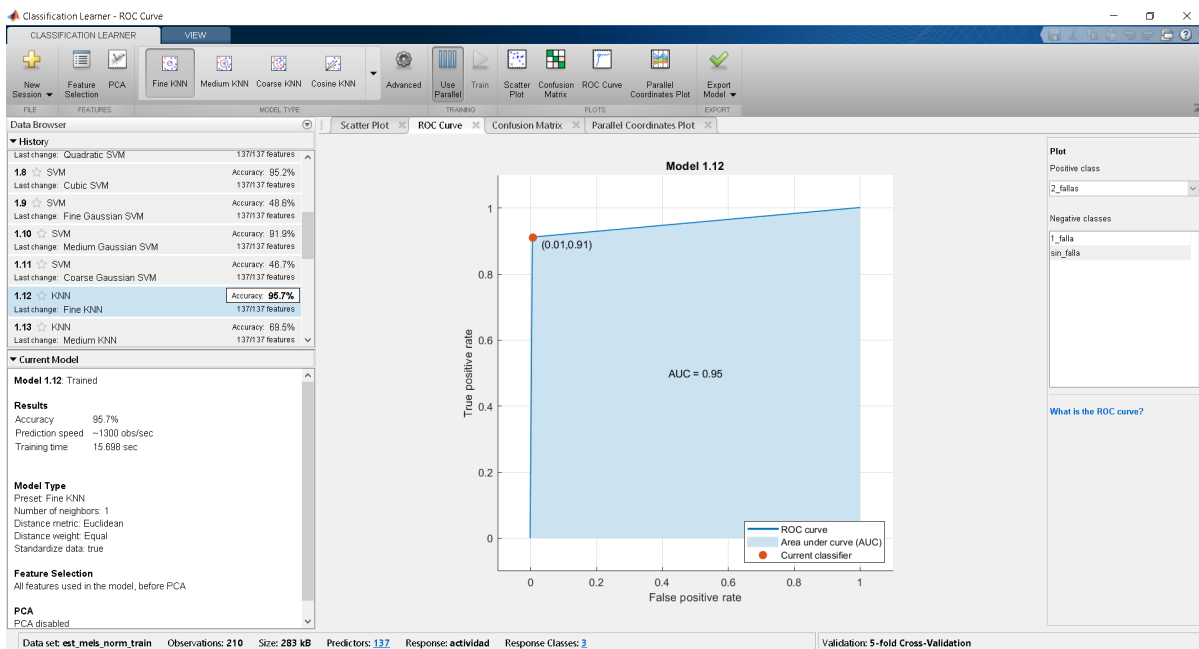


Figura B.12: ROC y AUC, 2 fallas del clasificador KNN.

B.2 Vehículo Honda Civic estructura 70/30.

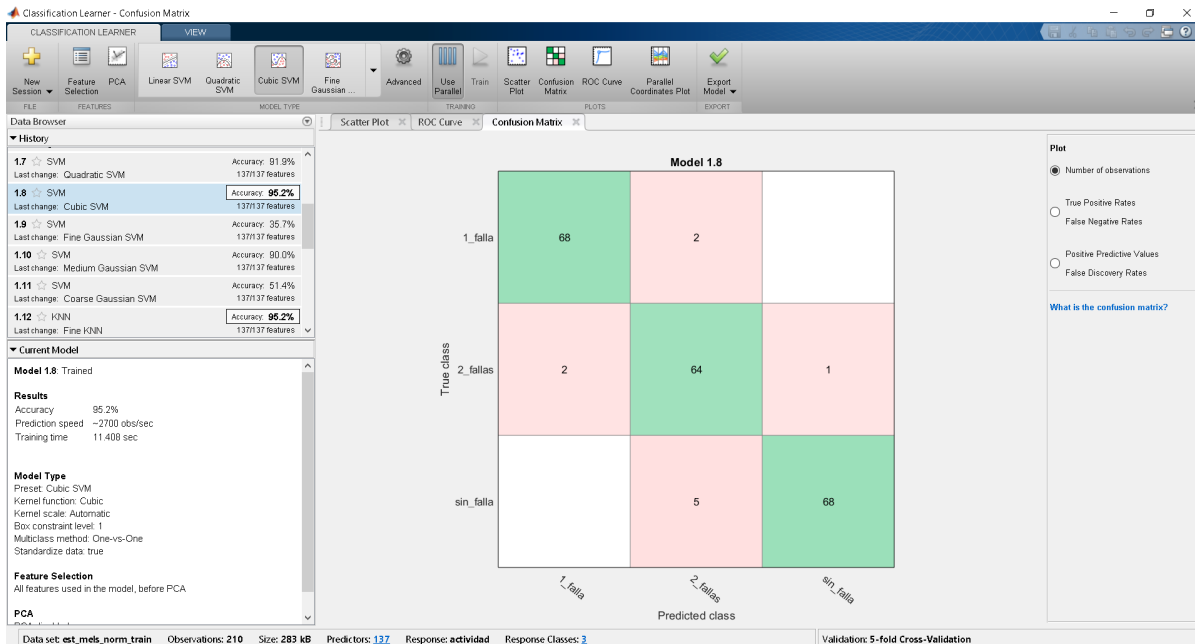


Figura B.13: Matriz de confusión, número de observaciones del clasificador SVM.

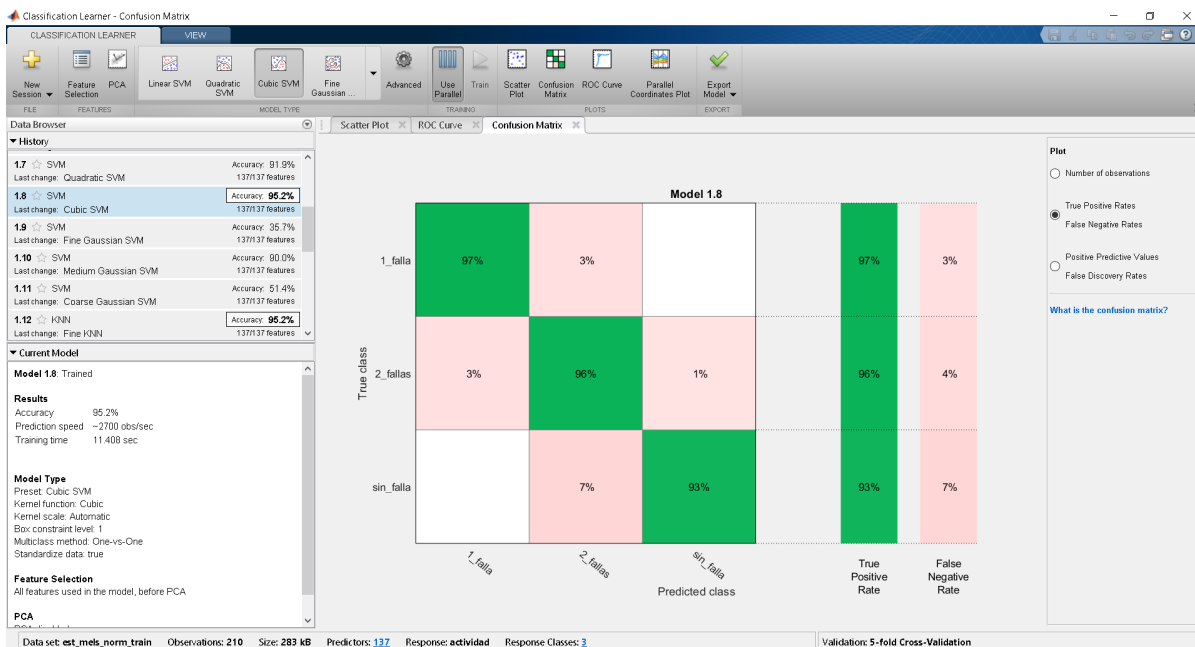


Figura B.14: Matriz de confusión, falsos positivos y falsos negativos del clasificador SVM.

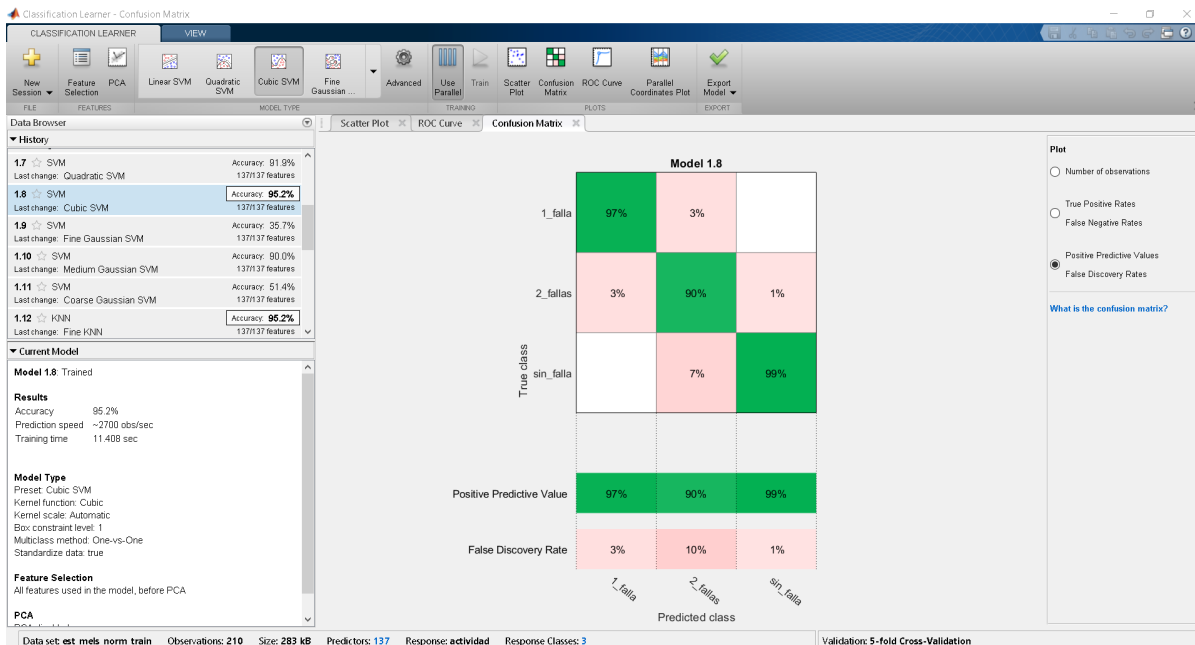


Figura B.15: Matriz de confusión, predictores positivos y falsos descubrimientos del clasificador SVM.

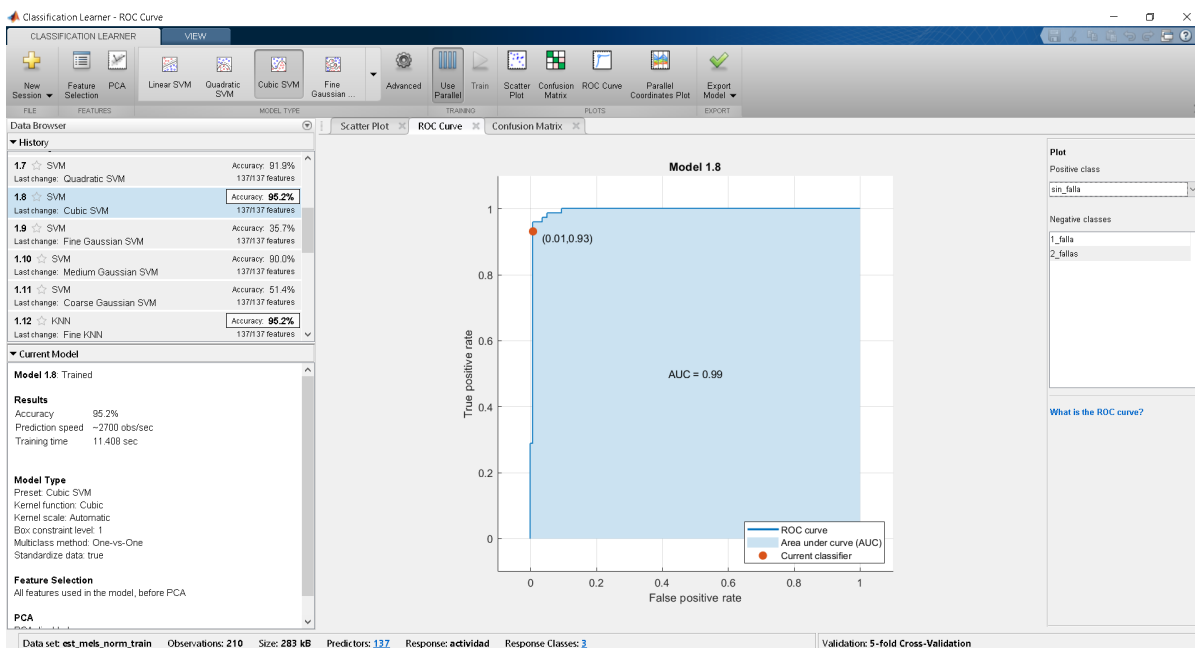


Figura B.16: ROC y AUC, sin fallas del clasificador SVM.

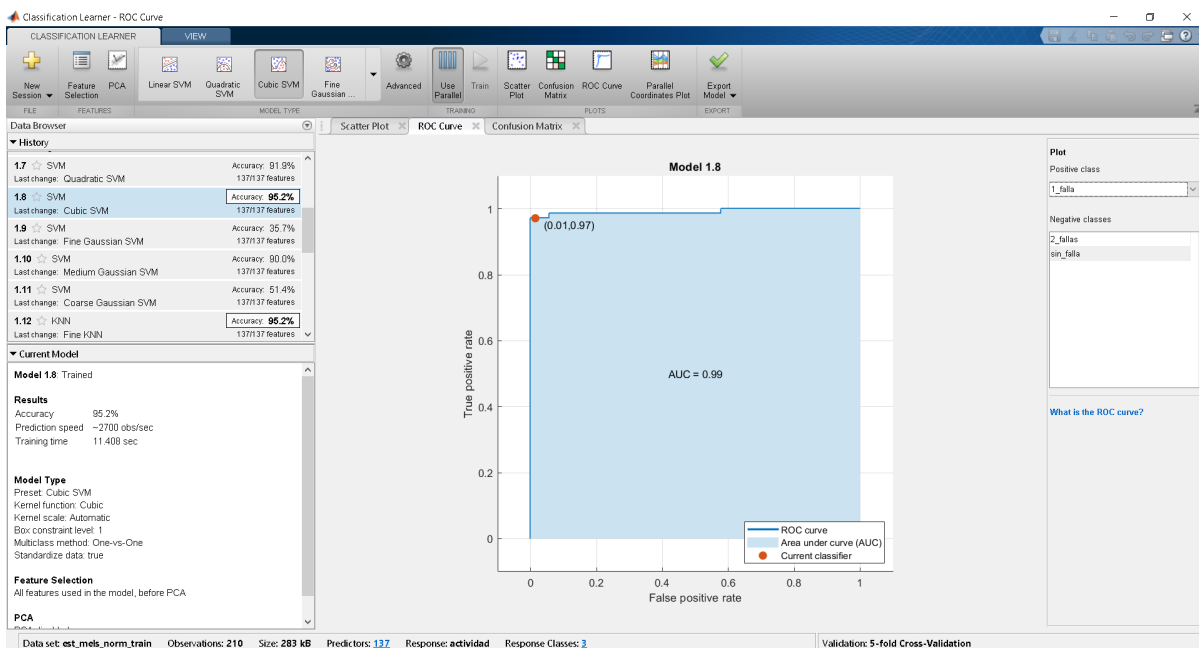


Figura B.17: ROC y AUC, 1 falla del clasificador SVM.

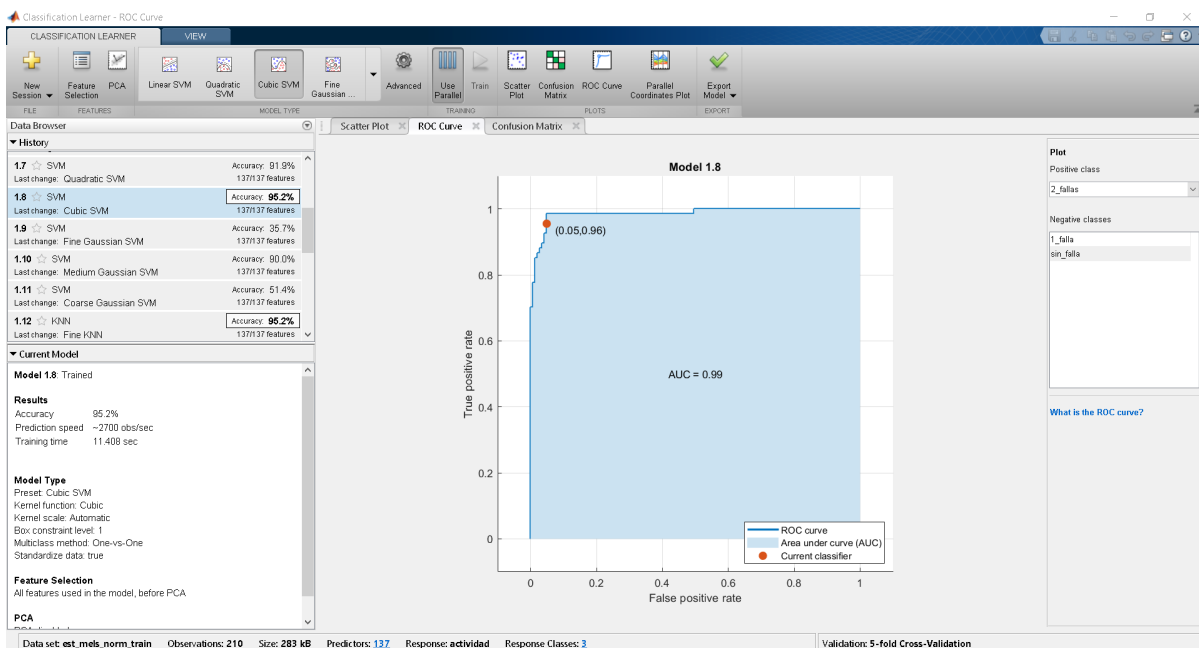


Figura B.18: ROC y AUC, 2 fallas del clasificador SVM.

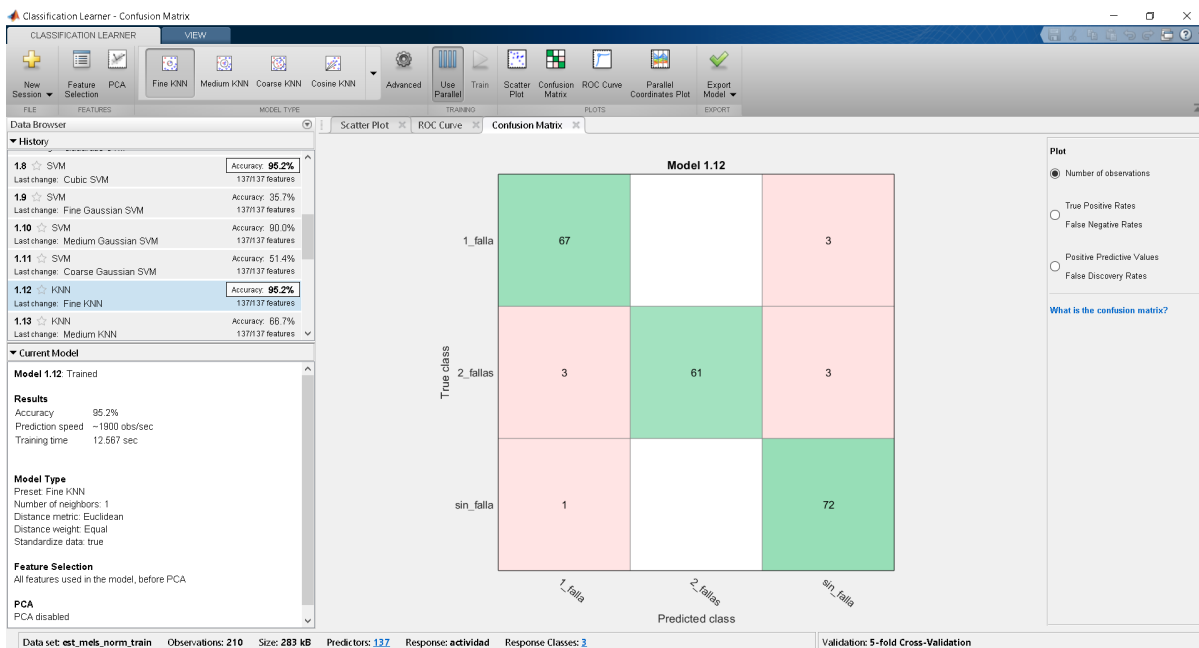


Figura B.19: Matriz de confusión, número de observaciones del clasificador KNN.

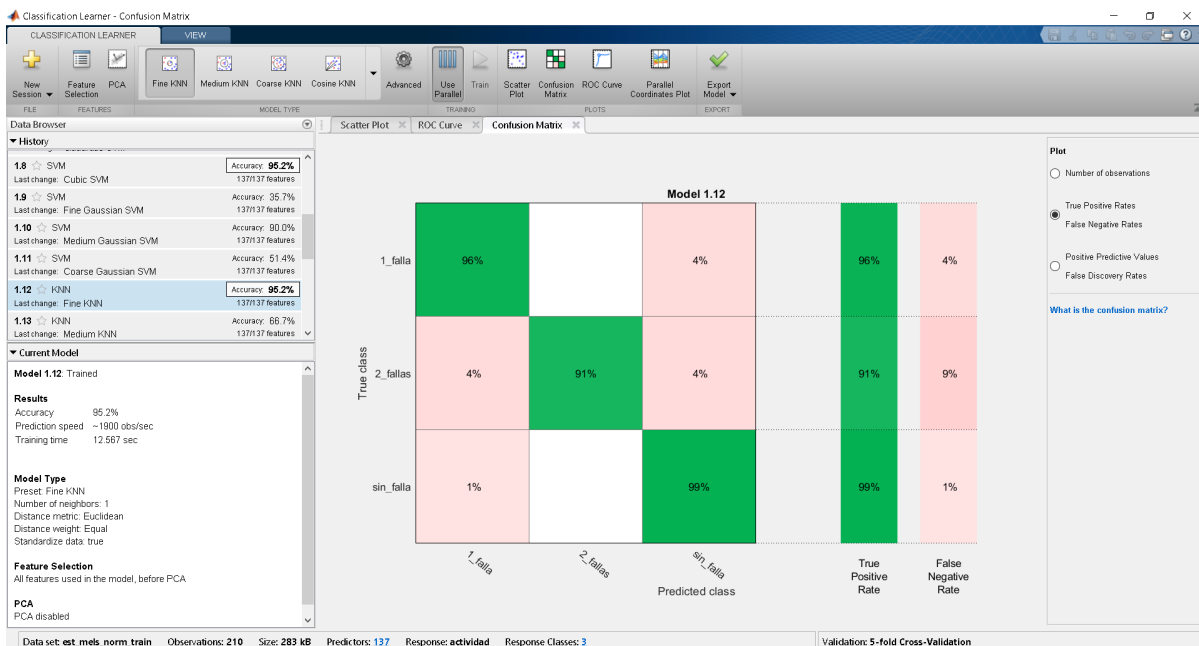


Figura B.20: Matriz de confusión, falsos positivos y falsos negativos del clasificador KNN.

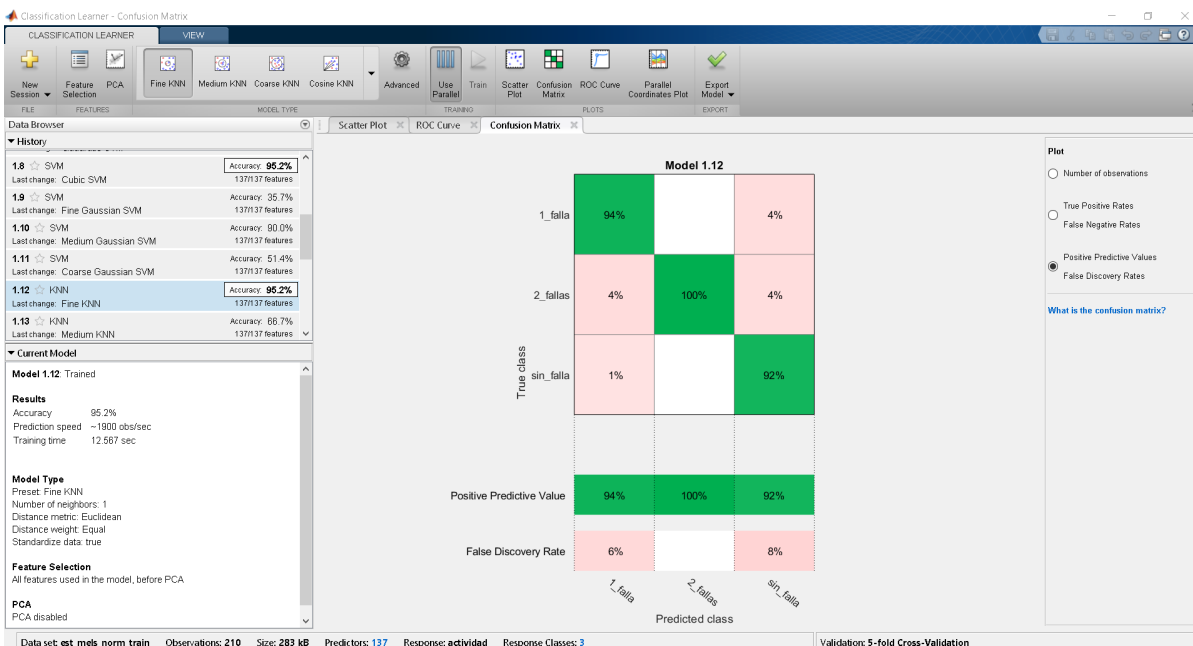


Figura B.21: Matriz de confusión, predictores positivos y falsos descubrimientos del clasificador KNN.

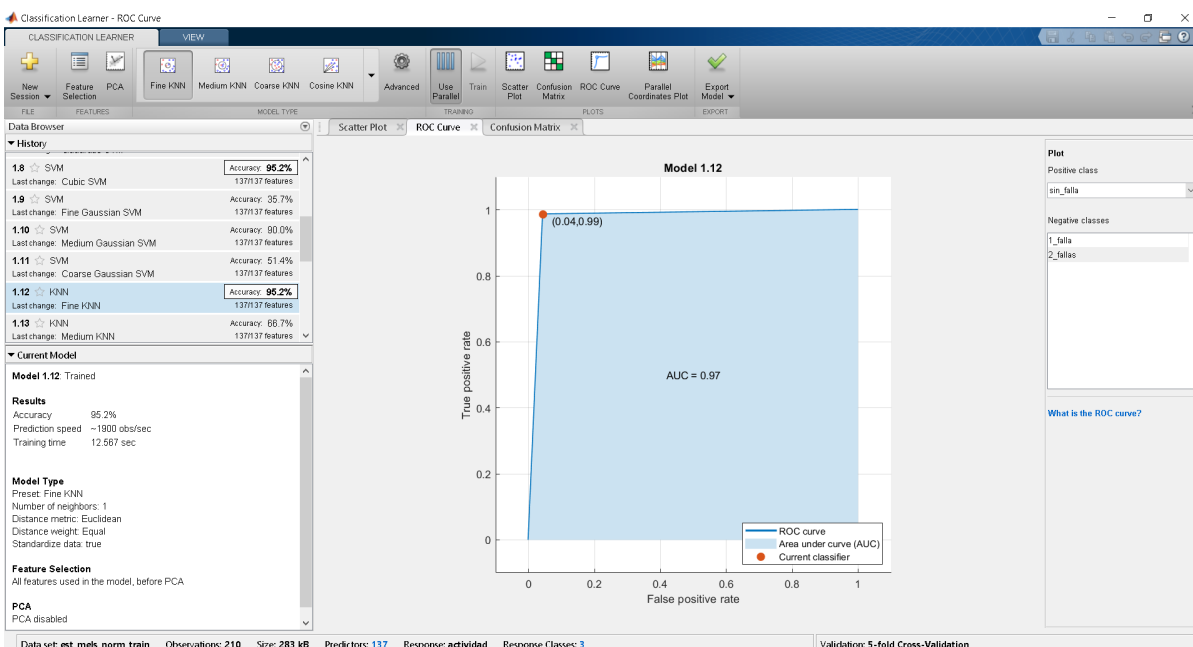


Figura B.22: ROC y AUC, sin fallas del clasificador KNN.

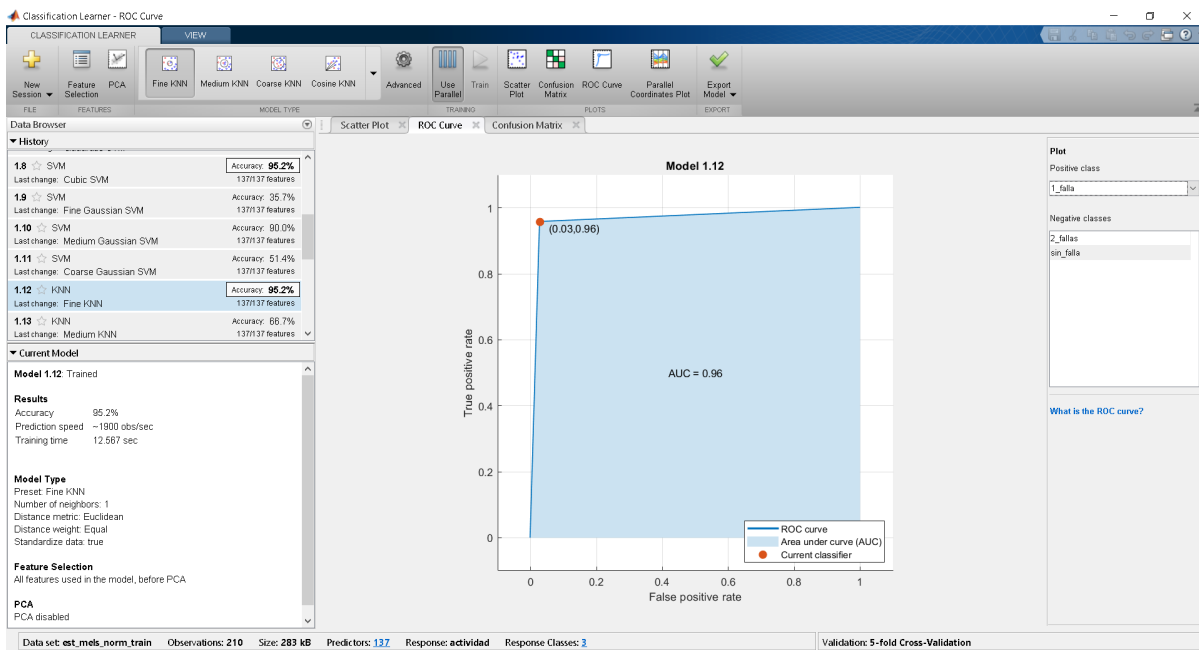


Figura B.23: ROC y AUC, 1 falla del clasificador KNN.

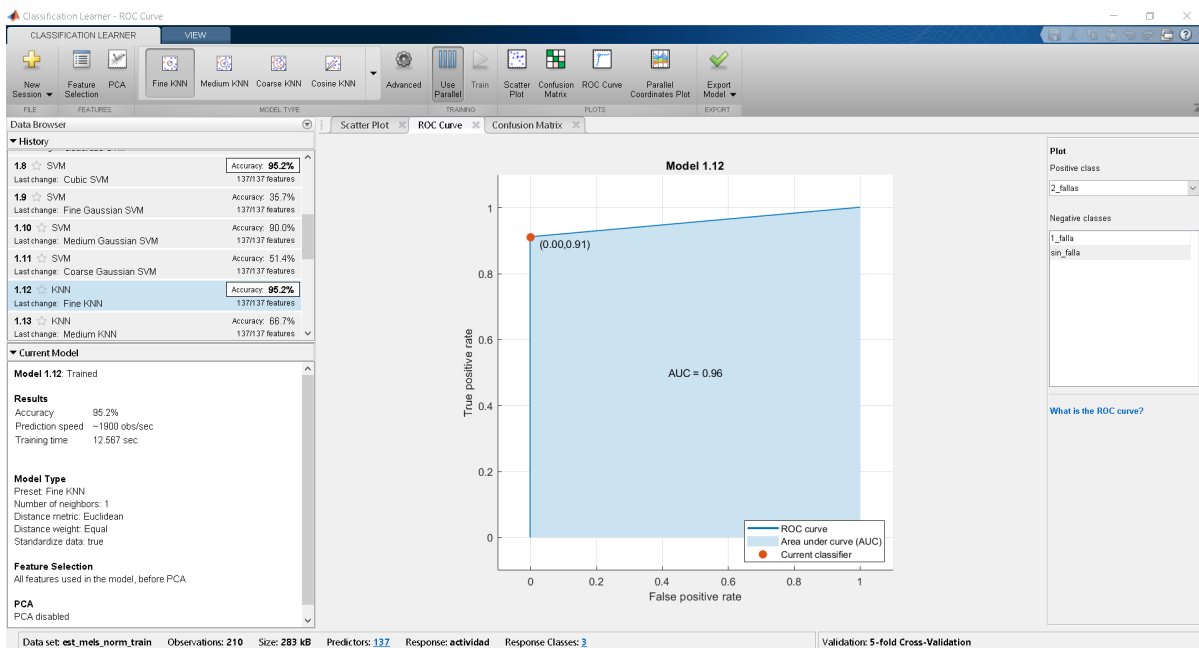


Figura B.24: ROC y AUC, 2 fallas del clasificador KNN.

Referencias

- Shimasaki, Yuichi, Masaki Kanehiro, and Shigeki Baba (1993). “SAE TECHNICAL Spark Plug Voltage Analysis for Monitoring Combustion in an Internal Combustion Engine”. In: 41 2, p. 21.
- Moreno, Antonio et al. (1994). *Aprendizaje automatico*. Barcelona. ISBN: 9788483019962. URL: <https://upcommons.upc.edu/handle/2099.3/36157>.
- Esqueda, José Jaime (2002). *Matlab e Interfaces Gráficas*. Tech. rep. Baja California: INSTITUTO TECNOLÓGICO DE CIUDAD MADERO, Universidad Autónoma de Baja California, Unidad Tijuana, p. 133.
- Munich, Mario E. (2004). “Bayesian Subspace Methods for Acoustic Signature Recognition of Vehicles. (Austria) [OnEuropean Signal Processing Conference (EUSIPCO-2004)]”. In: 12, pp. 6–10.
- Wu, Jian Da and Chao Qin Chuang (2005). “Fault diagnosis of internal combustion engines using visual dot patterns of acoustic and vibration signals”. In: *NDT and E International* 38.8, pp. 605–614. ISSN: 09638695. DOI: 10.1016/j.ndteint.2005.02.007.
- Chavanne, Amezaga Martinez, and M.G.A.M. Suarez (2008). “Localización y separación de fuentes de audio mediante el uso de un arreglo de micrófonos”. In: *VI Congreso Iberoamericano de Acústica - FIA 2008*.
- Andrés, Luis et al. (2009). “Análisis y Clasificación de Sonidos de Motores de Carros, para Diagnosticar Fallas, con Ayuda de Redes Neuronales”. In: URL: <http://ingenieria.uatx.mx/http://www.itapizaco.edu.mx/>.

- Aljaafreh, Ahmad and Liang Dong (2010). “An evaluation of feature extraction methods for vehicle classification based on acoustic signals”. In: *2010 International Conference on Networking, Sensing and Control, ICNSC 2010*, pp. 570–575. DOI: 10.1109/ICNSC.2010.5461596.
- Ganti, Raghu K. et al. (2010). “GreenGPS: A participatory sensing fuel-efficient maps application”. In: *MobiSys'10 - Proceedings of the 8th International Conference on Mobile Systems, Applications, and Services*, pp. 151–164. DOI: 10.1145/1814433.1814450.
- Sandeep Kumar Yadav, Prem Kumar Kalra (2010). “Automatic Fault Diagnosis of Internal Combustion Engine Based on Spectrogram and Artificial Neural Network Sandeep”. In: p. 7.
- Di Deco Sampedro, Javier (2012). “E. y A. de técnicas de aprendizaje automático en el ámbito médico”. MA thesis. Universidad Autónoma de Madrid, p. 103.
- Tahat, Ashraf et al. (2012). “Android-Based Universal Vehicle Diagnostic and Tracking System”. In: pp. 137–143.
- Arturo, Guillermo, Martínez Mascorro, and Aguilar Torres (2013). “Reconocimiento de voz basado en MFCC , SBC y Espectrogramas”. In: pp. 12–20.
- Johnstone, Michael N. (2013). “Automated Detection of Vehicles with Machine Learning”. In: *Edith Cowan University Research Online*, pp. 103–104.
- Garcia, Gerardo and Motor Pasion (2014). *SEAT Ibiza I-Tech, prueba*. URL: <https://www.motorpasion.com.mx/seat/seat-ibiza-i-tech-prueba> (visited on).
- Aktiengesellschaft, BERU (2015). *Todo sobre bujías de encendido. Información técnica núm. 02*. URL: www.beru.com.
- Auto-abc (2015). *Honda Civic ficha técnica*. URL: <http://es.auto-abc.eu/Honda-Civic/v7837-2006> (visited on).
- Wang, Xun (2015). “Estimation of multiple sound sources with data and model uncertainties using the EM and evidential EM algorithms. (Francia)”. In:

- Shu-yi, Paul Hii et al. (2016). “Analysis of Spark Plug Gap on Flame Development using Schlieren Technique and Image Processing Analysis of Spark Plug Gap on Flame Development using Schlieren Technique and Image Processing”. In: DOI: 10.1088/1757-899X/160/1/012044.
- Adrian, Enrique and Torres Vargas (2017). “Sistema de diagnóstico automotriz mediante el análisis de emisiones contaminantes con la aplicación de redes neuronales para la detección de fallas”. MA thesis. UNIVERSIDAD POLITENICA SALESIANA, p. 95.
- Infinity Recording Studio (2017). *Fundamentos sobre Micrófonos (Parte I)*. URL: <https://www.infinityrecordingstudio.com/post/2017/11/12/principios-sobre-micr%7B%5C'%7Bo%7D%7Dfonos-parte-i> (visited on).
- KitoSDev-CMS (2017). *Sistema OBD-II*. Accessed: 2019-05-22. URL: <https://obd2-elm327.es/sistema-obd2-historia-descripcion-futuro>.
- Mannes, John (2017). *Techcrunch The sound of impending failure*. Accessed: 2017-10-20. URL: <https://techcrunch.com/2017/01/29/the-sound-of-impending-failure/>.
- TECH, AD and ANALYTICS (2017). *El algoritmo K-NN y su importancia en el modelado de datos*. Accessed: 2019-05-22. URL: <https://www.analiticaweb.es/algoritmo-knn-modelado-datos/>.
- Choi, Yongju et al. (2018). “Noise-robust sound-event classification system with texture analysis”. In: *Symmetry* 10.9. ISSN: 20738994. DOI: 10.3390/sym10090402.
- RO-DES (2018). *¿Cómo detectar un fallo o avería en las bujías?* Accessed: 2019-05-22. URL: <https://www.ro-des.com/mecanica/como-detectar-un-fallo-o-averia-en-las-bujias/>.
- Erraez, Jhordan and Jonathan Fajardo (2018). “Determinación del consumo de combustible de vehículos en base a los ciclos de conducción EPA FTP75 Y EPA HWFET, en dinamómetro de chasis.” In:
- Garcia-Ceja, Enrique, Carlos E. Galván-Tejada, and Ramon Brena (2018). “Multi-view stacking for activity recognition with sound and accelerometer data”. In: *Information Fusion* 40, pp. 45–56. ISSN: 15662535. DOI: 10.1016/j.inffus.2017.06.004. URL: <http://dx.doi.org/10.1016/j.inffus.2017.06.004>.

- Magazine, U (2018). *Revista Universitaria ¿Cómo Detectar Fallas en Motores de un Auto?* url-
<http://universitariomagazine.com/site/index.php/eventos/como-detectar-fallas-en-motores-de-un-auto>. Accessed: 2017-10-20.
- Mahroogi, Faisal O and S Narayan (2018). “Acoustic transfer function in gasoline engines”.
 In: 14.3, pp. 270–280.
- Motor, Mundo (2018). *Sistema De Encendido Dis: Componentes, Funcionamiento, Y Más*.
 Accessed: 2019-05-22. URL: <https://www.mundodelmotor.net/sistema-de-encendido-dis/>.
- Ruili, Zeng, Zeng Rong, and Ding Lei (2018). “Research on Noise Locating of Diesel Engine Block Based on Microphone Array”. In: *2018 Chinese Control And Decision Conference (CCDC)*, pp. 6610–6613.
- SENER (2018). *Comisión Nacional para el Uso Eficiente de la Energía RENDIMIENTO DE COMBUSTIBLE EN VEHÍCULOS LIGEROS DE VENTA EN MÉXICO*. Accessed: 2018-01-16. URL: <https://www.gob.mx/cms/uploads/attachment/file/282848/Catalogo%202018%20final%201.pdf>.
- Studio, Seeed (2018). *ReSpeaker Mic Array v2.0*. URL: http://wiki.seeedstudio.com/ReSpeaker%7B%5C_%7DMic%7B%5C_%7DArray%7B%5C_%7Dv2.0/ (visited on).
- Veerappa, B. and S. Ramesh (2018). “Severity Analysis of Motorcycle Faults Based on Acoustic Signals”. In: pp. 253–262. DOI: 10.1007/978-981-10-5146-3.
- Wu, Guangqiang and Huwei Wu (2018). “Vibro-Impact Analysis of Manual Transmission Gear Rattle and Its Sound Quality Evaluation”. In: DOI: 10.4271/2017-01-0403.
- Zhong, Jian Hua, Pak Kin Wong, and Zhi Xin Yang (2018). “Fault diagnosis of rotating machinery based on multiple probabilistic classifiers”. In: *Mechanical Systems and Signal Processing* 108, pp. 99–114. ISSN: 10961216. DOI: 10.1016/j.ymsp.2018.02.009. URL: <https://doi.org/10.1016/j.ymsp.2018.02.009>.
- Alcala, Vanessa (2019). “DESARROLLO DE BIOMARCADORES BASADOS EN DETERMINANTES SOCIOECONÓMICOS Y DEMOGRÁFICOS PARA EL DIAGNÓSTICO DE ENFERMEDADES MULTIFACTORIALES NO TRANSMISIBLES POR MEDIO DE

- REDES NEURONALES PROFUNDAS.” MA thesis. Universidad Autónoma de Zacatecas, pp. 63–69.
- Bloomberg (2019). *Gasoline Prices Around the World: The Real Cost of Filling Up*. URL: <https://www.bloomberg.com/graphics/gas-prices/%7B%5C%7D20193:Mexico:MXN:1> (visited on).
- CCRRMA, Stanford University (2019). *Spectrograms*. Accessed: 2017-10-20. URL: <https://ccrma.stanford.edu/%7B-%7Djos/mdft/Spectrograms.html>.
- Dayong, Ning et al. (2019). “Separation method of impulsive fault component for gasoline engine based on acoustic signal analysis”. In: *Shock and Vibration 2019*. ISSN: 10709622. DOI: 10.1155/2019/8573479.
- KitoSDev-CMS (2019). *OBD2-ELM327*. URL: <https://obd2-elm327.es/elm327-informacion-dispositivos>.
- Lin, Lihua et al. (2019). “Research on Transformer Audio Fault Identification Method Based on Neural Network”. In: *Proceedings - 2019 International Conference on Intelligent Transportation, Big Data and Smart City, ICITBS 2019 3*, pp. 606–609. DOI: 10.1109/ICITBS.2019.00151.
- Luo, Linhuan, Xiao Liu, and Xiaohui Yan (2019). “Insulation fault identification of vacuum circuit breakers based on improved MFCC and SVM”. In: *Journal of Physics: Conference Series 1176.6*. ISSN: 17426596. DOI: 10.1088/1742-6596/1176/6/062027.
- Ma, Ruoyun et al. (2019). “Real-world driving cycles and energy consumption informed by large-sized vehicle trajectory data”. In: 223, pp. 564–574. DOI: 10.1016/j.jclepro.2019.03.002.
- Milenio, Redacción (2019). *Precio de la gasolina hoy viernes 8 de noviembre en México*. URL: <https://www.milenio.com/negocios/precio-gasolina-viernes-8-noviembre-2019-mexico>.
- ponit, Tutorials (2019). *KNN Algorithm - Finding Nearest Neighbors*. URL: https://www.tutorialspoint.com/machine%7B%5C_%7Dlearning%7B%5C_%7Dwith%7B%5C_%7Dpython/machine%7B%5C_%7Dlearning%7B%5C_%7Dwith%7B%5C_%7Dpython%7B%5C_%7D

5C_%7Dknn%7B%5C_%7Dalgorithm%7B%5C_%7Dfinding%7B%5C_%7Dnearest%7B%5C_%7Dneighbors.htm (visited on).

Robles-Guerrero, Antonio et al. (2019). “Analysis of a multiclass classification problem by Lasso Logistic Regression and Singular Value Decomposition to identify sound patterns in queenless bee colonies”. In: *Computers and Electronics in Agriculture* 159. February, pp. 69–74. ISSN: 01681699. DOI: 10.1016/j.compag.2019.02.024. URL: <https://doi.org/10.1016/j.compag.2019.02.024>.

SENER (2019). *Cat logo de Rendimientos 2019_v18-07-31_2_*. URL: <https://www.gob.mx/conuee/documentos/rendimiento-de-combustible-en-vehiculos-ligeros-de-venta-en-mexico>.

The R Foundation (2019). *The R Project for Statistical Computing*. URL: <https://www.r-project.org/about.html> (visited on).

Moghaddam, Baback, Mitsubishi Electric, and Ming-hsuan Yang (n.d.). “Gender Classification with Support Vector Machines”. In: (), p. 6.