

UNIVERSIDAD POLITÉCNICA SALESIANA

SEDE CUENCA

CARRERA DE INGENIERÍA MECÁNICA AUTOMOTRIZ

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

PROYECTO TÉCNICO:

**“DESARROLLO DE UN ALGORITMO MEDIANTE ANÁLISIS DE APRENDIZAJE
AUTOMÁTICO PARA LA DETECCIÓN DE FALLOS EN VEHÍCULOS M1 CON
MOTORES DE ENCENDIDO PROVOCADO”**

AUTORES:

Cabrera Palacios Adonnys Paul

Chiluiza Luna Byron Marcelo

TUTOR:

Ing. Néstor Diego Rivera Campoverde, M.Sc

Cuenca – Ecuador

2018

CESIÓN DE DERECHOS DE AUTOR

Nosotros, Adonnys Paul Cabrera Palacios, con documento de identificación N° 0707032587 y Byron Marcelo Chiluzza Luna, con documento de identificación N° 0705346302, manifestamos nuestra voluntad y cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud que somos autores del Trabajo de Titulación: “DESARROLLO DE UN ALGORITMO MEDIANTE ANÁLISIS DE APRENDIZAJE AUTOMÁTICO PARA LA DETECCIÓN DE FALLOS EN VEHÍCULOS M1 CON MOTORES DE ENCENDIDO PROVOCADO”, mismo que ha sido desarrollado para optar por el título de: *Ingeniero Mecánico Automotriz*, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en nuestra condición de autores nos reservamos los derechos morales de la obra antes citada. En concordancia, suscribimos este documento en el momento que hacemos entrega del trabajo final en formato impreso y digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, diciembre del 2018



Adonnys Paul Cabrera Palacios

C.I. 0707032587



Byron Marcelo Chiluzza Luna

C.I. 0705346302

CERTIFICACIÓN

Yo, Néstor Diego Rivera Campoverde, declaro que bajo mi tutoría fue desarrollado el Trabajo de Titulación: “DESARROLLO DE UN ALGORITMO MEDIANTE ANÁLISIS DE APRENDIZAJE AUTOMÁTICO PARA LA DETECCIÓN DE FALLOS EN VEHÍCULOS M1 CON MOTORES DE ENCENDIDO PROVOCADO”, realizado por Adonnys Paul Cabrera Palacios y Byron Marcelo Chiluiza Luna, obteniendo el *Proyecto Técnico* que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana.

Cuenca, diciembre del 2018



Ing. Néstor Diego Rivera Campoverde, M.Sc

C.I. 0103898995

DECLARATORIA DE RESPONSABILIDAD

Nosotros, Adonnys Paul Cabrera Palacios, con documento de identificación N° 0707032587, y Byron Marcelo Chiluzza Luna, con documento de identificación N° 0705346302, autores del Trabajo de Titulación: “DESARROLLO DE UN ALGORITMO MEDIANTE ANÁLISIS DE APRENDIZAJE AUTOMÁTICO PARA LA DETECCIÓN DE FALLOS EN VEHÍCULOS M1 CON MOTORES DE ENCENDIDO PROVOCADO”, certificamos que el total contenido del *Proyecto Técnico*, son de nuestra exclusiva responsabilidad y autoría.

Cuenca, diciembre del 2018



Adonnys Paul Cabrera Palacios

C.I. 0707032587



Byron Marcelo Chiluzza Luna

C.I. 0705346302

AGRADECIMIENTO

Agradezco Primero a Dios concederme la vida, guiándome en esta etapa importante de mi vida.

A mi madre por brindarme su confianza y apoyo en todo momento de mi vida estudiantil y cotidiana.

A mi tutor de tesis, Ing. Néstor Rivera M.Sc por brindarme su confianza y sabiduría en el transcurso de este proyecto.

A mis hermanos Jack y Becker, que han sido mis amigos y un enorme apoyo en mi vida.

A mi compañero de tesis Byron por ser un gran apoyo de amistad y conocimientos para el desarrollo de este proyecto.

A mis todos mis amigos, y familiares que de alguna u otra forma me han apoyado formando parte de este trabajo.

Adonnys

AGRADECIMIENTO

Agradecer primero a Dios por brindarme sabiduría, paciencia, confianza para sobresalir ante las adversidades de la vida.

A mi tutor de tesis Ing. Néstor Rivera M.Sc que gracias a sus conocimientos impartidos fue el eje principal para la culminación de este proyecto.

A mi compañero de tesis Adonnys, quien deposito toda la confianza en mí para desarrollar este proyecto.

Byron

DEDICATORIA

Dedico este proyecto:

Primeramente, a Dios y a la Virgencita del Cisne por ser mi fortaleza incondicional en cada momento de mi vida.

A mis queridos padres Boris y Nancy quienes han velado por mi bienestar a lo largo de mis estudios, por ser mi apoyo absoluto para culminar esta importante etapa de mi vida.

A mis hermanos que a pesar de la distancia alegraron cada día de mi estadía en esta ciudad tan hermosa como lo es Cuenca.

Esta especial dedicatoria va directamente al cielo para mi Papi Orlando, sé que él desde donde esté está sonriendo por haber alcanzado este triunfo.

Adonnys

DEDICATORIA

Dedico este trabajo de titulación, a mi abuelita que cariñosamente le decía mami Rosa quien es mi inspiración y un ejemplo de trabajo y lucha por salir adelante a pesar de que ahora me cuida desde el cielo.

Para mi madre Carmen, mi hermana Daniela y mis sobrinos que fueron pilares principales de apoyo y confianza, que gracias a su cariño me han ayudado a conseguir mis metas propuesta.

Byron

RESUMEN

Con la finalidad de aportar al mejoramiento del mantenimiento automotriz, en el presente trabajo investigativo se propone como objetivo principal el desarrollo de un algoritmo de aprendizaje automático para la detección de fallas en etapa temprana en el vehículos M1. A partir de los objetivos y el planteamiento del problema se elabora el marco teórico, el mismo que fundamente la propuesta que se espera obtener como resultado diagnosticar las fallas en etapa temprana en los vehículos M1 de estudio. Los temas principales expuestos en el marco teórico se relacionan con un estudio de los modos de fallo, herramientas de aprendizaje y clasificación supervisado y no supervisado. La propuesta pretende atender las necesidades de reducir el consumo de combustible, emisiones de gases, costos y tiempos de diagnóstico mediante un algoritmo de aprendizaje automático. Por consiguiente, mediante la herramienta de aprendizaje y clasificación se analizan los datos de comportamiento del sistema con diferentes tipos de Máquinas de Soporte Vectorial (SVM's) como el clasificador cúbico y el gaussiano, para de esa manera determinar la fiabilidad.

Posteriormente los datos que se obtienen son tratados mediante la ayuda del Software Matlab® determinar la validez de los resultados y la relación que determina si influyen en el kilometraje actual y el kilometraje del último mantenimiento y así poder determinar la fiabilidad.

ABSTRACT

With the intention of contributing towards the improvement of the automotive maintenance, this research paper proposes as its main objective to develop an automatic learning algorithm in order to detect early phase M1 vehicles defects. Furthermore, the research's theoretical background is developed based upon a problem approach and the project objectives; it states the proposal, and thus hopes to achieve as a result the diagnostic of automotive flaws within the earlier stages of the M1 study vehicles. The principal topics demonstrated in this theoretical background are developed in relation to a study of the types of flaws, learning –tools, and non-supervised and supervised classification. Through the employment of the automatic learning algorithm, this proposal endeavors to aid in the reduction of fuel-usage, gas emissions, expenditures, and diagnostic time. Therefore, by means of such learning-tools and classification, the system performance data is then analyzed with different kinds of Support Vector Machines (SVMs): including the cubic-classifier and the gaussiano, which function in order to determine reliability.

Subsequently, the obtained data is treated with the help of Matlab software, in order to determine the validity of the results, and also compare the relationship between the current and the last maintenance milage marker, in that way determining the reliability.

ÍNDICE

1	INTRODUCCIÓN	1
2	PROBLEMA.....	2
3	OBJETIVOS	3
3.1	Objetivo General	3
3.2	Objetivos Específicos.....	3
4	FUNDAMENTOS TEÓRICOS.....	4
4.1	Motores de encendido provocado, MEP	4
4.2	Definición de combustible	4
4.2.1	Propiedades de la gasolina.	5
4.3	Proceso de Combustión.....	5
4.3.1	Tipos de mezcla.....	6
4.4	Motor de cuatro tiempos	6
4.4.1	Fase de admisión.	7
4.4.2	Fase de compresión.	7
4.4.3	Fase de expansión.....	7
4.4.4	Fase de escape.	7
4.5	Inteligencia Artificial	8
4.5.1	Inteligencia computacional.....	8
4.5.1.1	<i>Máquinas de soporte vectorial.</i>	8
4.5.1.2	<i>K`means.</i>	9
4.5.1.3	<i>Árboles de decisión.</i>	10
4.6	Definición de falla.....	11
4.6.1	Modo de falla.....	11

4.7	Definición de adquisición de datos	11
4.8	Definición de sensor automotriz	12
4.9	Definición de ajuste de combustible	12
4.10	Definición de fiabilidad.....	13
4.10.1	Representación gráfica de las funciones características de los modelos de fiabilidad.	13
5	ESTADO DEL ARTE.....	14
6	MARCO METODOLÓGICO.....	16
6.1	Obtención de datos y valores de los PID's del sistema de inyección mediante un protocolo de pruebas en vehículos M1.....	16
6.1.1	Característica del parque automotor en el Ecuador.....	16
6.1.2	Campo experimental.....	17
6.1.2.1	<i>Vehículos de prueba</i>	17
6.1.3	Planificación del experimento para la obtención de datos.	20
6.1.3.1	<i>Variables de respuesta.</i>	21
6.1.3.2	<i>Variables de estudio.</i>	22
6.1.3.3	<i>Variables de bloqueo.</i>	22
6.1.3.4	<i>Variables de ruido.</i>	23
6.1.4	Equipos utilizados en la toma de muestras.....	23
6.1.4.1	<i>Freematics.</i>	23
6.1.4.2	<i>Sensor de Presión Absoluta de Múltiple (MAP).</i>	25
6.1.4.3	<i>Sensor de Flujo de Masa de Aire (MAF).</i>	26
6.1.4.4	<i>Sensor de Temperatura del Anticongelante del Motor (ECT).</i>	26
6.1.4.5	<i>Sensor de Temperatura del Aire de Admisión (IAT).</i>	27
6.1.4.6	<i>Sensor de Posición de la Mariposa (TPS).</i>	27
6.1.4.7	<i>Sensor de Revoluciones del Motor (RPM).</i>	28

6.1.4.8	<i>Sensor de Oxígeno (O2).</i>	29
6.1.4.9	<i>Sensor de Velocidad del vehículo (VSS).</i>	29
6.1.5	Sistema de adquisición de datos.	30
6.1.5.1	<i>Protocolo de medición.</i>	31
6.1.5.2	<i>Extracción y visualización de datos</i>	31
6.2	Aplicación de métodos estadísticos multivariante para el procesamiento de datos recolectados.	33
6.2.1	Variables de entrada.	33
6.2.2	Variables de salida.	34
6.2.3	Base de datos en estudio.	34
6.2.4	Procesamiento de la base de datos.	35
6.2.5	Análisis de datos obtenidos mediante K'means.	37
6.2.5.1	<i>Análisis de la categoría del kilometraje actual mediante K'means.</i>	38
6.2.5.2	<i>Análisis del último mantenimiento mediante K'means.</i>	42
6.2.6	Fiabilidad de los valores obtenidos en el kilometraje del último mantenimiento.	47
6.3	Desarrollo de un algoritmo mediante el análisis de aprendizaje automático para la detección de fallas en etapa temprana en motores de encendido provocado.	48
6.3.1	Análisis de la categoría de kilometraje actual mediante SVM.	49
6.3.1.1	<i>Análisis de la categoría del kilometraje actual usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP)</i>	50
6.3.1.2	<i>Análisis de la categoría del kilometraje actual usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).</i>	53
6.3.1.3	<i>Análisis de la categoría del kilometraje actual usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).</i>	55
6.3.1.4	<i>Análisis de la categoría del kilometraje actual usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP)</i>	57

6.3.1.5	<i>Análisis de la categoría del kilometraje actual usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM)</i>	60
6.3.1.6	<i>Análisis de la categoría del kilometraje actual usando siete vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS)</i>	62
6.3.2	<i>Análisis de la categoría de kilometraje del último mantenimiento mediante SVM.</i>	64
6.3.2.1	<i>Análisis de la categoría de kilometraje del último mantenimiento al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP)</i>	65
6.3.2.2	<i>Análisis de la categoría de kilometraje del último mantenimiento usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).....</i>	67
6.3.2.3	<i>Análisis de la categoría de kilometraje del último mantenimiento usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS)</i>	69
6.3.2.4	<i>Análisis de la categoría del último mantenimiento al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP)</i>	71
6.3.2.5	<i>Análisis de la categoría de kilometraje del último mantenimiento usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).....</i>	73
6.3.2.6	<i>Análisis de la categoría del último mantenimiento usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS)</i>	76
6.4	<i>Análisis de los resultados obtenidos mediante métodos estadísticos multivariante para la validación del algoritmo desarrollado</i>	78
6.4.1	<i>Validación del Modelo Matemático a través de un software de ingeniería.</i>	79
6.4.1.1	<i>Análisis del kilometraje actual al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP).....</i>	82
6.4.1.2	<i>Análisis del kilometraje actual usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).</i>	84
6.4.1.3	<i>Análisis del kilometraje actual usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).....</i>	85
6.4.1.4	<i>Análisis del kilometraje actual al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP).....</i>	87

6.4.1.5	<i>Análisis del kilometraje actual usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).</i>	88
6.4.1.6	<i>Análisis del kilometraje actual usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).</i>	89
6.4.1.7	<i>Análisis de la categoría del último mantenimiento al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP).</i>	91
6.4.1.8	<i>Análisis de la categoría del último mantenimiento usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).</i>	92
6.4.1.9	<i>Análisis de la categoría del último mantenimiento usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).</i>	94
6.4.1.10	<i>Análisis de la categoría del último mantenimiento al usando cuatro vectores (Rango SFT, Ajuste de Combustible Largo, MAP).</i>	95
6.4.1.11	<i>Análisis de la categoría del último mantenimiento usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).</i>	97
6.4.1.12	<i>Análisis de la categoría del último mantenimiento usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).</i>	98
7	CONCLUSIONES	100
8	RECOMENDACIONES.....	101
9	BIBLIOGRAFÍA	102
10	ANEXOS	107

ÍNDICE DE FIGURAS

Figura 4.1 Esquema de la combustión de la mezcla en los MEP.	4
Figura 4.2 Proceso de combustión.	5
Figura 4.3 Fases de un motor de cuatro tiempos.	6
Figura 4.4 Separación de datos mediante SVM.	9
Figura 4.5 K'means: Cluster A y Cluster B	10
Figura 4.6 Estructura de un árbol de decisión.	11
Figura 4.7 Representación del funcionamiento de un sensor automotriz.	12
Figura 4.8 Funciones características de los modelos de fiabilidad.	13
Figura 6.1 Venta anual de vehículos por marca.	16
Figura 6.2 Porcentaje de las marcas de vehículos en estudio.	18
Figura 6.3 Porcentaje de los modelos de vehículos para el experimento	18
Figura 6.4 Variables que intervienen en el diseño experimental.	20
Figura 6.5 Proceso para el entrenamiento del SVM.	21
Figura 6.6 Proceso para el entrenamiento del sistema montado.	21
Figura 6.7 Dispositivo Freemantics.	24
Figura 6.8 Sensor MAP.	25
Figura 6.9 Sensor MAF.	26
Figura 6.10 Sensor ECT.	26
Figura 6.11 Sensor IAT.	27
Figura 6.12 Sensor TPS	28
Figura 6.13 Sensor de RPM.	28
Figura 6.14 Sensor de Oxígeno (O ₂)	29
Figura 6.15 Sensor VSS.	30
Figura 6.16 Sistema de adquisición de datos.	30
Figura 6.17 Importación datos obtenidos con el Freemantics One +	32
Figura 6.18 Visualización de datos de los PID's mediante software matemático.	32
Figura 6.19 Visualización de PID's de los sensores.	33
Figura 6.20 Procesamiento de la base de datos en software matemático.	37

Figura 6.21 Análisis de 4 vectores: Rango, Ajuste de Combustible Largo, MAP, RPM.	39
Figura 6.22 Análisis de 3 vectores: Ajustes de Combustible de Largo, MAP, RPM.	40
Figura 6.23 Análisis de 3 vectores: Rango, Ajustes de Combustible Largo, MAP.	40
Figura 6.24 Análisis de 2 vectores: Ajuste de Combustible de Largo, MAP.	41
Figura 6.25 Análisis de 2 vectores: Rango, MAP.	42
Figura 6.26 Análisis de 3 vectores: Rango, Ajuste de Combustible Largo, MAP, RPM.	43
Figura 6.27 Análisis de 3 vectores: Ajuste de Combustible Largo, MAP, RPM.	44
Figura 6.28 Análisis de 3 vectores: Rango, Ajuste de Combustible Largo, MAP.	45
Figura 6.29 Análisis de 2 vectores: Rango, Ajuste de Combustible Largo, MAP.	46
Figura 6.30 Análisis de 2 vectores: Rango, MAP.	46
Figura 6.31 Relación de fiabilidad según los períodos de último mantenimiento de los vehículos en estudio.	47
Figura 6.32 Relación de fiabilidad según las categorías de último mantenimiento de los vehículos en estudio.	48
Figura 6.33 Selección de 5 predictores para el kilometraje actual.	51
Figura 6.34 Coordenadas paralelas para la predicción de las categorías del kilometraje actual. .	51
Figura 6.35 Diagrama de dispersión para predicción del kilometraje actual.	52
Figura 6.36 Selección de 4 predictores para el kilometraje actual.	53
Figura 6.37 Coordenadas paralelas para la predicción de las categorías del kilometraje actual. .	54
Figura 6.38 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.	55
Figura 6.39 Selección de 6 predictores para el kilometraje actual.	55
Figura 6.40 Coordenadas paralelas para la predicción de las categorías del kilometraje actual. .	56
Figura 6.41 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.	57
Figura 6.42 Selección de 3 predictores para el kilometraje actual.	58
Figura 6.43 Coordenadas paralelas para la predicción de las categorías del kilometraje actual. .	58
Figura 6.44 Diagrama de dispersión del ajuste del Rango SFT, en la predicción de las MAP. ...	59
Figura 6.45 Selección de 4 predictores para el kilometraje actual.	60
Figura 6.46 Coordenadas paralelas para la predicción de las categorías del kilometraje actual. .	61
Figura 6.47 Diagrama de dispersión del ajuste del MAP, en la predicción de las RPM.	62
Figura 6.48 Selección de 6 predictores para el kilometraje actual.	62
Figura 6.49 Coordenadas paralelas para la predicción de las categorías del kilometraje actual. .	63

Figura 6.50 Diagrama de dispersión del MAP en la predicción de las RPM.	64
Figura 6.51 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.	66
Figura 6.52 Diagrama de dispersión del ajuste del Rango SFT en la predicción del MAP.....	67
Figura 6.53 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.	68
Figura 6.54 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.	69
Figura 6.55 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.	70
Figura 6.56 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.....	71
Figura 6.57 Selección de 3 predictores para el kilometraje actual.	71
Figura 6.58 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.	72
Figura 6.59 Diagrama de dispersión del ajuste del Rango SFT en la predicción del MAP.....	73
Figura 6.60 Selección de 4 predictores para el kilometraje actual.	74
Figura 6.61 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.	75
Figura 6.62 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.	76
Figura 6.63 Selección de 6 predictores para el kilometraje actual.	76
Figura 6.64 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.	77
Figura 6.65 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.	78
Figura 6.66 Matriz de confusión del kilometraje actual.	83
Figura 6.67 Matriz de confusión para la predicción del kilometraje actual.....	84
Figura 6.68 Matriz de confusión del kilometraje actual.	84
Figura 6.69 Matriz de confusión para la predicción del kilometraje actual.....	85
Figura 6.70 Matriz de confusión del kilometraje actual.	86
Figura 6.71 Matriz de confusión para la predicción del kilometraje actual.....	86
Figura 6.72 Matriz de confusión del kilometraje actual.	87
Figura 6.73 Matriz de confusión para la predicción del kilometraje actual.....	88
Figura 6.74 Matriz de confusión del kilometraje actual.	88

Figura 6.75 Matriz de confusión para la predicción del kilometraje actual.....	89
Figura 6.76 Matriz de confusión del kilometraje actual.	90
Figura 6.77 Matriz de confusión para la predicción del kilometraje actual.....	90
Figura 6.78 Matriz de confusión del último mantenimiento.....	91
Figura 6.79 Matriz de confusión en la predicción para el kilometraje del último mantenimiento.	92
Figura 6.80 Matriz de confusión del último mantenimiento.....	93
Figura 6.81 Matriz de confusión de la predicción para el kilometraje del último mantenimiento.	93
Figura 6.82 Matriz de confusión del último mantenimiento.....	94
Figura 6.83 Matriz de confusión de la predicción para el kilometraje del último mantenimiento.	95
Figura 6.84 Matriz de confusión del último mantenimiento.....	96
Figura 6.85 Matriz de confusión de la predicción para el kilometraje del último mantenimiento.	96
Figura 6.86 Matriz de confusión del último mantenimiento.....	97
Figura 6.87 Matriz de confusión de la predicción para el kilometraje del último mantenimiento	98
Figura 6.88 Matriz de confusión del último mantenimiento.....	99
Figura 6.89 Matriz de confusión de la predicción para el kilometraje del último mantenimiento	99

ÍNDICE DE TABLAS

Tabla 6.1 Marca de vehículos de estudio.....	17
Tabla 6.2. Vehículos M1 de estudio.	19
Tabla 6.3 Variables de Respuesta.	22
Tabla 6.4 Variables de entrada.....	22
Tabla 6.5 Variables de bloqueo.	23
Tabla 6.6 Variables de ruido.....	23
Tabla 6.7 Características del Freematics One +.....	25
Tabla 6.8. Extracto de la base de datos en estudio.....	34
Tabla 6.9. División por categorías del kilometraje actual.	35
Tabla 6.10 División por categorías del último período de mantenimiento.	36
Tabla 6.11 Combinación de 3 y 4 vectores.....	38
Tabla 6.12 Combinación de 2 vectores.....	41
Tabla 6.13 Combinación de 3 vectores.....	43
Tabla 6.14 Combinación de 2 vectores.....	45
Tabla 6.15 Configuraciones de SVM con respecto al ajuste del kilometraje actual.....	50
Tabla 6.16. Configuración SVM con respecto al ajuste del último mantenimiento	65
Tabla 6.17 Extracto de los resultados de la predicción del kilometraje actual.	79
Tabla 6.18 Extracto de los resultados de la predicción para el kilometraje del último mantenimiento.	80
Tabla 6.19 Resultados porcentuales de la validación del algoritmo en la predicción del kilometraje actual.	81
Tabla 6.20 Resultados porcentuales de la validación del algoritmo en la predicción para el kilometraje del último mantenimiento.....	82

ÍNDICE DE ANEXOS

Anexo 1 Análisis de vector 11: Rango, ECT, IAT.	107
Anexo 2 Análisis de vector 11: Ajuste de combustible a largo plazo, ECT, IAT.	107
Anexo 3 Análisis de vector 11: ECT, IAT.....	108
Anexo 4 Análisis de vector 9: RANGO, ECT, IAT.	108
Anexo 5 Análisis de vector 9: Ajuste de combustible a largo plazo, ECT, IAT.	108
Anexo 6 Selección de 3 predictores para el kilometraje actual.	109
Anexo 7 Coordenadas paralelas para la predicción de las categorías del kilometraje actual.	109
Anexo 8 Matriz de confusión de la predicción del kilometraje actual.	110
Anexo 9 Selección de 6 predictores para el kilometraje del último mantenimiento.	110
Anexo 10 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.	111
Anexo 11 Matriz para la predicción para el kilometraje del último mantenimiento.	111
Anexo 12 Selección de 4 predictores para el kilometraje del último mantenimiento	112
Anexo 13 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.	112
Anexo 14 Matriz de confusión para el kilometraje del último mantenimiento.	113

1 INTRODUCCIÓN

Actualmente los modelos de vehículos constan con una computadora integrada ECU (Unidad de Control del Motor). El problema radica cuando se realiza un chequeo en el estado actual del motor por medio de un scanner automotriz, éste al realizar el diagnóstico no siempre cubre todas las variables que demuestren una anomalía en la señal de un sensor, debido a que, cuando las señales presentan fluctuaciones dentro de sus límites de funcionamiento producen fallas que no pueden ser reconocidas por el sistema de diagnóstico, haciendo que no se genere un código de avería (BOSCH, 2005), por esta razón el scanner generalmente detecta fallas correctivas y no fallas en etapa temprana. Como menciona (Aguilar Romero & Tanzado Flores, 2017) tener una mala apertura del electrodo de la bujía produce un bajo voltaje de encendido, dando como lugar un incremento en el consumo de combustible y un aumento en las emisiones contaminantes. Por tal motivo, aunque se utilice el scanner para realizar el diagnóstico del automóvil, no es posible tener el 100% de fiabilidad según indica (Fuentes Covarrubias & Fuentes Covarrubias, 2015).

Además, se puntualiza en el presente proyecto el desarrollo de un algoritmo de aprendizaje automático para la detección de fallas en etapa temprana en el automóvil y se espera obtener como resultados reducir el consumo de combustible, emisiones de gases, costos y tiempos de diagnóstico.

Los resultados obtenidos beneficiarán beneficiará al Grupo de Investigación de Ingeniería de Transporte (GIIT), para su línea de investigación de Ingeniería del Mantenimiento Automotriz y Eficiencia Energética de la Carrera de Ingeniería Mecánica Automotriz de la Universidad Politécnica Salesiana y para proyectos de investigación futuros.

2 PROBLEMA

El problema radica cuando se realiza un chequeo en el estado actual del motor por medio de un scanner automotriz, éste al realizar el diagnóstico no siempre cubre todas las variables que demuestren una anomalía en la señal de un sensor, debido a que, cuando las señales presentan fluctuaciones dentro de sus límites de funcionamiento producen fallas que no pueden ser reconocidas por el sistema de diagnóstico, haciendo que no se genere un código de avería (BOSCH, 2005), por esta razón el scanner generalmente detecta fallas correctivas y no fallas en etapa temprana. Como menciona (Aguilar Romero & Tanzado Flores, 2017) tener una mala apertura del electrodo de la bujía produce un bajo voltaje de encendido, provocando incremento en el consumo de combustible y un aumento en las emisiones contaminantes. Por tal motivo, aunque se utilice el scanner para realizar el diagnóstico del automóvil, no es posible tener el 100% de fiabilidad según indica (Fuentes Covarrubias & Fuentes Covarrubias, 2015).

3 OBJETIVOS

3.1 Objetivo General

Desarrollar un algoritmo mediante análisis de aprendizaje automático utilizando datos OBDII para la detección de fallos a etapa temprana en vehículos M1 con motores de encendido provocado en cilindrada menor o igual a 2000 cc.

3.2 Objetivos Específicos

- Obtener datos y valores de los PID's del sistema de inyección mediante un protocolo de pruebas en vehículos M1.
- Aplicar métodos estadísticos multivariante para el procesamiento de datos recolectados.
- Desarrollar un algoritmo mediante el análisis de aprendizaje automático, para la detección de fallas en etapa temprana en motores de encendido provocado.
- Analizar los resultados obtenidos mediante métodos estadísticos multivariantes para la validación del algoritmo desarrollado.

4 FUNDAMENTOS TEÓRICOS

4.1 Motores de encendido provocado, MEP

Otros nombres que reciben estos motores son: motor de explosión, motor de encendido Otto y por chispa, en motores modernos el instante en el que consigue al hacer saltar la chispa deberá ser el adecuado para conseguir que el proceso de combustión sea eficiente. Estos motores consisten de una mezcla de aire y combustible para su funcionamiento, como consecuencia de lo anterior, el proceso de combustión se produce por el avance de un frente de llama que recorre la cámara de combustión, partiendo desde la bujía y separando en todo momento dos zonas claramente definidas, una con gases frescos y otros con gases quemados. (Payri & Desantes, 2011). El esquema de combustión de los motores MEP se representa en la figura 4.1




Figura 4.1 Esquema de la combustión de la mezcla en los MEP.

Fuente: (Rovira de Antonio & Muñoz Domínguez, 2014)

4.2 Definición de combustible

Se denomina combustible a toda sustancia ya sea artificial o natural, que al momento de combinarse con el oxígeno genera calor rápidamente, además una ventaja es que pueden ser utilizados estos combustibles con diferentes composiciones y diferentes fases (líquidos y gaseosos), tomando en cuenta que actualmente en su gran mayoría son derivados del petróleo. (Payri & Desantes, 2011)

4.2.1 Propiedades de la gasolina.

- Volatilidad
- Poder calorífico
- Aditivos
- Densidad
- Resistencia a la detonación

4.3 Proceso de Combustión

En los motores de encendido provocado (MEP) se produce una combustión que da como resultado de la reacción química entre la mezcla de hidrocarburos y el comburente. La mezcla de hidrocarburos está compuesta por hidrógeno, carbono y el comburente (oxígeno). (Sánchez, 2012)



Figura 4.2 Proceso de combustión.

Fuente: (Sánchez, 2012)

Durante la combustión, si todo el carbono se transforma en dióxido de carbono (CO₂), todo el hidrógeno se transforma en agua (H₂O) y todo el azufre en dióxido de azufre (SO₂), se obtiene un proceso de combustión completo. A diferencia del proceso de combustión incompleto que está formado por componentes no quemados como carbono (C), monóxido de carbono (CO), hidrocarburos (HC). (Cengel & Boles, 2006)

4.3.1 Tipos de mezcla.

Una buena combustión depende de la calidad en la mezcla del combustible con el comburente, dependiendo de la proporción entre ellos, existen tres tipos de mezclas:

- **Mezcla estequiométrica:** Este tipo de mezcla se obtiene al mezclar aproximadamente de 1 gramo de combustible por cada 14,7 gramos de aire.
- **Mezcla rica:** Cuando la cantidad de combustible es mayor con respecto al aire que en una mezcla estequiométrica.
- **Mezcla pobre:** La cantidad de aire es mayor con respecto al combustible que en una mezcla estequiométrica. (Sánchez, 2012).

4.4 Motor de cuatro tiempos

En este tipo de motores el ciclo del trabajo se entiende como dos vueltas del cigüeñal o, lo que es lo mismo, cuatro fases o tiempos del émbolo, como se muestra en la figura 4.3.




Figura 4.3 Fases de un motor de cuatro tiempos.

Fuente: (Gonzales Calleja, 2016)

A continuación, se describe las cuatro fases del motor:

4.4.1 Fase de admisión.

En esta fase, el pistón empieza desde el punto muerto superior (PMS) y la válvula de admisión se abre completamente, produciéndose una mezcla de aire y combustible. Posteriormente el pistón desciende hasta al punto muerto inferior (PMI), instante en el que se cierra la válvula de admisión, en donde además el cigüeñal ha realizado un giro de 180° o media vuelta. (Gonzales Calleja, 2016)

4.4.2 Fase de compresión.

Fase que se genera posterior a la de admisión, en donde el pistón desarrolla una carrera ascendente desde el PMI al PMS, comprimiendo la mezcla, además las respectivas válvulas de admisión y escape permanecen cerradas, produciendo en el cigüeñal un giro 180 grados, presentándose una acumulación desde el inicio del ciclo 360° , en otros términos, una vuelta completa. (Gonzales Calleja, 2016)

4.4.3 Fase de expansión.

En este período, el pistón se encuentra en el PMS tiene lugar el salto de la chispa provocada por los electrodos de la bujía, provocando que se inflame la mezcla y se produzca la combustión, en este instante se considera un volumen constante y la presión se incrementa súbitamente, posteriormente se tiene como lugar la expansión de los gases quemados, donde el pistón es empujado desde el PMS hasta el PMI en su carrera descendente, reduciendo la presión en el cilindro. Al final de este período el cigüeñal ha girado 540° en total (Gonzales Calleja, 2016)

4.4.4 Fase de escape.

En esta última fase, el proceso de escape tiene como lugar la salida de los gases quemados. Cuando el pistón está en el PMI, la válvula de escape se abre, produciéndose el recorrido del

pistón, por consecuencia dando barrido de los gases quemados que son expulsados al exterior, la válvula de escape sigue abierta hasta que el pistón llega al PMS, instante en el cual se cierra. Al final del tiempo de escape el cigüeñal ha girado 720° en total desde el inicio del ciclo, es decir, para realizar el ciclo completo se necesita dos vueltas del cigüeñal. (Gonzales Calleja, 2016)

4.5 Inteligencia Artificial

La definición de la inteligencia artificial más cercana a la realidad lo propuso Marvin Minsky, uno de los pioneros de la IA, y dice así: “La inteligencia Artificial es la ciencia de construir máquinas para que permitan tener una mayor precisión, si las hicieran los humanos, requerirían inteligencias”. La IA podemos decir que es aquella ciencia que incorpora conocimiento a los procesos o actividades entendiendo una predicción como la pretensión de encontrar aquellos modelos que permitan pronosticar con mayor exactitud. (Escolano Ruiz, Cazorla Quevedo, Alfonso Galipienso, Colombia Pardo, & Lozano Ortega , 2003)

4.5.1 Inteligencia computacional.

La inteligencia computacional se deriva de la IA, es decir con lleva un aprendizaje con métodos como: máquinas de soporte vectorial y los árboles de decisión que se utilizan en el desarrollo de este proyecto

4.5.1.1 Máquinas de soporte vectorial.

La Máquina de Soporte Vectorial (SVM, por sus siglas en inglés) son herramientas clasificadoras con reconocimiento de patrones y son de aprendizaje supervisado, sus inicios nacen de métodos relacionados con problemas de clasificación y regresión. Se basa en transformar o proyectar un grupo de datos referente a una dimensión dada, con lo cual se llega a

una dimensión superior asignando una función Kernel. La SVM representa un eje de coordenadas en los vectores de entrenamiento, en caso de introducir nuevos datos al modelo, se colocan en el mismo eje con respecto a la cercanía de los grupos antes separados, los cuales serán clasificados. Una ventaja muy significativa en el modelo SVM, es que no depende del tamaño de la muestra que se está requiriendo para el problema, por lo tanto, puede encontrar metodologías que ayuden aún mejor desempeño respecto al tamaño de la muestra en caso de ser grande, el algoritmo se ajusta a problemas no lineales y la solución se da bajo una programación cuadrática. (Sánchez Anzola, 2015)

En la figura 4.4, se muestra el margen que separa dos clases (movimientos alcistas y movimientos bajistas), que busca encontrar un hiperplano que maximice el margen de las dos clases antes mencionadas, El margen obtenido en este caso se puede considerar como óptimo para la clasificación de los datos. (Sánchez Anzola, 2015)

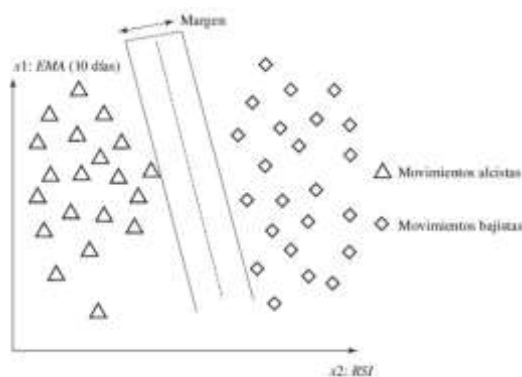


Figura 4.4 Separación de datos mediante SVM.

Fuente: (Sánchez Anzola, 2015)

4.5.1.2 *K*'means.

Es un algoritmo de aprendizaje sin supervisión, que corresponde a la teoría de máquinas de aprendizaje que buscan clasificar un conjunto de datos, es decir, separan elementos en grupos o

clústeres, como se muestra en la figura 4.5 para que cada observación pertenezca al clúster cuyo valor medio es el más cercano. (López & Fernández, 2018)

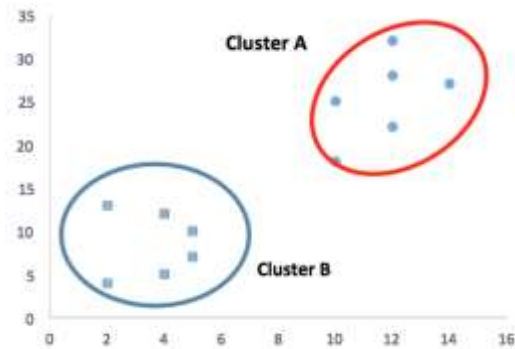


Figura 4.5 K'means: Cluster A y Cluster B

Fuente: (López & Fernández, 2018)

4.5.1.3 Árboles de decisión.

Los árboles de decisión fueron desarrollados por el año 1963 de la mano de Morgan y Sonquist, en la actualidad son utilizados como un modelo predictivo dentro del campo de la inteligencia artificial. (Camborda, 2017)

Los árboles de decisión son empleados principalmente para tareas de clasificación, que a partir de una base o conjunto de datos elaboran diagramas basados en reglas para representar sucesos con el objetivo de encontrar la solución a un problema, dicho en otras palabras, ayuda en la toma de decisiones más acertadas para solucionar un problema. Un árbol de decisión contiene estructuralmente nodos internos, nodos de probabilidad, nodos hojas y arcos. Algunas ventajas de los árboles es que son fáciles de entender y no presentan dificultades al combinar con otras herramientas de decisiones. (Camborda, 2017)




Figura 4.6 Estructura de un árbol de decisión.

Fuente: (Camborda, 2017)

4.6 Definición de falla

Es un cambio en el comportamiento de alguno de los componentes de un sistema, de manera que éste ya no puede cumplir con la función para la cual fue diseñado. (Hurtado Cortés, Villarreal López, & Villarreal López, 2016).

4.6.1 Modo de falla

Un modo de falla se define como una causa de falla o a su vez una manera en el que el sistema pierde la capacidad de desempeñar su función, es decir la forma en que un activo falla. A cada modo de falla existe un riesgo por lo cual corresponde una acción de mitigación o prevención, se dice que para cada sistema de modo de falla existe una tarea de mantenimiento. (Aguilar Otero, Torres Arcique, & Magaña Jiménez, 2010)

4.7 Definición de adquisición de datos

La adquisición de datos se define como el proceso de medir un fenómeno físico, corriente, presión, temperatura, entre otras. Para luego tener una mejora en el procesamiento de datos de en un estudio o proceso. (NATIONAL INSTRUMENTS, 2018)

4.8 Definición de sensor automotriz

Un sensor automotriz es un dispositivo que tiene la capacidad de convertir magnitudes físicas o químicas en magnitudes eléctricas para que estas sean entendidas y analizadas por la Unidad de Control del Motor o ECU (Engine Control Unit), para que gestione el funcionamiento del motor, los sistemas de seguridad y confort del automóvil. (Meganeboy, 2014)




Figura 4.7 Representación del funcionamiento de un sensor automotriz.

Fuente: (Meganeboy, 2014)

4.9 Definición de ajuste de combustible

Los ajustes de combustible son correcciones hechas por la ECU, para que la relación aire-combustible se mantenga en una mezcla estequiométrica (14:1) en compensación al desgaste de los componentes del sistema de combustible y de los elementos del motor. Las correcciones se dan en dos maneras: ajuste de combustible corto (SFT) y ajustes de combustible largo (LFT) (Calderón Calderón, 2012)

- **Long Fuel Trim (LFT)**, esta es una corrección a largo plazo que se da por la variación de los valores porcentuales (+/-) del sensor de oxígeno, indicando cuanto a corregido al ancho de pulso de inyección de combustible. A partir de un valor de 25% de corrección, se genera un código de falla.

- **Short Fuel Trim (SFT)**, esta corrección es a corto plazo, que se da por la variación de la señal del sensor de oxígeno y provoca que la mezcla alterne entre pobre y rica. (Calderón Calderón, 2012)

4.10 Definición de fiabilidad

Conocida como confiabilidad es la medida estadística de la probabilidad para que un elemento o un sistema no falle durante la prestación de un servicio de modo que cumpla con las tareas o funciones de forma correcta, garantizando un óptimo trabajo durante el tiempo preestablecido. (Apolo Torres & Gordillo Rojas, 2017)

4.10.1 Representación gráfica de las funciones características de los modelos de fiabilidad.

En la gráfica 4.8, se muestra los modelos de fiabilidad, es decir, los modelos de Exponencial, Weibull y Normal.




Figura 4.8 Funciones características de los modelos de fiabilidad.

Fuente: (Red Temática Nacional sobre Seguridad de Funcionamiento y Calidad de Servicio de Sistemas Productivos, 2010)

5 ESTADO DEL ARTE

Las máquinas de soporte vectorial (SVM), representan un método de aprendizaje relativamente nuevo y computacional basado en la teoría estadística de aprendizaje y pueden hacer las funciones de sistemas inteligentes. En el monitoreo de la condición de las máquinas y el problema de diagnóstico de falla, las SVM son empleadas para reconocer patrones especiales de la señal adquirida y seguidamente clasificar estos patrones según la ocurrencia de falla en el motor. (Suk Yang & Achmad, 2016).

Según (Aguilar Romero & Tanzado Flores, 2017), Cuando se genera una falla en el sistema de inyección, existen consecuencias en las emisiones contaminantes y en el consumo de combustible, además de que esa falla puede generar mayores problemas de funcionamiento del motor, por ende, es necesario intervenir para evitar futuras averías en el motor. Además, emplearon un análisis de los datos adquiridos por medio de las herramientas de aprendizaje y clasificación. Posteriormente a través del software Minitab®, para determinar la validez y estimar el índice de prioridad de riesgo.

El proyecto técnico: Diagnóstico de fallos del sistema de inyección de un motor de encendido provocado mediante inteligencia artificial, los autores (Rivera Caravajo & Cepeda Landin, 2017), indican que para el análisis de las fallas utilizan herramientas de aprendizaje y clasificación, ya que permiten clasificar las las fallas y diferencias si el motor de encendido provocado se encuentra en buen estado.

Según (Haro Zúñiga, 2017), es posible estimar las emisiones contaminantes productos de la mala combustión del motor de encendido provocado, a través del porcentaje de exactitud aplicando herramientas de aprendizaje y clasificación.

Posteriormente, (Barreto & Zhunio, 2017), efectúan un proyecto dirigido a las Aplicaciones de máquinas de soporte vectorial en el diagnóstico de motores de combustión, el autor propone ser utilizado ya que un buen porcentaje de clasificación muestra que el modelo funciona y es aplicable con nuevos datos, además de predecir una avería en un motor de combustión interna con un porcentaje de confiabilidad.

Según (Apolo Torres & Gordillo Rojas, 2017), la predicción de fallos, se puede tomar la función contraria a la fiabilidad, en este caso se la interpreta como la probabilidad de que el sistema falle en un tiempo determinado.

En base a lo anteriormente mencionado, se ha llevado a cabo varias investigaciones de estudios y proyectos de titulación, con el fin de ampliar el análisis de inteligencia artificial para el diagnóstico de fallos en motores de encendido provocado como es el proyecto de técnico: Análisis de modos de falla, efectos y criticidad del sistema de inyección de un motor de encendido provocado Corsa Evolution 1.4 L.

6 MARCO METODOLÓGICO

6.1 Obtención de datos y valores de los PID's del sistema de inyección mediante un protocolo de pruebas en vehículos M1

6.1.1 Característica del parque automotor en el Ecuador.

En la figura 6.1 se muestra las ventas anuales de las marcas de vehículos emitidos por la Asociación de Empresas Automotrices del Ecuador (AEADE).

Ventas anuales de vehículos por marca En unidades / porcentaje de participación 2010-2017																
Marca	2010	%	2011	%	2012	%	2013	%	2014	%	2015	%	2016	%	2017	%
CHEVROLET	53 479	40,42%	58 180	42,31%	54 047	40,24%	50 795	38,00%	53 574	41,02%	40 995	30,92%	39 371	30,07%	41 001	30,27%
GA	10 008	8,26%	11 965	9,52%	10 344	8,25%	12 200	10,01%	10 038	10,07%	7 647	6,40%	8 406	13,96%	18 273	17,54%
HYUNDAI	22 241	23,84%	14 879	10,84%	12 291	10,32%	9 679	8,46%	10 623	9,86%	5 070	6,08%	4 930	7,70%	8 443	8,90%
GREAT WALL	879	0,53%	2 085	1,42%	2 088	1,72%	1 688	1,48%	2 050	1,90%	2 445	2,94%	2 797	4,28%	6 752	6,46%
TOYOTA	8 722	6,60%	6 730	4,80%	6 840	5,62%	6 429	5,56%	6 478	6,32%	2 001	4,49%	3 981	6,04%	4 804	4,97%
NISSAN	5 427	2,32%	10 080	2,22%	7 981	5,20%	8 579	5,28%	6 039	6,32%	3 754	4,57%	2 474	3,89%	2 508	2,40%
HINO	3 831	2,90%	4 133	2,90%	3 028	2,48%	3 736	3,28%	4 378	3,81%	3 306	4,39%	2 380	3,38%	3 301	3,32%
FORD	4 080	3,09%	4 398	3,12%	4 254	3,52%	4 080	3,56%	4 164	3,47%	1 771	2,38%	1 044	2,38%	2 541	2,42%
MAZDA	8 886	6,60%	8 032	5,72%	5 102	4,22%	6 402	5,53%	6 998	6,29%	3 001	4,49%	2 648	4,02%	1 966	1,98%
RENAULT	5 129	3,88%	5 443	3,92%	2 707	2,22%	2 694	2,31%	2 667	2,35%	1 108	1,39%	1 747	2,72%	1 053	1,08%
VOLKSWAGEN	2 883	1,82%	3 591	2,57%	2 958	2,44%	3 846	3,62%	3 942	3,65%	1 105	1,39%	975	1,52%	1 889	1,90%
CHERY	499	0,37%	1 035	1,08%	1 854	1,52%	1 134	1,00%	1 117	0,97%	1 094	1,30%	879	1,38%	1 514	1,54%
JAC	496	0,37%	904	0,66%	1 086	0,90%	1 176	1,02%	1 314	1,19%	801	1,10%	727	0,91%	866	0,92%
CITROËN	315	0,24%	137	0,10%	179	0,14%	184	0,16%	483	0,38%	329	0,40%	189	0,29%	686	0,66%
mitsubishi	1 034	0,78%	983	0,71%	371	0,30%	454	0,39%	488	0,36%	855	0,31%	881	0,34%	468	0,47%
PEUGEOT	238	0,18%	348	0,25%	241	0,20%	182	0,16%	184	0,16%	148	0,18%	134	0,18%	481	0,48%
MERCEDES BENZ	481	0,34%	448	0,32%	357	0,27%	44	0,04%	235	0,28%	318	0,39%	216	0,34%	441	0,46%
FIAT	98	0,07%	88	0,06%	159	0,14%	908	0,45%	278	0,23%	235	0,29%	28	0,04%	398	0,34%
FAW	3	0,00%	-	0,00%	-	0,00%	-	0,00%	49	0,04%	298	0,25%	127	0,19%	399	0,39%
DFSK	-	0,00%	-	0,00%	-	0,00%	-	0,00%	268	0,04%	598	0,69%	371	0,56%	398	0,39%
BYD	138	0,10%	77	0,06%	140	0,12%	38	0,03%	299	0,26%	171	0,21%	108	0,16%	387	0,39%
FOTON	29	0,02%	20	0,01%	21	0,02%	48	0,04%	128	0,11%	78	0,09%	01	0,00%	291	0,28%
JEEP	71	0,05%	155	0,11%	237	0,20%	409	0,36%	443	0,37%	203	0,25%	152	0,24%	285	0,29%
LIAN	189	0,14%	288	0,21%	300	0,25%	73	0,06%	35	0,03%	149	0,18%	55	0,08%	247	0,24%
AUDI	111	0,08%	131	0,09%	190	0,15%	190	0,17%	181	0,16%	182	0,22%	134	0,21%	188	0,19%
HONDA	198	0,15%	214	0,15%	216	0,18%	171	0,15%	147	0,12%	121	0,15%	206	0,32%	171	0,18%
DONGFENG	98	0,07%	163	0,12%	90	0,07%	140	0,12%	203	0,18%	216	0,27%	155	0,23%	188	0,19%
BMW	203	0,15%	212	0,15%	192	0,15%	149	0,13%	150	0,12%	114	0,14%	98	0,15%	148	0,15%
FLUXO	-	0,00%	-	0,00%	-	0,00%	-	0,00%	-	0,00%	154	0,19%	148	0,19%	149	0,14%
SHODA	345	0,26%	647	0,48%	554	0,45%	525	0,45%	264	0,24%	100	0,12%	57	0,09%	110	0,11%
KENWORTH	271	0,21%	353	0,26%	480	0,40%	482	0,42%	472	0,39%	179	0,22%	66	0,09%	77	0,07%
GOLDEN DRAGON	-	0,00%	65	0,05%	52	0,04%	41	0,04%	2	0,00%	117	0,14%	98	0,15%	74	0,07%
INTERNATIONAL	168	0,13%	234	0,17%	263	0,22%	281	0,24%	186	0,16%	591	0,24%	67	0,11%	70	0,07%
JMC	43	0,03%	107	0,08%	133	0,10%	241	0,21%	106	0,09%	121	0,15%	30	0,05%	59	0,06%
FREIGHTLINER	419	0,31%	349	0,26%	276	0,22%	341	0,29%	279	0,22%	95	0,12%	17	0,00%	17	0,02%
BEBEN	-	0,00%	-	0,00%	-	0,00%	-	0,00%	52	0,04%	49	0,06%	5	0,01%	30	0,03%
UD TRUCKS	-	0,00%	-	0,00%	-	0,00%	-	0,00%	86	0,07%	78	0,10%	29	0,05%	26	0,03%
YUTONG	-	0,00%	64	0,04%	49	0,04%	36	0,03%	48	0,04%	48	0,06%	3	0,00%	20	0,02%
MANCK	171	0,13%	199	0,14%	309	0,24%	227	0,20%	100	0,08%	83	0,08%	17	0,03%	18	0,02%
Otras	2 071	1,57%	1 814	1,32%	1 891	1,32%	1 410	1,24%	798	0,68%	379	0,46%	827	1,00%	1 457	1,41%
Total	132 172	100%	138 893	100%	131 448	100%	113 813	100%	120 050	100%	81 309	100%	63 555	100%	105 077	100%

Figura 6.1 Venta anual de vehículos por marca.

Fuente: (Asociación de Empresas Automotrices del Ecuador)

6.1.2 Campo experimental.

6.1.2.1 Vehículos de prueba

Para la corrida del experimento se eligen las 3 marcas de vehículos más vendidos a nivel nacional. Para validar y constatar cuales son las marcas más vendidas en los últimos años, se toma los datos emitidos por AEADE desde el 2014 hasta el 2017 de la figura 6.1, donde se demuestra que las marcas de vehículos más vendidas en el Ecuador son: como líder se tiene la marca Chevrolet seguidas de Kia y Hyundai.

En la tabla 6.1 se muestra la cantidad y el porcentaje de ventas en los 4 últimos años de estas marcas de vehículos.

Tabla 6.1 Marca de vehículos de estudio.

Fuente: (Asociación de Empresas Automotrices del Ecuador)

Marca	2014	%	2015	%	2016	%	2017	%
Chevrolet	53.574	44,62	40.265	49,52	28.375	44,65	41.101	39,12
Kia	12.038	10,03	7.647	9,40	8.486	13,35	18.223	17,34
Hyundai	10.623	8,85	5.678	6,98	4.930	7,76	9.443	8,99

En la figura 6.2, se muestra las marcas de vehículos que serán utilizadas para la realización de la toma de datos para el presente proyecto, es decir, las marcas Chevrolet, Hyundai y Kia, con los cuales se procede a realizar el experimento. Además, se puede determinar el porcentaje de cada marca de vehículo que se va a utilizar en el estudio, la composición del porcentaje de Chevrolet es del 58% siendo el más numeroso respecto a las dos marcas pioneras Hyundai y Kia.

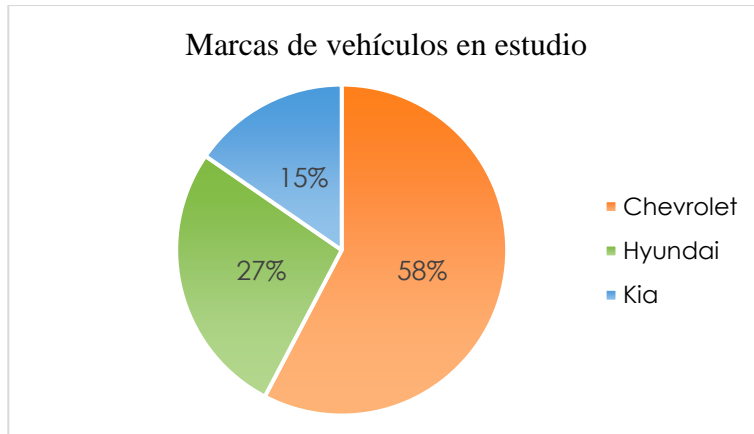


Figura 6.2 Porcentaje de las marcas de vehículos en estudio.

Fuente: Autores

En la figura 6.3, se muestra los modelos de vehículos que son utilizados para la realización de la toma de datos para el presente proyecto, entre ellos los modelos que poseen la composición del porcentaje más numerosa, es decir el Aveo Activo y Aveo Emotion con el 15% que pertenecen a la marca Chevrolet, también el modelo Cerato-Forte con el 11% que pertenece a la marca Kia y por último el modelo del Accent con el 11% que pertenece a la marca Hyundai con los cuales se procederá a realizar el experimento.




Figura 6.3 Porcentaje de los modelos de vehículos para el experimento

Fuente: Autores

La tabla 6.2 contiene breve información referente a los vehículos M1 en estudio de las marcas Chevrolet, Hyundai, Kia. Los datos que contiene la tabla demuestran que la Chevrolet abarca el mercado Automotriz como lo indica la AEADE.

Tabla 6.2. Vehículos M1 de estudio.

Fuente: Autores

Marca	Modelo	Año	Cilindrada	
Chevrolet	Aveo Activo	2008	1400	
		2011	1600	
		2011	1600	
	Aveo Emotion	2008	1600	
		2009	1600	
		2017	1600	
		2008	1600	
	Spark GT	2018	1200	
		2012	1500	
		Aveo Family	2015	1500
			2017	1500
		2018	1500	
	Sail	2017	1500	
		2017	1600	
		Chevitaxi	2006	1500
Hyundai	I 30	2014	1800	
		2005	1600	
	Getz	2005	1600	
		2010	1600	
	Accent	2005	1600	
		2014	1600	
		2017	1600	
Kia	Rio	2019	1400	
		2011	1600	
	Cerato Forte	2014	1600	
		2015	1600	

6.1.3 Planificación del experimento para la obtención de datos.

En este análisis se pretende reconocer patrones o datos característicos que mejor reflejen la condición de fallo en la que se encuentren los vehículos en estudio desde una base de datos obtenida mediante un dispositivo OBDII, necesario para el desarrollo de un algoritmo que detecta fallas en etapa temprana en los vehículos de categoría M1.

En el desarrollo de la corrida experimental existen factores que intervienen en el funcionamiento del motor, estos factores se clasifican en: variables de respuesta, variables de entrada, variables de bloqueo y variables de estudio.



Figura 6.4 Variables que intervienen en el diseño experimental.

Fuente: (Palacios Delgado & Pesántez Alvarez, 2016)

En la figura 6.5, se muestra el proceso de entrenamiento de la herramienta de aprendizaje y clasificación, que muestra como variables de entrada los sensores del vehículo como por ejemplo: los sensores MAP, IAT, TPS, O2, etc. Teniendo como resultado la repuesta del kilometraje actual y el kilometraje del último mantenimiento.

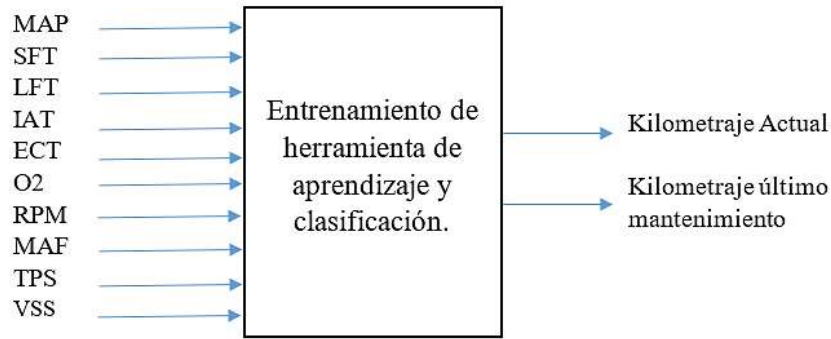


Figura 6.5 Proceso para el entrenamiento del SVM.

Fuente: Autores

En la figura 6.6, se muestra el proceso de entrenamiento del sistema, es decir a diferencia de la figura 6.5, se toma la obtención de los datos de entrenamiento invirtiendo las variables de entrada y salida.




Figura 6.6 Proceso para el entrenamiento del sistema montado.

Fuente: Autores

6.1.3.1 Variables de respuesta.

Estas variables representan el resultado de cada prueba que se realiza durante todo el proceso, lo que puede indicar características factibles que permita determinar un fallo en los motores. En la tabla 6.3 se muestran las variables de respuesta. (Gutiérrez Pulido & de la Vara Salazar, 2012)

Tabla 6.3 Variables de Respuesta.
Fuente: Autores

VARIABLES	UNIDAD
Kilometraje actual	[km]
Kilometraje del último mantenimiento	[km]

6.1.3.2 Variables de estudio.

También conocidas como variables de entrada son en la cual se enfoca todo el proceso de experimentación, respecto de cómo afectan a las variables de respuesta. La variación de estas variables no se afecta entre sí, es decir son independientes unas entre otras y se las deben seleccionar de manera que influyan o tengan un impacto directo sobre las variables de respuesta. (Gutiérrez Pulido & de la Vara Salazar, 2012)

Tabla 6.4 Variables de entrada
Fuente: Autores

VARIABLES	UNIDAD
Presión absoluta del colector	[kPa]
Ajustes de combustible	[%]
Sensor de oxígeno	[%]
Revoluciones del motor	[rpm]
Sensor de temperatura del motor	[°C]
Sensor de temperatura del aire	[°C]
Sensor de velocidad del vehículo	[km]
Sensor de posición de la mariposa	[%]

6.1.3.3 Variables de bloqueo.

Son las variables que se las pueden controlar durante el proceso del experimento fijándolas en un valor o nivel específico. (Gutiérrez Pulido & de la Vara Salazar, 2012)

Tabla 6.5 Variables de bloqueo.

Fuente: Autores

Variables	Unidad
Temperatura del motor	[°C]
Presión del neumático	[lb/plg ²]
Modelo de vehículo	

6.1.3.4 Variables de ruido.

Son variables que no se pueden controlar durante la experimentación debido a que se dan por factores ambientales, las mismas que afectaran a las variables de respuesta. (Gutiérrez Pulido & de la Vara Salazar, 2012)

Tabla 6.6 Variables de ruido.

Fuente: Autores

Variables	Unidad
Temperatura ambiente	[°C]
Presión atmosférica	[kPa]
Humedad relativa del aire	[%]
Régimen de giro del motor	[rpm]
Peso del vehículo	[ton]
Apertura de la mariposa	[%]
Velocidad del vehículo	[km/h]

6.1.4 Equipos utilizados en la toma de muestras.

6.1.4.1 Freematics.

El Freematics se comunica con el puerto OBDII de los vehículos y funciona como un dispositivo independiente, esto se debe al registro de datos que tiene acceso a la ECU del vehículo. Los datos recopilados pueden procesarse en tiempo real, almacenarse en una memoria

flash interna o tarjeta microSD y transmitirse a través de Bluetooth, Wifi o red celular. (Freematics, 2016)

Para la adquisición de datos se utiliza un dispositivo denominado Freematics que se muestra en la figura 6.7.



Figura 6.7 Dispositivo Freematics.

Fuente: Autores

Para la toma de adquisición de datos se utiliza el Freematics One +. Posee la capacidad de conectarse con vehículos de marcas americanas, japonesas, coreanas entre otras. La principal ventaja que emite el dispositivo Freematics es que posee un interfaz para conectarse con la computadora, que dispongan de un protocolo de comunicación OBD II, además, toma datos en tiempo real que luego son almacenados en una Micro SD interna que posee, para finalmente por medio de un programa realizado en el software de ingeniería Matlab® se pueda visualizar los datos.

Las variables que se obtienen mediante este equipo son las siguientes: Sensor de Presión Absoluta del Múltiple, Sensor de flujo de Masa de Aire, Sensor de Temperatura del Anticongelante del Motor, Sensor de Temperatura del Aire de Admisión, Sensor de Posición de

la Mariposa, Sensor de Revoluciones del Motor, Sensor de Oxígeno, Sensor de Velocidad del vehículo, Ajuste de Combustible Corto y Ajuste de combustible Largo.

Tabla 6.7 Características del Freematics One +.

Fuente: (Freematics, 2016)

Características	Descripción
Marca	Freematics
Modelo	One +
Espacio del programa	4 MB o 16 MB de Flash + 520 KB de RAM
Protocolo de comunicación	OBD-II, Bluetooth, Wifi
Almacenamiento de datos	MicroSD
Entorno de desarrollo	Plataforma IO, Arduino IDE, etc.
Características de la biblioteca	Acceso OBD-II / GPS / MEMS, creación de redes,
Arduino	almacenamiento de datos, servidor BLE GATT

6.1.4.2 *Sensor de Presión Absoluta de Múltiple (MAP).*

Este sensor capta la diferencia entre la presión externa (atmosférica) y la succión del múltiple, dado que es útil para la ECU, ya que permite calcular el combustible y tiempo de encendido.

(Concepción, 2010)



Figura 6.8 Sensor MAP

Fuente: Autores

6.1.4.3 *Sensor de Flujo de Masa de Aire (MAF).*

Este sensor de flujo de aire se encarga de informar a la ECU la presión atmosférica, en otros términos, mide el flujo de aire que ingresa al motor. (Kowienski, 2005)



Figura 6.9 Sensor MAF

Fuente: Autores

6.1.4.4 *Sensor de Temperatura del Anticongelante del Motor (ECT).*

Este sensor informa a la ECU la temperatura del líquido del refrigerante. Cuando el motor se encuentra frío, la resistencia del sensor aumenta caso contrario disminuye, es decir, cuando el motor se encuentra en temperatura de funcionamiento. (Kowienski, 2005)



Figura 6.10 Sensor ECT

Fuente: Autores

6.1.4.5 Sensor de Temperatura del Aire de Admisión (IAT).

El IAT es un termistor que posee una resistencia variable, cuando la temperatura del aire aumenta la resistencia del sensor disminuye, viceversa. Este sensor mide la temperatura del aire que está ingresando al interior de los cilindros del motor y su señal es utilizada para ajustar la cantidad de combustible para la inyección y el encendido del motor por medio de la ECU. (Acosta Sánchez & Veloz Lalaleo, 2017)



Figura 6.11 Sensor IAT

Fuente: Autores

6.1.4.6 Sensor de Posición de la Mariposa (TPS).

El sensor TPS tiene como principal función la de informar al Módulo de Control del Motor (ECM), la posición angular en la que se encuentra la mariposa del cuerpo de aceleración ubicada a la entrada del múltiple de admisión y es alimentado con 5 voltios.

La información que entrega este sensor es una señal que va desde los 0.5V (mariposa cerrada) a 4.5V (mariposa totalmente abierta), con esto la ECM realiza el cálculo del pulso de inyección de combustible, el avance del encendido del motor y el funcionamiento del sistema de control de emisiones. (Álvarez Pineda & Calle Calle, 2018)



Figura 6.12 Sensor TPS

Fuente: Autores

6.1.4.7 Sensor de Revoluciones del Motor (RPM).

El sensor de las RPM del motor sirve para detectar las revoluciones por minuto, además se encuentra fijado en el bloque motor y se encarga de informa a la ECU la posición del cigüeñal y la posición de los cilindros del motor para así generar la chispa, en cada una de las bujías. (Adrian, 2008)



Figura 6.13 Sensor de RPM

Fuente: Autores

6.1.4.8 *Sensor de Oxígeno (O2).*

Conocido también como sensor Lambda, en la mayoría de los vehículos está ubicado a la salida del múltiple de escape, mientras que en otros va instalado en el tubo de escape antes del convertidor catalítico (catalizador).

El sensor O2 es el encargado de medir los gases de escape específicamente la concentración de oxígeno existente en el humo de escape. Este sensor al detectar mayor cantidad de oxígeno en los gases manda una señal eléctrica a la ECM y esta se encarga de hacer correcciones en la mezcla aire-combustible, en este caso aumentando el tiempo de inyección para poder obtener una relación estequiométrica de 14:1. Cuando hay un nivel de oxígeno bajo, se ajusta la cantidad de combustible por ser mezcla rica lo que significa que hay mayor cantidad de combustible en la mezcla. (EMPRENTO CORP, 2018)



Figura 6.14 Sensor de Oxígeno (O2)

Fuente: Autores

6.1.4.9 *Sensor de Velocidad del vehículo (VSS).*

Este sensor se encuentra ubicado a la salida de la transmisión del motor, tiene como función transmitir información relativa de la velocidad a la ECU, también el sensor es de tipo “HALL” y

transmite 16 impulsos/giro, finalmente con esto muestra la velocidad del vehículo. (Kowienski, 2005)



Figura 6.15 Sensor VSS

Fuente: Autores

6.1.5 Sistema de adquisición de datos.

Para la adquisición de datos se tiene sensores del vehículo, dispositivo Freematics y una computadora con software programable, como se muestra en la figura 6.16. Como un dispositivo independiente y con alta velocidad, los datos recopilados pueden procesarse en tiempo real y almacenarse en una tarjeta microSD. En comparación con los sistemas tradicionales, este sistema es rápido, eficaz a la hora de adquirir y aprovechar la potencia de procesamiento de datos en tiempo real.

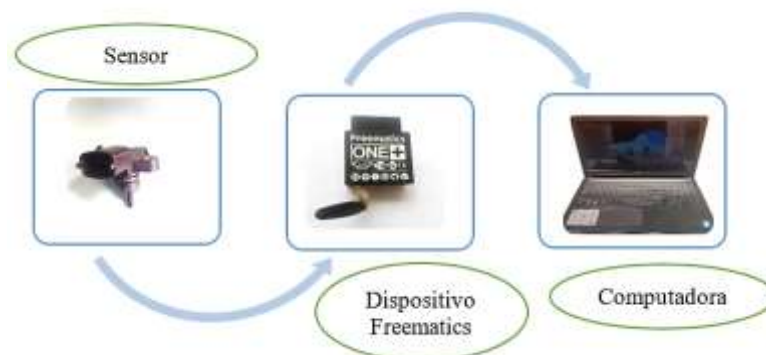


Figura 6.16 Sistema de adquisición de datos.

Fuente: Autores

6.1.5.1 *Protocolo de medición.*

Para garantizar la adquisición correcta de los datos se toma en cuenta el siguiente protocolo que se describe a continuación:

- Programación del dispositivo FREEMATICS para la adquisición de datos.
- Instalar el FREEMATICS en el puerto DLC del vehículo.
- Verificar que el led de color azul del FREEMATICS se encienda unos segundos.
- Fijar la antena de GPS del FREEMATICS sobre el tablero del vehículo.
- Encender el motor del vehículo.
- Esperar que el motor alcance su temperatura normal de funcionamiento (en caso de motor frío)
- Realizar un recorrido con el vehículo no menor a 5 minutos.
- Apagar el motor del vehículo.
- Esperar un tiempo aproximado de 30 segundos para desmontar el FREEMATICS.
- Extraer los datos almacenados en el FREEMATICS.
- Analizar los datos mediante métodos estadístico-multivariante.

6.1.5.2 *Extracción y visualización de datos*

Los datos o valores de las señales emitidas por los PID's de los diferentes sensores analizados se almacenan en una hoja de cálculo como se muestra en la figura 6.17, para su posterior análisis y esto sucede al momento de encender y apagar el motor del vehículo. Los datos almacenados en las hojas de cálculo no se encuentran organizados.

	A	B	C	D	E
1	0	93066			
2	0	97907			
3	10D	0			
4	10C	1130			
5	111	0			
6	105	37			
7	10F	32			
8	10B	31			
9	106	7			
10	107	1			
11	114	136			
12	20	-8	2	-103	
13	0	99389			
14	10D	0			
15	10C	993			
16	111	0			
17	105	38			
18	10F	32			
19	10B	32			
20	106	5			

Figura 6.17 Importación datos obtenidos con el Freematics One +
Fuente: Autores

Para visualizar los datos correctamente se utiliza un algoritmo desarrollado en Matlab® por (Gárate, 2018), el mismo que sirve para adquirir las señales PID's de los vehículos y permite organizar los datos correspondientes de cada sensor como se muestra en la figura 6.18, además, observar las gráficas representativas de los PID's que se detalla en la figura 6.19.




Figura 6.18 Visualización de datos de los PID's mediante software matemático.
Fuente: Autores

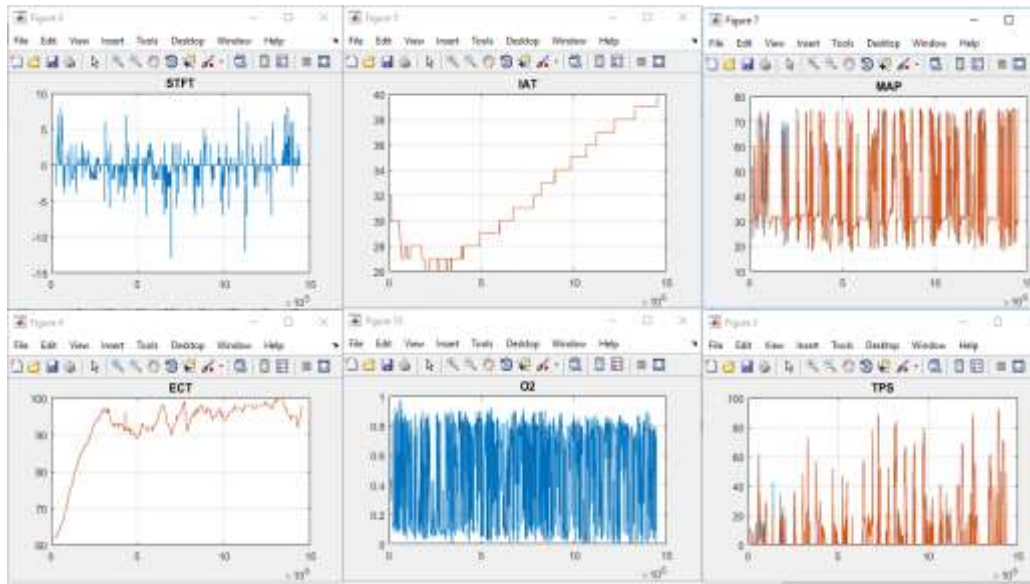


Figura 6.19 Visualización de PID's de los sensores.

Fuente: Autores

6.2 Aplicación de métodos estadísticos multivariante para el procesamiento de datos recolectados.

Para el procesamiento de los datos se aplica el método llamado Clusters (K' means) o de conglomerados para clasificar de modo óptimo todos los datos recolectados, los mismos que deben presentar ciertas características semejantes al grupo.

El Clusters debe ayudar a encontrar características o patrones importantes dentro de los conjuntos con el fin de hallar relaciones fuertes entre las variables que tengan un impacto directo sobre el resultado que se desea obtener.

6.2.1 Variables de entrada.

Los valores de los PID's en estado ralenti de los vehículos M1 representan las variables de entrada para el análisis.

6.2.2 Variables de salida.

La información adquirida del estado actual de los motores de los vehículos M1 basada en el kilometraje actual de recorrido de cada uno de ellos, para este análisis son las variables de salida.

6.2.3 Base de datos en estudio.

En la tabla 6.8 se muestra parte de la base de datos en estudio, que proporciona información con respecto al vehículo y valores emitidos de PID's de los sensores analizados.

Tabla 6.8. Extracto de la base de datos en estudio.

Fuente: Autores

Marca	Modelo	Año de fabricación	Kilometraje actual	Kilometraje (ultimo mantenimiento)	Cilindrada (cc)	Condición	RPM	MAP (kpa)	MAF	TPS (%)	ECT (C°)	VSS
Chevrolet	SPARK GT	2018	31434	28434	1200	Ralentí	674	51	0	11	105	0
Chevrolet	SPARK GT	2018	31434	28434	1200	Ralentí	674	51	0	11	105	0
Chevrolet	AVEO EMOTION	2009	240000	230000	1600	Ralentí	815	33	0	0	84	0
Chevrolet	AVEO EMOTION	2009	240000	230000	1600	Ralentí	815	33	0	0	84	0
Chevrolet	AVEO FAMILY	2018	12949	12000	1500	Ralentí	844	42	0	0	89	0
Chevrolet	AVEO FAMILY	2018	12949	12000	1500	Ralentí	844	42	0	0	89	0
Chevrolet	AVEO FAMILY	2012	444655	442592	1500	Ralentí	851	33	0	0	85	0
Kia	RIO	2019	22153	22153	1400	Ralentí	681	36	0	12	87	0
Kia	RIO	2019	22153	22153	1400	Ralentí	681	36	0	12	87	0
Chevrolet	AVEO EMOTION	2009	240000	230000	1600	Ralentí	818	34	0	0	89	0
Chevrolet	AVEO EMOTION	2009	240000	230000	1600	Ralentí	818	34	0	0	89	0
Chevrolet	AVEO EMOTION	2009	240000	230000	1600	Ralentí	826	34	0	0	90	0
Chevrolet	AVEO EMOTION	2009	240000	230000	1600	Ralentí	826	34	0	0	90	0
Kia	RIO	2019	22153	22153	1400	Ralentí	680	36	0	12	87	0
Kia	RIO	2019	22153	22153	1400	Ralentí	680	36	0	12	87	0
Kia	RIO	2019	22153	22153	1400	Ralentí	678	36	0	12	87	0
Kia	RIO	2019	22153	22153	1400	Ralentí	678	36	0	12	87	0
Chevrolet	AVEO ACTIVO	2011	120000	115000	1600	Ralentí	800	47	0	0	94	0
Chevrolet	AVEO FAMILY	2012	444655	442592	1500	Ralentí	797	33	0	0	93	0
Chevrolet	AVEO FAMILY	2012	444655	442592	1500	Ralentí	797	33	0	0	93	0
Kia	RIO	2019	22153	22153	1400	Ralentí	682	36	0	12	87	0
Kia	RIO	2019	22153	22153	1400	Ralentí	682	36	0	12	87	0
Chevrolet	AVEO EMOTION	2009	240000	230000	1600	Ralentí	812	34	0	0	90	0

6.2.4 Procesamiento de la base de datos.

En la base de datos adquiridos se empieza a dividir los datos del kilometraje actual y la diferencia de kilometraje del último de mantenimiento en 11 y 9 categorías respectivamente. Sobre el kilometraje actual se establece intervalos que van de 50000 en 50000 kilómetros y categorizados con letras mayúsculas como, por ejemplo: 0-50000 km con categoría A, 50000-100000 km con categoría B, etc., como se muestra en la tabla 6.9.

Tabla 6.9. División por categorías del kilometraje actual.

Fuente: Autores

Rango de kilometraje	Kilometraje actual	Categoría	Número de categoría
	12949		
0-50000	22153	A	1
	31434		
	34560		
50000-100000	62000	B	2
	86338		
100000-150000	114215	C	3
	120000		
	116999		
150000-200000	112530	D	4
	157200		
200000-250000	158583	E	5
	164476		
250000-300000	240000	F	6
	279282		
350000-400000	381403	H	7
	444655		
400000-450000	444655	I	8
	496939		
450000-500000	491630	J	9
	564200		
500000-550000	592000	L	10
	720516		
700000-750000	720320	O	11
	720320		

Además, en la tabla anterior se muestra como al rango de kilometraje se le es dividido por medio de categorías, tomando en cuenta el Kilometraje actual de cada vehículo.

En la tabla 6.10 se aprecian 9 categorías, las mismas que están designadas con letras dobles e iguales del abecedario. Las categorías van de menor a mayor desde AA hasta JJ con intervalos de 500 kilómetros a excepción de la primera categoría AA que integra vehículos que van desde los 0 km hasta los 1000 km .

Tabla 6.10 División por categorías del último período de mantenimiento.

Fuente: Autores

Kilometraje (último mantenimiento)	Diferencia	Categoría diferencia	Número de categoría
22153	0	AA	1
279150	0	AA	1
380914	500	AA	1
33560	1000	BB	2
12000	1000	BB	2
156500	1000	BB	2
156000	1500	CC	3
719214	1500	CC	3
84219	2000	DD	4
110530	2000	DD	4
442592	2000	DD	4
111715	2500	EE	5
28434	3000	FF	6
29350	3500	GG	7
493439	3500	GG	7
560700	3500	GG	7
588000	4000	HH	8
115000	5000	JJ	9
230000	5000	JJ	9
481520	5000	JJ	9
715320	5000	JJ	9

La clasificación de las categorías de la tabla anterior esta basada en el kilometraje del último mantenimiento, por ende esta clasificación abarca desde los 0 km hasta los 5000 km.

Para el procesamiento de la base de datos se utiliza un software matemático, donde la matriz de datos elaborada con las diferentes categorías es exportada hacia el software, como se muestra en la figura 6.20.

	A	B	C	D	E	F	G	H	I	J	K	L
	NUMEROD...	ALTURAm...	MARCA	MODELO	AODEFABR...	KILOMETR...	CATEGORI...	KILOMETR...	DIFERENCIA	CATEGORI...	CILINDRAD...	CONDICION
	Number	Number	Categorical	Categorical	Number	Number	Categorical	Number	Number	Categorical	Number	Categorical
1	NUMERO D...	ALTURA (m...	MARCA	MODELO	AÑO DE FA...	KILOMETR...	CATEGORI...	KILOMETR...	DIFERENCIA	CATEGORI...	CILINDRAD...	CONDICION
2	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
3	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
4	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
5	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
6	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
7	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
8	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
9	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
10	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
11	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
12	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
13	17	10	Kia	Rio	2019	22153	A	22153	0	AA	1400	Ralenti
14	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
15	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
16	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
17	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
18	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
19	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
20	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
21	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
22	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
23	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti
24	20	10	Hyundai	ACCENT	2014	279282	F	279150	0	AA	1600	Ralenti

Figura 6.20 Procesamiento de la base de datos en software matemático.

Fuente: Autores

6.2.5 Análisis de datos obtenidos mediante K’means.

A continuación, se generan vectores que contengan combinaciones de 2, 3 y 4 variables para el análisis, a su vez, la información de la base de datos es clasificada en 9 y 11 grupos para relacionar el análisis multivariante con las categorías de kilometraje del último mantenimiento y el kilometraje actual de recorrido de los vehículos M1.

Como resultado del análisis multivariante de cada vector, se obtiene un plano con coordenadas (X, Y), donde el eje X declara el kilometraje actual que tienen los vehículos en estudio y el eje Y son los períodos del último mantenimiento. Cada grupo será representado por un color diferente dentro del plano.

Para validar las agrupaciones que se generan como resultado del procesamiento de la base de datos, estas deben abarcar un grupo de puntos de un solo color lo más cercanos entre sí sobre el plano, además no tener más de un punto del mismo color fuera o distante del grupo, por otra parte, pueden existir más de una agrupación sobre el plano durante el análisis.

6.2.5.1 *Análisis de la categoría del kilometraje actual mediante K’means.*

- *Análisis con 3 y 4 vectores*

En la tabla 6.11, se muestra el resultado que se obtiene de las combinaciones de vectores luego del análisis realizado mediante K’means, el objetivo de este análisis es encontrar agrupaciones que demuestren que combinación o combinaciones otorgan información válida para el desarrollo del algoritmo.

Tabla 6.11 Combinación de 3 y 4 vectores

Fuente: Autores

Vectores	Número de agrupaciones
Rango, Ajuste de Combustible Largo, MAP, RPM.	1
Ajuste de combustible Largo, MAP, RPM.	1
Rango, Ajuste de combustible Largo, MAP	1

En la agrupación que se muestran en la figura 6.21 se realiza según los valores del rango de ajuste de combustible corto, la presión absoluta del múltiple, el ajuste de combustible largo y las

revoluciones en ralentí del motor. Se observan 3 puntos cercanos de color amarillo entre los 1000 a 1500 km del kilometraje del último período de mantenimiento, representando una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que esta categoría comprende vehículos que van desde los 10000 a 160000 kilómetros aproximadamente de su recorrido actual.




Figura 6.21 Análisis de 4 vectores: Rango, Ajuste de Combustible Largo, MAP, RPM.
Fuente: Autores

En la agrupación que se muestran en la figura 6.22 se realiza según los valores de ajuste de combustible largo, la presión absoluta del múltiple y las revoluciones en ralentí del motor. Se observan 3 puntos cercanos de color turquesa entre los 1000 a 1500 km de su último período de mantenimiento representando una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que esta categoría comprende vehículos que van desde los 10000 a 160000 kilómetros aproximadamente de su recorrido actual




Figura 6.22 Análisis de 3 vectores: Ajustes de Combustible de Largo, MAP, RPM.

Fuente: Autores

En la agrupación que se muestran en la figura 6.23 se realiza según los valores del rango de ajuste de combustible corto, la presión absoluta del múltiple y el ajuste de combustible largo. Se observan 3 puntos cercanos de color amarillo que se encuentran en los 1000 km de su último período de mantenimiento la misma que representa una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que esta categoría comprende vehículos que van desde los 10000 a 160000 kilómetros aproximadamente de su recorrido actual.




Figura 6.23 Análisis de 3 vectores: Rango, Ajustes de Combustible Largo, MAP.

Fuente: Autores

- **Análisis con 2 vectores.**

En la tabla 6.12, se muestra el número de agrupaciones obtenidas de las mejores combinaciones con dos vectores, demostrando así que el MAP y el Rango de los ajustes de combustible corto tiene dos agrupaciones.

Tabla 6.12 Combinación de 2 vectores.

Fuente: Autores

Vectores	Número de agrupaciones
Ajuste de Combustible Largo, MAP.	1
Rango, MAP.	2

En la agrupación que se muestran en la figura 6.24 se realiza según los valores de la presión absoluta del múltiple y el ajuste de combustible largo. Se observan 3 puntos cercanos de color amarillo que se encuentran en los 1000 km de su último período de mantenimiento la misma que representa una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que esta categoría comprende vehículos que van desde los 10000 a 160000 kilómetros aproximadamente de su recorrido actual.




Figura 6.24 Análisis de 2 vectores: Ajuste de Combustible de Largo, MAP.

Fuente: Autores

En las agrupaciones que se muestran en la figura 6.25 se realizan según los valores del rango de ajuste de combustible corto y la presión absoluta del múltiple. Se observan dos agrupaciones, una de ellas ubicada en los 1000 km de color amarillo y la segunda se encuentra entre los 2000 a 2500 km de color azul, estas agrupaciones representan el último período de mantenimiento la misma que representa una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que las dos categorías agrupadas comprenden vehículos que van desde los 20000 a 160000 kilómetros aproximadamente de su recorrido actual.




Figura 6.25 Análisis de 2 vectores: Rango, MAP

Fuente: Autores

6.2.5.2 Análisis del último mantenimiento mediante K'means.

- Análisis con 3 y 4 vectores.

La Tabla 6.13 contiene las combinaciones de vectores y el resultado de sus agrupaciones al ser analizados mediante K'means.

Tabla 6.13 Combinación de 3 y 4 vectores

Fuente: Autores

Vectores	Número de agrupaciones
Rango, Ajuste de Combustible Largo, MAP, RPM.	1
Ajuste de combustible Largo, MAP, RPM.	1
Rango, Ajuste de combustible Largo, MAP	1

En la agrupación que se muestran en la figura 6.26 se realiza según los valores del rango de ajuste de combustible corto, la presión absoluta del múltiple, el ajuste de combustible largo y las revoluciones en ralentí del motor. Se observan 3 puntos cercanos de color celeste entre los 1000 a 1500 km de su último período de mantenimiento representando una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que esta categoría comprende vehículos que van desde los 10000 a 160000 kilómetros aproximadamente de su recorrido actual




Figura 6.26 Análisis de 4 vectores: Rango, Ajuste de Combustible Largo, MAP, RPM.

Fuente: Autores

En la agrupación que se muestran en la figura 6.27 se realiza según los valores de ajuste de combustible largo, la presión absoluta del múltiple y las revoluciones en ralentí del motor. Se observan 4 puntos cercanos de color celeste entre los 1000 a 2000 km de su último período de

mantenimiento representando una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que esta categoría comprende vehículos que van desde los 10000 a 420000 kilómetros aproximadamente de su recorrido actual




Figura 6.27 Análisis de 3 vectores: Ajuste de Combustible Largo, MAP, RPM.
Fuente: Autores

En la agrupación que se muestran en la figura 6.28 se realiza según los valores del rango de ajuste de combustible corto, la presión absoluta del múltiple y el ajuste de combustible largo. Se observan 3 puntos cercanos de color turquesa que se encuentran en los 1000 km de su último período de mantenimiento la misma que representa una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que esta categoría comprende vehículos que van desde los 10000 a 160000 kilómetros aproximadamente de su recorrido actual.




Figura 6.28 Análisis de 3 vectores: Rango, Ajuste de Combustible Largo, MAP.

Fuente: Autores

- **Análisis con 2 vectores.**

En la tabla 6.14 se muestra el resultado de las combinaciones de vectores analizando valores del último mantenimiento mediante K’means.

Tabla 6.14 Combinación de 2 vectores

Fuente: Autores

Vectores	Número de agrupaciones
Ajuste de Combustible Largo, MAP.	1
Rango, MAP.	1

En la agrupación que se muestran en la figura 6.29 se realiza según los valores del rango de ajuste de combustible corto y el ajuste de combustible largo. Se observan 3 puntos cercanos de color azul que se encuentran en los 1000 km de su último período de mantenimiento la misma que representa una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que esta categoría comprende vehículos que van desde los 10000 a 160000 kilómetros aproximadamente de su recorrido actual.




Figura 6.29 Análisis de 2 vectores: Rango, Ajuste de Combustible Largo..

Fuente: Autores

En la agrupación que se muestran en la figura 6.30 se realiza según los valores del rango de ajuste de combustible corto, la presión absoluta del múltiple. Se observan 2 puntos cercanos de color amarillo que se encuentran en los 1000 km de su último período de mantenimiento la misma que representa una categoría de vehículos M1 con respecto al eje Y, y sobre el eje X se interpreta que esta categoría comprende vehículos que van desde los 10000 a 160000 kilómetros aproximadamente de su recorrido actual.




Figura 6.30 Análisis de 2 vectores: Rango, MAP.

Fuente: Autores

6.2.6 Fiabilidad de los valores obtenidos en el kilometraje del último mantenimiento.

En la figura 6.31, se interpreta un ejemplo entre la relación de la fiabilidad con los períodos de último mantenimiento de los vehículos M1 estudiados. En la figura se describe que en un lapso de 20000 kilómetros los períodos de mantenimiento están prolongados cada 5000 km lo que generalmente en la mayoría de los vehículos se da, además se observa como la fiabilidad es alta cuando se ha realizado el mantenimiento, y disminuye conforme aumenta el kilometraje recorrido del vehículo hasta la próxima revisión.

El resultado de todo los análisis mediante K-means como se explica en el capítulo anterior indican en su mayoría agrupaciones entre los 1000 a 1500 km del último período de mantenimiento, dando así que la fiabilidad de los vehículos es de 0,7 a 0,6.

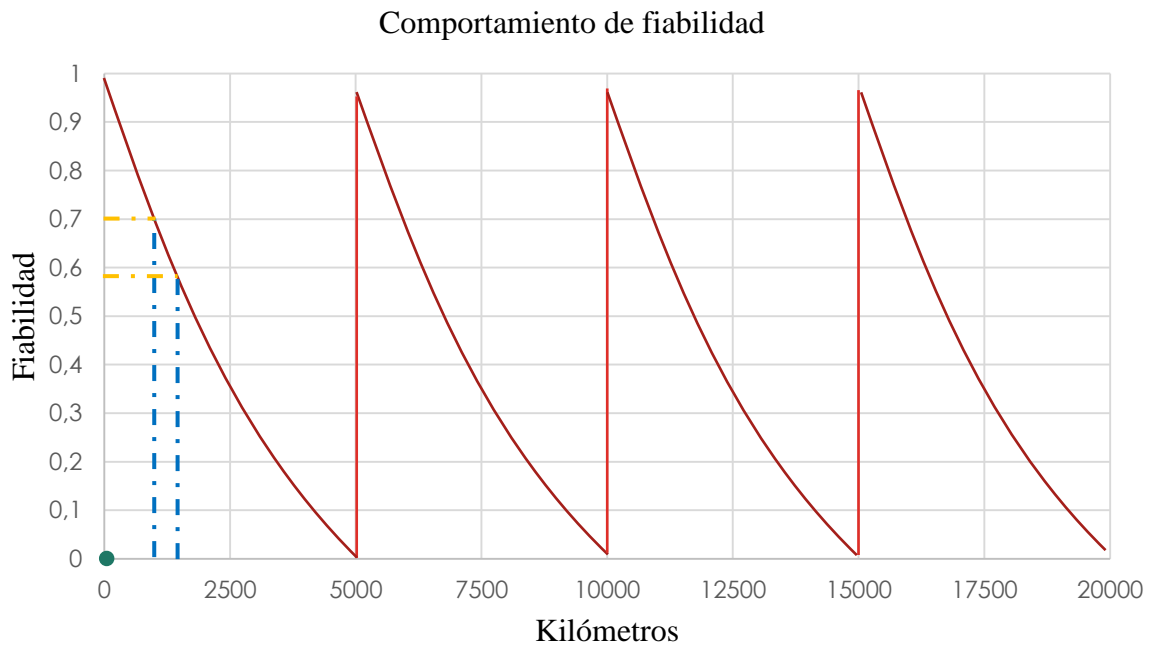


Figura 6.31 Relación de fiabilidad según los períodos de último mantenimiento de los vehículos en estudio.

Fuente: (Apolo Torres & Gordillo Rojas, 2017)

La figura 6.32 muestra las categorías del último mantenimiento según la fiabilidad de este, se observan 9 categorías siendo AA la de mayor fiabilidad debido que los vehículos recibieron mantenimiento recientemente, por otra parte, la categoría JJ tiene una fiabilidad muy baja por que se encuentra en los 5000 kilómetros que corresponde al período que debe recibir mantenimiento. En la tabla 6.10 se describe como esta categorizado el período de último mantenimiento de los vehículos de estudio.

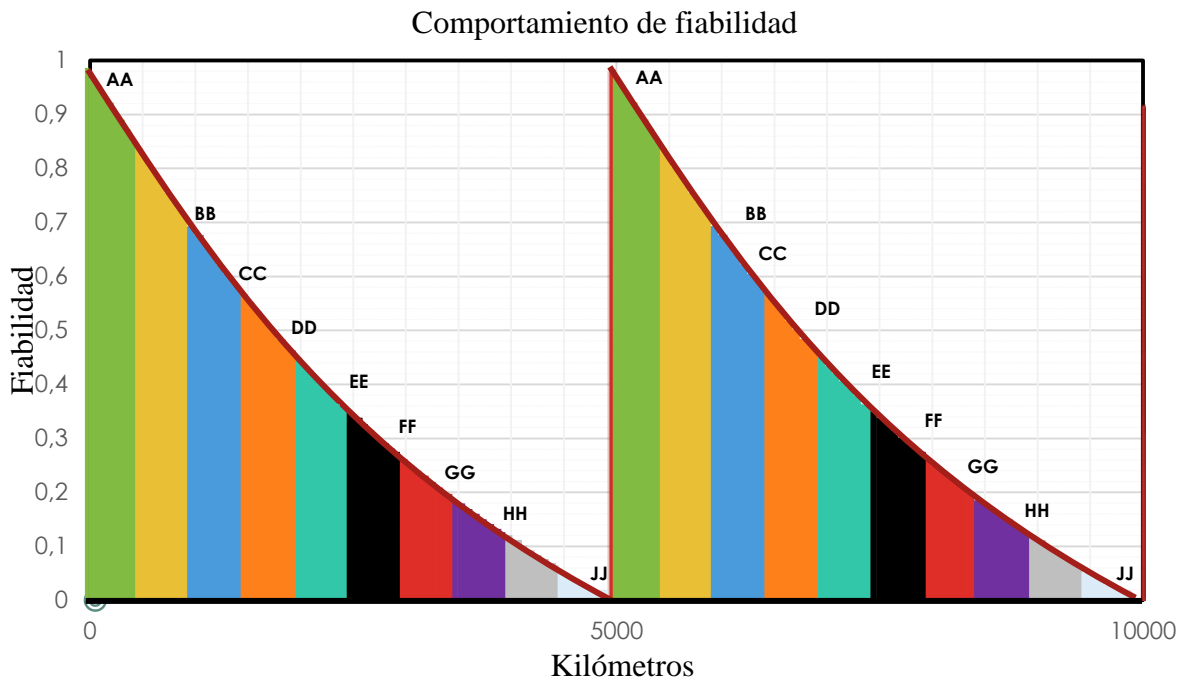


Figura 6.32 Relación de fiabilidad según las categorías de último mantenimiento de los vehículos en estudio.

Fuente: Autores

6.3 Desarrollo de un algoritmo mediante el análisis de aprendizaje automático para la detección de fallas en etapa temprana en motores de encendido provocado.

Se obtiene una base de datos previamente para entrenar mediante la herramienta de aprendizaje y clasificación de SVM, para ello se utiliza variables de predicción como: MAP, RPM, Ajuste de Combustible Corto, Ajuste de Combustible Largo, VSS, TPS, O2, con lo que se

contruye el modelo para obtener respuestas en función de las entradas asignadas como predictores, las repuestas que van a predecir son practicamente las categorías del kilometraje actual y las categorías en cuanto al kilometraje del último mantenimiento que es de ayuda en la programación de mantenimeinto para la detección de fallas en etapa temprana.

Se establece el 50 % como porcentaje de validación del SVM para obtener un buen resultado en la fiabilidad de la frontera de decisión obtenida (hiperplano que mejor separe el conjunto de datos).

En el proyecto se busca demostrar la validez que tienen la herramienta de aprendizaje y clasificación a traves de las SVM, para la predicción de las categorías de kilometraje y kilometraje del último mantenimiento.







6.3.1 Análisis de la categoría de kilometraje actual mediante SVM.

En el análisis mediante herramientas de apredizaje y clasificación se entrenan los datos obtenidos previamente, con ello establecer las variables de predicción y las de repuestas que se desea obtener, a continuación, las variable de predicción son las categorías del kilometraje y categorías en lo que se refiere al kilometraje del último mantenimiento. Como variables de entrada es necesario tomar como predictores en el estudio que establece la señal de funcionamiento de los sensores MAP, VSS, TPS, Ajustes de Combustibles, RPM y para las demas variables como Marca, Altura, número de vehículo, etc., se coloca no importar. En la figura 6.32 del apartado 6.3.1.1 se muestra la plataforma de selección de las variables de predicción y de repuestas.

En la tabla 6.15 se muestra las diferentes combinaciones de vectores para el análisis mediante herramientas de aprendizaje y clasificación

Tabla 6.15 Configuraciones de SVM con respecto al ajuste del kilometraje actual.

Fuente: Autores

N.-	Vectores	Tipo SVM	Simbología	Exactitud (%)
1	Rango SFT, Ajuste de Combustible Largo, MAP	Lineal		61.2%
2	Rango SFT, Ajuste de Combustible largo, MAP, RPM	Lineal		69.9%
3	Rango SFT, Ajuste de Combustible Largo, MAP, RPM, O2, TPS	Lineal		79.2%
4	Rango SFT, Ajuste de Combustible Largo, MAP	Gaussiano		99.6%
5	Rango SFT, Ajuste de Combustible largo, MAP, RPM	Gaussiano		99.2%
6	Rango SFT, Ajuste de Combustible Largo, MAP, RPM, O2, TPS	Cúbico		97.7 %

6.3.1.1 *Análisis de la categoría del kilometraje actual usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP)*

Para comenzar a aplicar la herramienta de aprendizaje y clasificación, se toma los predictores en el estudio y para las demás variables elegir “Do not import” (no importar) del menú desplegable tal como se muestra en la figura 6.33.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 - 26	Do not import
ALTURAMAX	double	4 - 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AÑOFABRICACION	double	2005 - 2015	Do not import
KILOMETRAJEACTUAL	double	12949 - 729516	Do not import
CATEGORIAKII	categorical	11 unique	Do not import
KILOMETRAJEultmem	double	12000 - 715214	Do not import
DIFERENCIA	double	0 - 5000	Do not import
CATEGORIAOF	categorical	5 unique	Do not import
CLINDRAGACC	double	1200 - 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 - 858	Do not import
MAP	double	21 - 49	Predictor
MAF	double	0 - 8	Do not import
TPS	double	0 - 14	Do not import
ECT	double	78 - 99	Do not import
VSS	double	0 - 0	Do not import
JAT	double	17 - 70	Do not import
SFTMAX	double	-2 - 6	Do not import
SFTMIN	double	-6 - 3	Do not import
RANGOSFT	double	0 - 8	Predictor
AJUSTELARGOALCA	double	-10 - 14	Predictor
O2	double	0.035 - 0.9	Do not import
VarName25	string	< unavailable >	Do not import

Figura 6.33 Selección de 5 predictores para el kilometraje actual.

Fuente: Autores

En las coordenadas paralelas de la figura 6.34, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones del kilometraje actual.

En este caso las variables normalizadas son 3, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto máximo, Ajuste de combustible Corto mínimo), MAP y el Ajuste de Combustible Largo.




Figura 6.34 Coordenadas paralelas para la predicción de las categorías del kilometraje actual.

Fuente: Autores

En la figura 6.35, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (MAP) y en “Y”(Rango SFT), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso tres, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 61.2% en Linear SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra “OK” o “CON DEFECTO”.

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción del kilometraje actual.

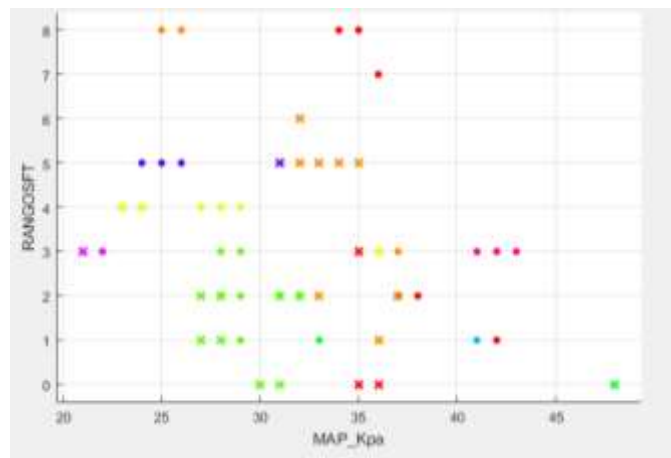


Figura 6.35 Diagrama de dispersión para predicción del kilometraje actual.

Fuente: Autores

6.3.1.2 Análisis de la categoría del kilometraje actual usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).

Para comenzar a aplicar la herramienta de aprendizaje y clasificación, se toma los predictores en el estudio y para las demás variables elegir “Do not import” (no importar) del menú desplegable tal como se muestra en la figura 6.36.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Response
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Do not import
CATEGORIADEF	categorical	9 unique	Do not import
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Predictor
MAP	double	21 .. 49	Predictor
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Do not import
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Do not import
IAT	double	17 .. 70	Do not import
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Predictor
AJUSTELARGOALCA...	double	-10 .. 14	Predictor
O2	double	0.035 .. 0.9	Do not import

Figura 6.36 Selección de 4 predictores para el kilometraje actual.

Fuente: Autores

En las coordenadas paralelas de la figura 6.37, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones del kilometraje actual.

En este caso las variables normalizadas son 4, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP y con un menor cambio significativo el Ajuste de Combustible Largo, mientras las líneas horizontales mas cercanas a la media no son de mayor importancia en el estudio, tal como las RPM.




Figura 6.37 Coordenadas paralelas para la predicción de las categorías del kilometraje actual.

Fuente: Autores

En la figura 6.38, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (RPM y en “Y”(MAP), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso cuatro, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 69.9% en Linear SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra “OK” o “CON DEFECTO”.

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción del kilometraje actual.




Figura 6.38 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.

Fuente: Autores

6.3.1.3 *Análisis de la categoría del kilometraje actual usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).*

Para comenzar a aplicar la herramienta de aprendizaje y clasificación, se toma los predictores en el estudio y para las demás variables elegir “Do not import” (no importar) del menú desplegable tal como se muestra en la figura 6.39.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Response
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Do not import
CATEGORIADIF	categorical	9 unique	Do not import
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Predictor
MAP	double	21 .. 49	Predictor
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Predictor
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Do not import
IAT	double	17 .. 70	Do not import
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Predictor
AJUSTELARGOALCA...	double	-10 .. 14	Predictor
O2	double	0.035 .. 0.9	Predictor

Figura 6.39 Selección de 6 predictores para el kilometraje actual.

Fuente: Autores

En las coordenadas paralelas de la figura 6.40, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones del kilometraje actual.

En este caso las variables normalizadas son 6, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP, el Ajuste de Combustible Largo, mientras las líneas horizontales mas cercanas a la media no son de mayor importancia en el estudio, tal como las RPM, TPS, O2.




Figura 6.40 Coordenadas paralelas para la predicción de las categorías del kilometraje actual.

Fuente: Autores

En la figura 6.41, se muestra un diagrama de dispersión con todos los puntos en las ubicaciones específicas por los vectores “X” (RPM) y en “Y”(MAP), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso seis, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 79.2% en Linear SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra "OK" o "CON DEFECTO".

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción del kilometraje actual.




Figura 6.41 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.

Fuente: Autores

6.3.1.4 *Análisis de la categoría del kilometraje actual usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP)*

Para comenzar a aplicar la herramienta de aprendizaje y clasificación, se toma los predictores en el estudio y para las demás variables elegir "Do not import" (no importar) del menú desplegable tal como se muestra en la figura 6.42.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 - 26	Do not import
ALTURAMAX	double	4 - 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
ANOFABRICACION	double	2005 - 2015	Do not import
KILOMETRAJEACTUAL	double	12949 - 729516	Do not import
CATEGORIAKIL	categorical	11 unique	Do not import
KILOMETRAJECUTMOM	double	12000 - 715214	Do not import
DIFERENCIA	double	0 - 5000	Do not import
CATEGORIADF	categorical	5 unique	Do not import
CLINDRAGACC	double	1200 - 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 - 858	Do not import
MAP	double	21 - 49	Predictor
MAF	double	0 - 5	Do not import
TPS	double	0 - 14	Do not import
ECT	double	78 - 99	Do not import
VSS	double	0 - 0	Do not import
IAT	double	17 - 70	Do not import
SFTMAX	double	-2 - 6	Do not import
SFTMIN	double	-6 - 3	Do not import
RANGOSFT	double	0 - 5	Predictor
AJUSTELARGOALCA	double	-10 - 14	Predictor
O2	double	0.035 - 0.9	Do not import
VarName25	string	< unavailable >	Do not import

Figura 6.42 Selección de 3 predictores para el kilometraje actual.

Fuente: Autores

En las coordenadas paralelas de la figura 6.43, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones del kilometraje actual.

En este caso las variables normalizadas son 3, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP y el Ajuste de Combustible Largo.




Figura 6.43 Coordenadas paralelas para la predicción de las categorías del kilometraje actual.

Fuente: Autores

En la figura 6.44, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (MAP) y en “Y”(Rango SFT), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso tres, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 99.6% en Fine Gaussian SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra “OK” o “CON DEFECTO”.

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción del kilometraje actual.




Figura 6.44 Diagrama de dispersión del ajuste del Rango SFT, en la predicción de las MAP.

Fuente: Autores

6.3.1.5 Análisis de la categoría del kilometraje actual usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM)

Para comenzar a aplicar la herramienta de aprendizaje y clasificación, se toma los predictores en el estudio y para las demás variables elegir “Do not import” (no importar) del menú desplegable tal como se muestra en la figura 6.45.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Response
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Do not import
CATEGORIADEF	categorical	9 unique	Do not import
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Predictor
MAP	double	21 .. 49	Predictor
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Do not import
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Do not import
IAT	double	17 .. 70	Do not import
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Predictor
AJUSTELARGOALCA...	double	-10 .. 14	Predictor
O2	double	0.035 .. 0.9	Do not import

Figura 6.45 Selección de 4 predictores para el kilometraje actual.

Fuente: Autores

En las coordenadas paralelas de la figura 6.46, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones del kilometraje actual.

En este caso las variables normalizadas son 4, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP, el Ajuste de Combustible Largo, mientras las líneas horizontales mas cercana a la media no son de mayor importancia en el estudio, tal como las RPM.




Figura 6.46 Coordenadas paralelas para la predicción de las categorías del kilometraje actual.

Fuente: Autores

En la figura 6.47, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (RPM) y en “Y”(MAP), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso cuatro, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 99.2% en Fine Gaussian SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra “OK” o “CON DEFECTO”.

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción del kilometraje actual.




Figura 6.47 Diagrama de dispersión del ajuste del MAP, en la predicción de las RPM.

Fuente: Autores

6.3.1.6 *Análisis de la categoría del kilometraje actual usando siete vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS)*

Para comenzar a aplicar la herramienta de aprendizaje y clasificación, se toma los predictores en el estudio y para las demás variables elegir “Do not import” (no importar) del menú desplegable tal como se muestra en la figura 6.48.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Response
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Do not import
CATEGORIADIF	categorical	9 unique	Do not import
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Predictor
MAP	double	21 .. 49	Predictor
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Predictor
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Do not import
IAT	double	17 .. 70	Do not import
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Predictor
AJUSTELARGOALCA...	double	-10 .. 14	Predictor
O2	double	0.035 .. 0.9	Predictor

Figura 6.48 Selección de 6 predictores para el kilometraje actual.

Fuente: Autores

En las coordenadas paralelas de la figura 6.49, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones del kilometraje actual.

En este caso las variables normalizadas son 6, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP, el Ajuste de Combustible Largo, mientras las líneas horizontales mas cercanas a la media no son de mayor importancia en el estudio, tal como las RPM, TPS, O2.




Figura 6.49 Coordenadas paralelas para la predicción de las categorías del kilometraje actual.

Fuente: Autores

En la figura 6.50, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (RPM) y en “Y”(MAP), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso seis, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 97.7% en Cubic SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra "OK" o "CON DEFECTO".

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción del kilometraje actual.




Figura 6.50 Diagrama de dispersión del MAP en la predicción de las RPM.







Fuente: Autores

6.3.2 Análisis de la categoría de kilometraje del último mantenimiento mediante SVM.

En la tabla 6.16, se muestra las diferentes combinaciones de vectores para el análisis mediante herramientas de aprendizaje y clasificación

Tabla 6.16. Configuración SVM con respecto al ajuste del último mantenimiento

Fuente: Autores

N.-	Vectores	Tipo SVM	Simbología	Exactitud (%)
1	Rango SFT, Ajuste de Combustible Largo, MAP	Lineal		61.9%
2	Rango SFT, Ajuste de Combustible largo, MAP, RPM	Lineal		64.6%
3	Rango SFT, Ajuste de Combustible Largo, MAP, RPM, O2, TPS	Lineal		71.2%
4	Rango SFT, Ajuste de Combustible Largo, MAP	Gaussiano		99.2%
5	Rango SFT, Ajuste de Combustible largo, MAP, RPM	Gaussiano		99.2%
6	Rango SFT, Ajuste de Combustible Largo, MAP, RPM, O2, TPS	Cúbico		98.5 %

6.3.2.1 Análisis de la categoría de kilometraje del último mantenimiento al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP)

En las coordenadas paralelas de la figura 6.51, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones para el kilometraje del último mantenimiento.

En este caso las variables normalizadas son 3, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP y el Ajuste de Combustible Largo.




Figura 6.51 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

En la figura 6.52, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (MAP) y en “Y”(Rango SFT), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso tres, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 61.9 % en Linear SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra “OK” o “CON DEFECTO”.

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción para el kilometraje del último mantenimiento.




Figura 6.52 Diagrama de dispersión del ajuste del Rango SFT en la predicción del MAP.

Fuente: Autores

6.3.2.2 *Análisis de la categoría de kilometraje del último mantenimiento usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM)*

En las coordenadas paralelas de la figura 6.53, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones para el kilometraje del último mantenimiento.

En este caso las variables normalizadas son 4, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP, el Ajuste de Combustible Largo, mientras las líneas horizontales mas cercana a la media no son de mayor importancia en el estudio, tal como las RPM.




Figura 6.53 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

En la figura 6.54, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (RPM) y en “Y”(MAP), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso cuatro, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 64.6 % en Linear SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra “OK” o “CON DEFECTO”.

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción para el kilometraje del último mantenimiento.




Figura 6.54 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.

Fuente: Autores

6.3.2.3 *Análisis de la categoría de kilometraje del último mantenimiento usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS)*

En las coordenadas paralelas de la figura 6.55, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones para el kilometraje del último mantenimiento.

En este caso las variables normalizadas son 6, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP, el Ajuste de Combustible Largo, mientras las líneas horizontales mas cercana a la media no son de mayor importancia en el estudio, tal como las RPM, TPS, O2.




Figura 6.55 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

En la figura 6.56, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (RPM) y en “Y”(MAP), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso seis, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 71.2 % en Linear SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra “OK” o “CON DEFECTO”.

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción para el kilometraje del último mantenimiento.




Figura 6.56 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM

Fuente: Autores

6.3.2.4 *Análisis de la categoría del último mantenimiento al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP)*

Para comenzar a aplicar la herramienta de aprendizaje y clasificación, se toma los predictores en el estudio y para las demás variables elegir “Do not import” (no importar) del menú desplegable tal como se muestra en la figura 6.57.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Do not import
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Do not import
CATEGORIADIF	categorical	9 unique	Response
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Do not import
MAP	double	21 .. 49	Predictor
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Do not import
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Do not import
IAT	double	17 .. 70	Do not import
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Predictor
AJUSTELARGOALCA...	double	-10 .. 14	Predictor
O2	double	0.035 .. 0.9	Do not import

Figura 6.57 Selección de 3 predictores para el kilometraje actual.

Fuente: Autores

En las coordenadas paralelas de la figura 6.58, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones para el kilometraje del último mantenimiento.

En este caso las variables normalizadas son 3, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP y el Ajuste de Combustible Largo.




Figura 6.58 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

En la figura 6.59, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (MAP) y en “Y”(Rango SFT), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso tres, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 99.2 % en Fine Gaussian SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen

al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra "OK" o "CON DEFECTO".

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción para el kilometraje del último mantenimiento.




Figura 6.59 Diagrama de dispersión del ajuste del Rango SFT en la predicción del MAP.

Fuente: Autores

6.3.2.5 *Análisis de la categoría de kilometraje del último mantenimiento usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM)*

Para comenzar a aplicar la herramienta de aprendizaje y clasificación, se toma los predictores en el estudio y para las demás variables elegir "Do not import" (no importar) del menú desplegable tal como se muestra en la figura 6.60.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Do not import
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Do not import
CATEGORIADIF	categorical	9 unique	Response
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Predictor
MAP	double	21 .. 49	Predictor
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Do not import
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Do not import
IAT	double	17 .. 70	Do not import
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Predictor
AJUSTELARGOALCA...	double	-10 .. 14	Predictor
O2	double	0.035 .. 0.9	Do not import

Figura 6.60 Selección de 4 predictores para el kilometraje actual.

Fuente: Autor

En las coordenadas paralelas de la figura 6.61 se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones para el kilometraje del último mantenimiento.

En este caso las variables normalizadas son 4, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP, el Ajuste de Combustible Largo, mientras las líneas horizontales mas cercana a la media no son de mayor importancia en el estudio, tal como las RPM.




Figura 6.61 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

En la figura 6.62, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (RPM) y en “Y”(MAP), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso cuatro, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 99.2% en Fine Gaussian SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra “OK” o “CON DEFECTO”.

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción para el kilometraje del último mantenimiento.




Figura 6.62 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.

Fuente: Autores

6.3.2.6 *Análisis de la categoría del último mantenimiento usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS)*

Para comenzar a aplicar la herramienta de aprendizaje y clasificación, se toma los predictores en el estudio y para las demás variables elegir “Do not import” (no importar) del menú desplegable tal como se muestra en la figura 6.63.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Do not import
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Do not import
CATEGORIADIF	categorical	9 unique	Response
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Predictor
MAP	double	21 .. 49	Predictor
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Predictor
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Do not import
IAT	double	17 .. 70	Do not import
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Predictor
AJUSTELARGOALCA...	double	-10 .. 14	Predictor
O2	double	0.035 .. 0.9	Predictor

Figura 6.63 Selección de 6 predictores para el kilometraje actual.

Fuente: Autores

En las coordenadas paralelas de la figura 6.64, se indican la visualización de datos de alta dimensión, en el eje vertical se representa las predicciones para el kilometraje del último mantenimiento.

En este caso las variables normalizadas son 6, las líneas que se encuentran con mayor distancia de la media (mean) indican que tienen una mayor inferencia en los resultados, como por ejemplo en este caso las variables que influyen más es el Rango SFT (Ajuste de Combustible Corto Máximo, Ajuste de combustible Corto Mínimo), MAP, el Ajuste de Combustible Largo, mientras las líneas horizontales mas cercanas a la media no son de mayor importancia en el estudio, tal como las RPM, TPS, O2.




Figura 6.64 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

En la figura 6.65, se muestra un diagrama de dispersión con todo los puntos en las ubicaciones específicas por los vectores “X” (RPM) y en “Y”(MAP), como se aprecia en la figura que cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina su posición en el eje vertical y con variedad de colores que muestran las distintas clases que existen, en este caso seis, esto se realiza al momento de entrenar la herramienta de aprendizaje y clasificación.

La fiabilidad en este caso es del 98.5 % en Cubic SVM, la gráfica que tienen puntos de colores son valores acertados y por el contrario las que se marca con X son errores que surgen al entrenar las herramientas de aprendizaje y clasificación, dichos errores son de poca relevancia, además permite clasificar las fallas y con ello poder diferenciar el motor de combustión interna si se encuentra "OK" o "CON DEFECTO".

Para separar estos datos se cuenta con 2 dimensiones para posteriormente crear un hiperplano que se adecúe a cada uno de los distintos datos obtenidos para conseguir la mayor fiabilidad y poder hacer la predicción para el kilometraje del último mantenimiento.




Figura 6.65 Diagrama de dispersión del ajuste del MAP en la predicción de las RPM.

Fuente: Autores

6.4 Análisis de los resultados obtenidos mediante métodos estadísticos multivariante para la validación del algoritmo desarrollado

En el presente proyecto se busca demostrar la efectividad de la relación del kilometraje actual y el kilometraje del último mantenimiento y la validez de la clasificación de los datos.

En primer lugar, se definen las variables que se ingresara tanto para el caso del kilometraje actual y el caso para el kilometraje del último mantenimiento, ya que existen diversos porcentajes exactitud respecto al análisis de la herramienta de clasificación.

6.4.1 Validación del Modelo Matemático a través de un software de ingeniería.

Para la validación se lleva a cabo ingresando al algoritmo datos de vehículos nuevos para las muestras de entrenamiento, se obtienen las nuevas muestras mediante la adquisición de datos obtenidos por el FREEMATICS.

En la tabla 6.17, se muestra el número de las variables y el porcentaje resultante de predicción con respecto al kilometraje actual.

Tabla 6.17 Extracto de los resultados de la predicción del kilometraje actual.

Fuente: Autores

Categorías	Rango SFT-LFT- MAP-RPM-TPS O2 97,7 %	Rango SFT-LFT- MAP-RPM-TPS O2 79,2 %	Rango SFT-LFT- MAP-RPM 99,2%	Rango SFT-LFT- MAP-RPM 69,6%	Rango SFT-LFT- MAP 99,6%	Rango SFT-LFT- MAP 61,2%
Real	Predicción					
C	'C'	'B'	'C'	'B'	'C'	'H'
C	'C'	'B'	'C'	'B'	'C'	'H'
C	'C'	'B'	'C'	'B'	'C'	'B'
L	'D'	'L'	'C'	'L'	'C'	'L'
L	'L'	'C'	'C'	'L'	'C'	'L'
L	'L'	'C'	'C'	'L'	'C'	'L'
B	'B'	'B'	'B'	'B'	'B'	'B'
B	'B'	'B'	'B'	'B'	'B'	'B'
B	'B'	'B'	'B'	'B'	'B'	'B'
A	'A'	'A'	'A'	'D'	'A'	'D'
A	'A'	'B'	'A'	'D'	'A'	'D'
C	'A'	'A'	'C'	'A'	'C'	'A'
A	'A'	'A'	'A'	'A'	'A'	'A'
A	'A'	'A'	'A'	'A'	'A'	'A'
A	'A'	'A'	'A'	'A'	'A'	'A'
A	'A'	'A'	'A'	'A'	'A'	'A'
A	'A'	'A'	'A'	'A'	'A'	'A'
A	'A'	'A'	'A'	'A'	'A'	'A'
C	'D'	'C'	'C'	'C'	'C'	'C'
C	'D'	'C'	'C'	'C'	'C'	'C'
C	'D'	'D'	'C'	'C'	'C'	'C'
O	'H'	'H'	'C'	'H'	'C'	'H'
O	'H'	'H'	'C'	'H'	'C'	'H'
O	'H'	'H'	'C'	'H'	'C'	'H'
L	'L'	'L'	'L'	'L'	'L'	'L'

En la tabla 6.18, se muestra el número de las variables y el porcentaje resultante de predicción con respecto al kilometraje del último mantenimiento.

Tabla 6.18 Extracto de los resultados de la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

Categorías	Rango SFT-LFGT-MAP 99,2%	Rango SFT-LFT-MAP 61,2%	Rango SFT-LFT-MAP-RPM 99,2%	Rango SFT-LFT-MAP-RPM 64,6%	Rango SFT-LFT-MAP-RPM-TPS 02 98,5%	Rango SFT-LFT-MAP-RPM-TPS 02 71,2%
Real	Predicción					
JJ	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'	'DD'
JJ	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'	'DD'
JJ	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'
JJ	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'
JJ	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'
HH	'DD'	'DD'	'HH'	'DD'	'HH'	'HH'
HH	'DD'	'DD'	'HH'	'DD'	'HH'	'HH'
HH	'DD'	'DD'	'HH'	'DD'	'HH'	'HH'
HH	'DD'	'DD'	'HH'	'DD'	'HH'	'HH'
HH	'DD'	'DD'	'HH'	'DD'	'HH'	'HH'
BB	'BB'	'HH'	'BB'	'BB'	'BB'	'BB'
BB	'BB'	'HH'	'BB'	'BB'	'BB'	'BB'
BB	'BB'	'HH'	'BB'	'BB'	'BB'	'BB'
BB	'BB'	'HH'	'BB'	'BB'	'BB'	'BB'
BB	'BB'	'HH'	'BB'	'BB'	'BB'	'BB'
GG	'JJ'	'JJ'	'GG'	'JJ'	'GG'	'JJ'
GG	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'
GG	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'	'JJ'
GG	'DD'	'DD'	'JJ'	'JJ'	'JJ'	'JJ'
GG	'DD'	'DD'	'JJ'	'JJ'	'JJ'	'JJ'
CC	'CC'	'CC'	'CC'	'CC'	'CC'	'CC'
CC	'CC'	'CC'	'CC'	'CC'	'CC'	'CC'
CC	'CC'	'CC'	'CC'	'CC'	'CC'	'CC'
CC	'CC'	'CC'	'CC'	'CC'	'CC'	'CC'
CC	'CC'	'CC'	'CC'	'CC'	'CC'	'CC'

En la tabla 6.19, se muestra el número de muestra verdadera y predicha, en la cual se ingresa 130 datos y como resultados de exactitudes mayores de predicción para el kilometraje actual es

del 68% y para el kilometraje del último mantenimiento es del 85% como se muestra en la tabla 6.19 y 6.20, teniendo de error el 32% y 15% respectivamente.

Tabla 6.19 Resultados porcentuales de la validación del algoritmo en la predicción del kilometraje actual.

Fuente: Autores

N.-	Vectores	Tipo SVM	Exactitud (%) Predicha	Exactitud (%) Verdadera
1	Rango, Ajuste de Combustible Largo, MAP	Lineal	61.2%	51.5%
2	Rango SFT, Ajuste de Combustible largo, MAP, RPM	Lineal	69.9%	60.7%
3	Rango, Ajuste de Combustible Largo, MAP, RPM, O2, TPS	Lineal	79.2%	55.3%
4	Rango, Ajuste de Combustible Largo, MAP	Gaussiano	99.6%	67.6%
5	Rango SFT, Ajuste de Combustible largo, MAP, RPM	Gaussiano	99.2%	63.8%
6	Rango, Ajuste de Combustible Largo, MAP, RPM, O2, TPS	Cúbico	97.7 %	65.3 %

Tabla 6.20 Resultados porcentuales de la validación del algoritmo en la predicción para el kilometraje del último mantenimiento.

Fuente: Autor

N.-	Vectores	Tipo SVM	Exactitud (%) Predicha	Exactitud (%) Verdadera
1	Rango, Ajuste de Combustible Largo, MAP	Lineal	60.0%	50.0%
2	Rango SFT, Ajuste de Combustible largo, MAP, RPM	Lineal	69.2%	64.6%
3	Rango, Ajuste de Combustible Largo, MAP, RPM, O2, TPS, VSS	Lineal	82.7%	73.0%
4	Rango, Ajuste de Combustible Largo, MAP	Gaussian o	100.0%	53.8%
5	Rango SFT, Ajuste de Combustible largo, MAP, RPM	Gaussian o	98.5%	85.3%
6	Rango, Ajuste de Combustible Largo, MAP, RPM, O2, TPS, VSS	Cúbico	98.8 %	80.7 %

6.4.1.1 *Análisis del kilometraje actual al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP).*

En la figura 6.66, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM

predijo correctamente, las celdas fuera de la diagonal que se encuentren de color rojo muestran los errores en la predicción, como por ejemplo en este caso el clasificador a cometido varios errores, ya que existen muestras que se aprecian fuera de la diagonal de la matriz de confusión.

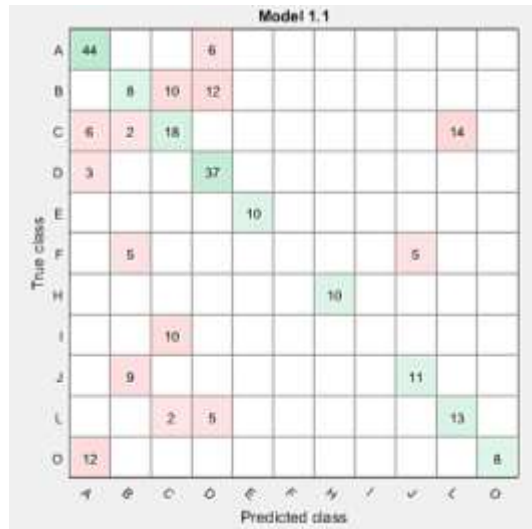


Figura 6.66 Matriz de confusión del kilometraje actual.

Fuente: Autores

La figura 6.67, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM tienen gran parte de similitud al aplicarlos a pesar que el análisis de la combinación del Rango de ajuste de combustible corto, el MAP y los Ajustes de Combustible Largo entreguen muchas predicciones erróneas, en este caso el número de errores que presentan las dos matrices son iguales, sin embargo se observa que los errores por categorías tienen variación. De igual manera la predicción de las categorías acertadas son las mismas.

Kilometraje real	A	20			5									
	B		5		5			5						
	C	5	3	7				2				3		
	D			5	10									5
	E		5											
	F									5				
	H							5						
	I			5										
	J			5						5				
	L											10		
	O								5					5
		A	B	C	D	E	F	H	I	J	L	O		
	Kilometraje predicho													

Figura 6.67 Matriz de confusión para la predicción del kilometraje actual.

Fuente: Autores

6.4.1.2 *Análisis del kilometraje actual usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).*

En la figura 6.68, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal que se encuentren de color rojo muestran los errores en la predicción, como por ejemplo en este caso el clasificador a cometido varios errores, ya que existen muestras que se aprecian fuera de la diagonal de la matriz de confusión.

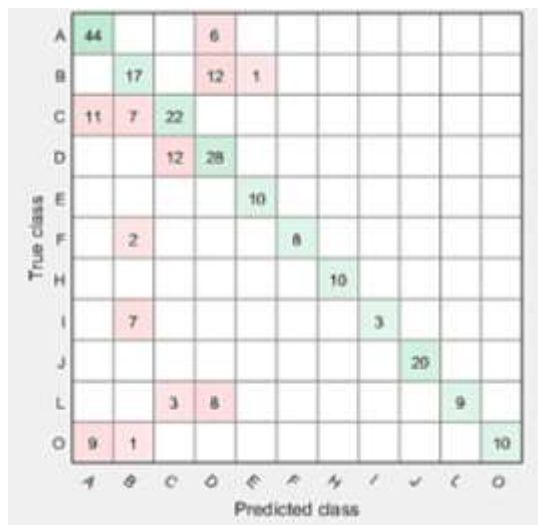


Figura 6.68 Matriz de confusión del kilometraje actual.

Fuente: Autores

La figura 6.69, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM en el análisis de la combinación del Rango de ajuste de combustible corto, el MAP, los Ajustes de Combustible Largo y las RPM del motor no tienen similitud al aplicarlo, generando predicciones erróneas como se observa. El número de errores que presentan las dos matrices no son iguales, de igual manera la predicción de las categorías acertadas no coinciden en cierta parte en ambas matrices.

Kilometraje real	A	20		5	5								
	B		10	5	5								
	C			10									
	D			5	10				2	3			
	E		5	5									
	F		1				4						
	H							5					
	I		3	2									
	J			5					5				
	L										10		
	O							5				5	
			A	B	C	D	E	F	H	I	J	L	O
			Kilometraje predicho										

Figura 6.69 Matriz de confusión para la predicción del kilometraje actual.

Fuente: Autores

6.4.1.3 *Análisis del kilometraje actual usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).*

En la figura 6.70, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal que se encuentren de color rojo muestran los errores en la predicción, como por ejemplo en este caso el clasificador a cometido varios errores, ya que existen muestras que se aprecian fuera de la diagonal de la matriz de confusión.




Figura 6.70 Matriz de confusión del kilometraje actual.

Fuente: Autores

La figura 6.71, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM en el análisis de la combinación del Rango de ajuste de combustible corto, el MAP, los Ajustes de Combustible Largo, las RPM del motor, el O2 y el TPS no tienen similitud al aplicarlo, generando predicciones erróneas como se observa. El número de errores que presentan las dos matrices no son iguales, de igual manera la predicción de las categorías acertadas no coinciden en cierta parte en ambas matrices.

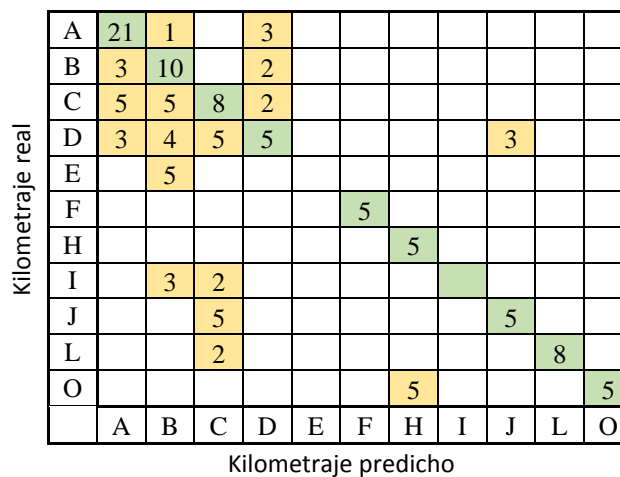


Figura 6.71 Matriz de confusión para la predicción del kilometraje actual.

Fuente: Autores

6.4.1.4 *Análisis del kilometraje actual al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP)*

En la figura 6.72, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal en el caso que se encuentren de color rojo muestran los errores que cometieron en la predicción.




Figura 6.72 Matriz de confusión del kilometraje actual.

Fuente: Autores

La figura 6.73, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM en el análisis de la combinación del Rango de ajuste de combustible corto, el MAP, los Ajustes de Combustible Largo, no tienen similitud al aplicarlo, generando predicciones erróneas como se observa. El número de errores que presentan las dos matrices no son iguales, de igual manera la predicción de las categorías acertadas no coinciden en cierta parte en ambas matrices.

Kilometraje real	A	23		2								
	B		10	5								
	C			20								
	D			5	10							5
	E			5								
	F					5						
	H						5					
	I			5								
	J			5					5			
	L			5						5		
	O			5								5
	A	B	C	D	E	F	H	I	J	L	O	
		Kilometraje predicho										

Figura 6.73 Matriz de confusión para la predicción del kilometraje actual.

Fuente: Autores

6.4.1.5 *Análisis del kilometraje actual usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).*

En la figura 6.74, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha, además las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente y las celdas fuera de la diagonal en el caso que se encuentren de color rojo muestran los errores que cometieron en la predicción.




Figura 6.74 Matriz de confusión del kilometraje actual.

Fuente: Autores

La figura 6.75, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM en el análisis de la combinación del Rango de ajuste de combustible corto, el MAP, los Ajustes de Combustible Largo, las RPM del motor, no tienen similitud al aplicarlo, generando predicciones erróneas como se observa. El número de errores que presentan las dos matrices no son iguales, de igual manera la predicción de las categorías acertadas no coinciden en cierta parte en ambas matrices.

Kilometraje real	A	23		2										
	B		10	5										
	C			20										
	D	4		5	10									
	E													
	F						5							
	H							5						
	I			5										
	J			5						5				
	L			5								5		
	O		5	5										
		A	B	C	D	E	F	H	I	J	L	O		
		Kilometraje predicho												

Figura 6.75 Matriz de confusión para la predicción del kilometraje actual.

Fuente Autores

6.4.1.6 *Análisis del kilometraje actual usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).*

En la figura 6.76, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal que se encuentren de color rojo muestran los errores en la predicción, como por ejemplo en este caso el clasificador a cometido varios errores, ya que existen muestras que se aprecian fuera de la diagonal de la matriz de confusión.




Figura 6.76 Matriz de confusión del kilometraje actual.

Fuente: Autores

La figura 6.78, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM en el análisis de la combinación del Rango de ajuste de combustible corto, el MAP, los Ajustes de Combustible Largo, las RPM del motor, el O2 y el TPS no tienen similitud al aplicarlo, generando predicciones erróneas como se observa. El número de errores que presentan las dos matrices no son iguales, de igual manera la predicción de las categorías acertadas no coinciden en cierta parte en ambas matrices.

Kilometraje real	A	23						2			
	B		10					5			
	C	5		10	5						
	D			5	10		3			2	
	E						5				
	F						5				
	H							5			
	I			2					3		
	J			5						5	
	L				1						9
	O							5			
	A	B	C	D	E	F	H	I	J	L	O

Figura 6.77 Matriz de confusión para la predicción del kilometraje actual.

Fuente: Autores

6.4.1.7 Análisis de la categoría del último mantenimiento al usando tres vectores (Rango SFT, Ajuste de Combustible Largo, MAP).

En la figura 6.78, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal que se encuentren de color rojo muestran los errores en la predicción, como por ejemplo en este caso el clasificador a cometido varios errores, ya que existen muestras que se aprecian fuera de la diagonal de la matriz de confusión.




Figura 6.78 Matriz de confusión del último mantenimiento.

Fuente: Autores

La figura 6.79, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM para el período del último mantenimiento tienen similitud al aplicarlos a pesar que el análisis de la combinación del Rango de ajuste de combustible corto, el MAP y los Ajustes de Combustible Largo entreguen muchas predicciones erróneas, en este caso el número de errores que presentan las dos matrices no son iguales y las predicción de las categorías acertadas no presentan los mismos aciertos.

Mantenimiento real	AA	20							
	BB	2	5	8				5	
	CC	4			6				
	DD	2			5				13
	EE					5			
	FF						5		
	GG	5			7				3
	HH				5				
	JJ	5							25
		AA	BB	CC	DD	EE	FF	GG	HH
Mantenimiento predicho									

Figura 6.79 Matriz de confusión en la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

6.4.1.8 Análisis de la categoría del último mantenimiento usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).

En la figura 6.80, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal que se encuentren de color rojo muestran los errores en la predicción, como por ejemplo en este caso el clasificador a cometido varios errores, ya que existen muestras que se aprecian fuera de la diagonal de la matriz de confusión.

AA	30	9	1						
BB		29							11
CC	12		8						
DD	3			26					11
EE					10				
FF						10			
GG	1	4		2			9		14
HH				10					
JJ	5			9					46
	AA	BB	CC	DD	EE	FF	GG	HH	JJ

Figura 6.80 Matriz de confusión del último mantenimiento.

Fuente: Autores

La figura 6.81, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM para el período del último mantenimiento tienen similitud al aplicarlos a pesar que el análisis de la combinación del Rango de ajuste de combustible corto, el MAP, los Ajustes de Combustible Largo y las RPM del motor entreguen predicciones erróneas, en este caso el número de errores que presentan las dos matrices no coinciden y los errores por categorías tienen variación al igual que categorías acertadas.

Mantenimiento real	AA	15							5
	BB		19	1					
	CC			10					
	DD	1			5				14
	EE					5			
	FF						5		
	GG		5		5				5
	HH				5				
	JJ	5							25
		AA	BB	CC	DD	EE	FF	GG	HH

Mantenimiento predicho

Figura 6.81 Matriz de confusión de la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

6.4.1.9 Análisis de la categoría del último mantenimiento usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).

En la figura 6.82, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal que se encuentren de color rojo muestran los errores en la predicción, como por ejemplo en este caso el clasificador a cometido varios errores, ya que existen muestras que se aprecian fuera de la diagonal de la matriz de confusión.




Figura 6.82 Matriz de confusión del último mantenimiento

Fuente: Autores

La figura 6.83, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM para el período del último mantenimiento tienen similitud al aplicarlos a pesar que el análisis de la combinación del Rango de ajuste de combustible corto, el MAP, los Ajustes de Combustible Largo y las RPM del motor entreguen predicciones erróneas, en este caso el número de errores que presentan las dos matrices no son

iguales, sin embargo se observa que los errores por categorías tienen variación. Por otro lado las predicción de las categorías acertadas son las mismas.

Mantenimiento real	AA	20								
	BB		10	5				5		
	CC			10						
	DD				7				13	
	EE					5				
	FF						5			
	GG							10	5	
	HH								5	
	JJ	5			2					23
		AA	BB	CC	DD	EE	FF	GG	HH	JJ

Figura 6.83 Matriz de confusión de la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

6.4.1.10 Análisis de la categoría del último mantenimiento al usando cuatro vectores (Rango SFT, Ajuste de Combustible Largo, MAP).

En la figura 6.84, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal en el caso que se encuentren de color rojo muestran los errores que cometieron en la predicción.




Figura 6.84 Matriz de confusión del último mantenimiento.

Fuente: Autores

La figura 6.85, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM en el análisis de la combinación del Rango de ajuste de combustible corto, el MAP y los Ajustes de Combustible Largo, no tienen similitud. La matriz anterior presenta el 100% de predicciones correctas a diferencia de la matriz de la figura 6.86 que presenta predicciones erróneas. El número de errores que presentan las dos matrices no son iguales, de igual manera la predicción de las categorías acertadas no coinciden.




Figura 6.85 Matriz de confusión de la predicción para el kilometraje del último mantenimiento.

Fuente: Autores

6.4.1.11 Análisis de la categoría del último mantenimiento usando cuatro vectores (Rango SFT, Ajuste de Combustible largo, MAP, RPM).

En la figura 6.86, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal en el caso que se encuentren de color rojo muestran los errores que cometieron en la predicción.




Figura 6.86 Matriz de confusión del último mantenimiento.

Fuente: Autores

La figura 6.87, se muestra en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM en el análisis de la combinación del Rango de ajuste de combustible corto, el MAP, los Ajustes de Combustible Largo y las RPM del motor no tienen similitud al aplicarlo. La matriz anterior presenta en su mayoría predicciones correctas a diferencia de la matriz de la figura que se muestra mas abajo que presenta predicciones erróneas como se observa. El número de errores que presentan las dos matrices no son iguales, al contrario la predicción de las categorías acertadas si coinciden.

Mantenimiento real	AA	20								
	BB		20							
	CC			10						
	DD				10				10	
	EE					5				
	FF						5			
	GG							11	4	
	HH								5	
	JJ	5								25
		AA	BB	CC	DD	EE	FF	GG	HH	JJ
Mantenimiento predicho										

Figura 6.87 Matriz de confusión de la predicción para el kilometraje del último mantenimiento

Fuente: Autores

6.4.1.12 Análisis de la categoría del último mantenimiento usando seis vectores (Rango SFT, Ajuste de combustible largo, MAP, RPM, O2, TPS).

En la figura 6.88, se muestra la gráfica de la matriz de confusión para el kilometraje actual, en el eje horizontal corresponde a la clase predicha (Predicted Class), y en el eje vertical la clase verdadera (True Class), las celdas diagonales de color verde se muestra cuantas veces el SVM predijo correctamente, las celdas fuera de la diagonal que se encuentren de color rojo muestran los errores que cometieron en la predicción, como por ejemplo en este caso el clasificador a cometido 2 errores, ya que existen muestras que se aprecian fuera de la diagonal de la matriz de confusión.




Figura 6.88 Matriz de confusión del último mantenimiento.

Fuente: Autores

La figura 6.89 se muestra, en comparación con la matriz de confusión de la figura anterior, refleja como los resultados de predicción del SVM tienen gran parte de similitud al aplicarlos como resultado del análisis de la combinación del Rango de ajuste de combustible corto, el MAP, los Ajustes de Combustible Largo, las RPM del Motor, el O2 y el TPS, en este caso el número de errores que presentan las dos matrices tienen poca variación y la predicción de las categorías acertadas son las mismas.

Mantenimiento real	AA	20								
	BB		15				5			
	CC			10						
	DD				10				10	
	EE					5				
	FF						5			
	GG							11	4	
	HH								5	
	JJ	6								24
		AA	BB	CC	DD	EE	FF	GG	HH	JJ

Mantenimiento predicho

Figura 6.89 Matriz de confusión de la predicción para el kilometraje del último mantenimiento

Fuente: Autores

7 CONCLUSIONES

- Para el estudio se utilizó un algoritmo K-means de aprendizaje sin supervisión, que permite encontrar agrupaciones de los datos obtenidos con diferentes combinaciones de variables, para que así mediante la herramienta de aprendizaje y clasificación permitan encontrar las mayores exactitudes ahorrando tiempo.
- Para el estudio se utiliza la herramienta de aprendizaje y clasificación, a razón que nos brinda un mayor porcentaje de exactitud en el resultado de las predicciones en comparación con los árboles de decisión.
- Las herramientas de aprendizaje y clasificación basadas en SVM lineal, pueden conseguir exactitudes de 61.2 % a 79.2 %, lo que determina en la validación del algoritmo un menor índice de exactitud durante la predicción, en comparación con el clasificador SVM gaussiano o cúbico.
- Los resultados obtenidos en este estudio mediante las herramientas de aprendizaje y clasificación, utilizando clasificadores SVM gaussiano y cúbico obtienen un 99.6% de exactitud lo que, valida la forma acertada del clasificador, debido a que permiten distinguir las categorías del kilometraje actual y el kilometraje del último mantenimiento.
- El método SVM gaussiano aplicado para el kilometraje actual y el kilometraje del último mantenimiento tienen resultados con porcentajes de exactitud del 68% y 85% respectivamente, las fallas en la predicción se dan en un margen porcentual de error del 32% y 15%.

8 RECOMENDACIONES

- Se recomienda para la base de datos, tomar diferentes tipos de vehículos y de diversas marcas para realizar un análisis más extendido en este estudio, con respecto a las categorías del kilometraje actual y el último mantenimiento y por lo cual generar en base a la fiabilidad decisiones inteligentes para la gestión del mantenimiento.
- Para la predicción de fallos en etapa temprana, se utiliza la gráfica de la fiabilidad que se interpreta como la probabilidad de que el sistema falle en un tiempo dado, como un indicador de mantenimiento.

9 BIBLIOGRAFÍA

Hurtado Cortés, L. L., Villarreal López, E., & Villarreal López, L. (2016). *Detección y diagnóstico de fallas mediante técnicas de inteligencia artificial, un estado del arte.*

Obtenido de DYNÁ:
<https://revistas.unal.edu.co/index.php/dyna/article/view/55612/57576>

A. M. (2008). *Sensores Y Actuadores de Inyección Electrónica.* Obtenido de SCRIBD:
<https://es.scribd.com/doc/2083227/sensores>

Acosta Sánchez , E. L., & Veloz Lalaleo, A. V. (2017). *IDENTIFICACIÓN Y MODELAMIENTO DEL SISTEMA DE CONTROL DE INYECCIÓN ELECTRÓNICA DEL VEHÍCULO MARCA KIA MODELO CERATO STD 1600 GS (Tesis de Pregrado).* Escuela Superior Politécnica de Chimborazo, Riobamba.

Aguilar Otero, J. R., Torres Arcique, R., & Magaña Jiménez, D. (2010). *Análisis de modos de falla, efectos y criticidad (AMFEC) para la planeación del mantenimiento empleando criterios de riesgo y confiabilidad.* Obtenido de Tecnología, Ciencia, Educación:
<http://www.redalyc.org/articulo.oa?id=48215094003>

Aguilar Romero, A. Y., & Tanzado Flores, L. F. (2017). *ANÁLISIS DE MODOS DE FALLA, EFECTOS Y CRITICIDAD (AMFEC) DEL SISTEMA DE INYECCIÓN DE UN MOTOR DE ENCENDIDO PROVOCADO CORSA EVOLUTION 1.4L EMPLEANDO HERRAMIENTAS DE APRENDIZAJE Y CLASIFICACIÓN PARA LA PROGRAMACIÓN DEL MANTENIMIENTO (Tesis de Pregrado).* Universidad Politécnica Salesiana, Cuenca.

Álvarez Pineda, D. O., & Calle Calle, P. A. (2018). *CREACIÓN DE UNA BASE DE DATOS A PARTIR DEL ANÁLISIS DE LAS SEÑALES DE LOS SENSORES DEL SISTEMA DE*

- INYECCIÓN PARA LA LOCALIZACIÓN DE AVERÍAS EN MOTORES DE COMBUSTIÓN INTERNA (Tesis de Pregrado)*. Universidad Politécnica Salesiana, Cuenca.
- Apolo Torres, V. H., & Gordillo Rojas, D. A. (2017). *DETERMINACIÓN DE LA FIABILIDAD DE UN MOTOR CORSA EVOLUTION 1.4L A PARTIR DEL ANÁLISIS DE MODOS DE FALLAS EN LÍNEA BASADAS EN LA DISTRIBUCIÓN WEIBULL (Tesis de Pregrado)*. Universidad Politécnica Salesiana, Cuenca.
- Asociación de Empresas Automotrices del Ecuador. (s.f.). *Anuario Aeade 2017*. Obtenido de Asociación de Empresas Automotrices del Ecuador: http://www.aeade.net/anuario/?fbclid=IwAR3wm-2l9JK3k0UAQHc2y3APQ47JGzS0xRx_jQRM-9Xx-2sn-MukqBrQT3I
- Barreto, C., & Zhunio, L. (2017). *Aplicaciones de máquinas de soporte vectorial en el diagnóstico de motores de combustión (Tesis de Pregrado)*. Universidad Politécnica Salesiana, Cuenca.
- BOSCH. (2005). *Manual de la Técnica del Automóvil*. Barcelona: Reverte S.A.
- Calderón Calderón, A. F. (2012). *OPTIMIZACIÓN DE LA POTENCIA EN UN MOTOR DE COMBUSTIÓN INTERNA GASOLINA MEDIANTE EL CONTROL DE AJUSTES DE COMBUSTIBLE Y EL MONITOREO DEL SENSOR DE OXÍGENO (Tesis de Pregrado)*. Escuela Politécnica del Ejército, Latacunga.
- Camborda, M. (2017). *Aplicaciones de árboles de decisión para la predicción del rendimiento académico de los estudiantes de los primeros ciclos de la carrera de ingeniería civil de la universidad continental*. Huancayo.
- Cengel, Y. A., & Boles, M. A. (2006). *Termodinámica*. México: McGraw-Hill.


- Concepción, M. (2010). *Estrategias de Sistemas Automotrices OBD-II*. U.S.A.
- EMPRENTO CORP. (2018). *Sensor de Oxígeno - Sensor O2*. Obtenido de CODIGOSDTC:
<https://codigosdte.com/sensor-o2/>
- Escolano Ruiz, F., Cazorla Quevedo, M. Á., Alfonso Galipienso, M., Colombia Pardo, O., & Lozano Ortega, M. Á. (2003). *Inteligencia Artificial Modelos, Técnicas, y Áreas de aplicación*. Madrid: Spain Paraninfo, S.A.
- Freematics. (2016). *Freematics ONE+*. Obtenido de Freematics:
<https://freematics.com/pages/products/freematics-one-plus/>
- Fuentes Covarrubias, R., & Fuentes Covarrubias, A. G. (Mayo de 2015). Desarrollo de un sistema experto para el diagnóstico de fallas automotrices. Colima, Mexico.
- Gonzales Calleja, D. (2016). *Mantenimiento mecánico preventivo del vehículo*. Madrid: Paraninfo, S.A 1 edición.
- Gutiérrez Pulido, H., & de la Vara Salazar, R. (2012). *Análisis y Diseño de Experimentos*. Ciudad de México: McGRAW-HILL.
- Haro Zúñiga, J. A. (2017). *ESTIMACIÓN DE LAS EMISIONES CONTAMINANTES DE VEHÍCULOS CON MOTOR DE ENCENDIDO PROVOCADO MEDIANTE ANÁLISIS DE RUIDO A TRAVÉS DE HERRAMIENTAS DE CLASIFICACIÓN DE APRENDIZAJE (Tesis de Pregrado)*. Universidad Politécnica Salesiana, Cuenca.
- Kowienski, d. J. (2005). *Manual de Técnicas de Inyección:datos, circuitos y códigos de fallas*. Buenos Aires: Ediciones Técnicas RT.
- López, D., & Fernández, A. (2018). *Aplicación en los medios de prensa de un agrupamiento K-Means (Clustering K-Means)*. Obtenido de Revista Chilena de Economía y Sociedad:

- <https://rches.utem.cl/articulos/aplicacion-en-los-medios-de-prensa-de-un-agrupamiento-k-means-clustering-k-means/>
- Meganeboy, D. (2014). *Sensores en el automóvil*. Obtenido de Aficionados a la Mecánica: <http://www.aficionadosalamecanica.net/sensores.htm>
- NATIONAL INSTRUMENTS. (2018). *¿Qué es Adquisición de Datos?* Obtenido de NATIONAL INSTRUMENTS: <https://www.ni.com/data-acquisition/what-is/esa/>
- Palacios Delgado, E. A., & Pesántez Alvarez, J. E. (2016). *CREACIÓN DE UNA BASE DE DATOS A PARTIR DE LAS SEÑALES DE LOS SENSORES DEL MOTOR PARA LA LOCALIZACIÓN DE AVERÍAS QUE NO GENERAN CÓDIGO (Tesis de Pregrado)*. Universidad Politécnica Salesiana, Cuenca.
- Payri, F., & Desantes, J. M. (2011). *Motores de combustión interna alternativos*. BARCELONA: REVERTE.
- Red Temática Nacional sobre Seguridad de Funcionamiento y Calidad de Servicio de Sistemas Productivos. (2010). *APROXIMACIÓN DE LA CONFIABILIDAD: APLICACIONES PRÁCTICAS*. Obtenido de Document: <https://vdocuments.site/libro-ingeman-aproximaciona-la-confiabilidad-aplicaciones-practicaspdf.html>
- Rivera Caravajo, J., & Cepeda Landin, C. (2017). *Diagnóstico de fallos de sistema de inyección de un motor de encendido provocado mediante inteligencia artificial (Tesis de Pregrado)*. Universidad Politécnica Salesiana, Cuenca.
- Rovira de Antonio, A. J., & Muñoz Domínguez, M. (2014). *Máquinas Térmicas*. Madrid: UNED - Universidad Nacional de Educación a Distancia.
- Sánchez Anzola, N. (2015). Máquinas de soporte vectorial y redes neuronales artificiales en la predicción del movimiento USD/COP spot intradiario. *Odeon* , 19-23.


Sánchez, E. (2012). *Sistemas Auxiliares del Motor*. Madrid.

Suk Yang, B., & Achmad, W. (2016). *Support vector machine in machine condition monitoring and fault diagnosis*. Elsevier, 2560-2574.


10 ANEXOS




Anexo 1 Análisis de vector 11: Rango, ECT, IAT.




Anexo 2 Análisis de vector 11: Ajuste de combustible a largo plazo, ECT, IAT.



Anexo 3 Análisis de vector 11: ECT, IAT.




Anexo 4 Análisis de vector 9: RANGO, ECT, IAT.



Anexo 5 Análisis de vector 9: Ajuste de combustible a largo plazo, ECT, IAT.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Response
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Do not import
CATEGORIADIF	categorical	9 unique	Do not import
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Predictor
MAP	double	21 .. 49	Do not import
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Predictor
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Do not import
IAT	double	17 .. 70	Do not import
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Do not import
AJUSTELARGOALCA...	double	-10 .. 14	Do not import
O2	double	0.035 .. 0.9	Predictor

Anexo 6 Selección de 3 predictores para el kilometraje actual.




Anexo 7 Coordenadas paralelas para la predicción de las categorías del kilometraje actual.

True class	A	38	2	4	2	2									2	
	B	2	17		9					2						
	C	4	3	21	3	1					5	3				
	D		5		24					2	8				1	
	E	1	5		3					1						
	F	3	3		4											
	H		5		4			1								
	I	2	1	1	4				2							
	J	1	2		1	4					11				1	
	L	1										19				
	O		1		3						2				14	
			↖	⊗	⊙	⊜	⊞	⊟	⊠	⊡	⊢	⊣	⊤	⊥	⊦	
			Predicted class													

Anexo 8 Matriz de confusión de la predicción del kilometraje actual.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Do not import
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Predictor
CATEGORIADIF	categorical	9 unique	Response
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Predictor
MAP	double	21 .. 49	Do not import
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Predictor
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Do not import
IAT	double	17 .. 70	Do not import
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Do not import
AJUSTELARGOALCA...	double	-10 .. 14	Predictor
O2	double	0.035 .. 0.9	Predictor

Anexo 9 Selección de 6 predictores para el kilometraje del último mantenimiento.




Anexo 10 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.

AA	38							2	
BB	1	39							
CC			14			2		4	
DD				36				4	
EE					10				
FF						10			
GG	5	7	2				15	1	
HH								10	
JJ	3		2	2			6		47
	AA	BB	CC	DD	EE	FF	GG	HH	JJ

Anexo 11 Matriz para la predicción para el kilometraje del último mantenimiento.

Name	Type	Range	Import as
NUMERODEVEHICULO	double	1 .. 26	Do not import
ALTURAmnm	double	4 .. 2550	Do not import
MARCA	categorical	3 unique	Do not import
MODELO	categorical	13 unique	Do not import
AODEFABRICACION	double	2005 .. 2019	Do not import
KILOMETRAJEACTUAL	double	12949 .. 720516	Do not import
CATEGORIAKM	categorical	11 unique	Do not import
KILOMETRAJEultimom...	double	12000 .. 719214	Do not import
DIFERENCIA	double	0 .. 5000	Do not import
CATEGORIADIF	categorical	9 unique	Response
CILINDRADACC	double	1200 .. 1800	Do not import
CONDICION	categorical	1 unique	Do not import
RPM	double	631 .. 858	Do not import
MAP_Kpa	double	21 .. 49	Do not import
MAF	double	0 .. 0	Do not import
TPS	double	0 .. 14	Predictor
ECT	double	78 .. 99	Do not import
VSS	double	0 .. 0	Predictor
IAT	double	17 .. 70	Predictor
SFTMAX	double	-2 .. 6	Do not import
SFTMIN	double	-6 .. 3	Do not import
RANGOSFT	double	0 .. 8	Do not import
AJUSTELARGOALCA...	double	-10 .. 14	Do not import
O2	double	0.035 .. 0.9	Predictor

Anexo 12 Selección de 4 predictores para el kilometraje del último mantenimiento



Anexo 13 Coordenadas paralelas para la predicción para el kilometraje del último mantenimiento.

True class	AA	53			12	9				6	
	BB		70	1				1		8	
	CC	2		26	4					8	
	DD	5			56				4	15	
	EE	6			2	12					
	FF						20				
	GG		4	1	8	1		38		8	
	HH				2				18		
	JJ		10		14					96	
			AA	BB	CC	DD	EE	FF	GG	HH	JJ
		Predicted class									

Anexo 14 Matriz de confusión para el kilometraje del último mantenimiento.