



UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE CUENCA
CARRERA DE MECATRÓNICA

**PREDICCIÓN DE FALLAS MEDIANTE UN MODELO DE
APRENDIZAJE AUTOMÁTICO EN MOTORES DE COMBUSTIÓN
INTERNA**

Trabajo de titulación previo a la obtención del
título de Ingeniero en Mecatrónica

AUTOR: JORGE SANTIAGO GUARTAZACA UYAGUARI
TUTOR: ING. NÉSTOR DIEGO RIVERA CAMPOVERDE, MSc.

Cuenca – Ecuador

2024

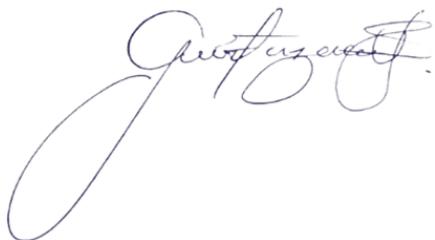
CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Yo, Jorge Santiago Guartazaca Uyaguari con documento de identificación N° 0105473847 manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Cuenca, 31 de julio del 2024

Atentamente,



Jorge Santiago Guartazaca Uyaguari
0105473847

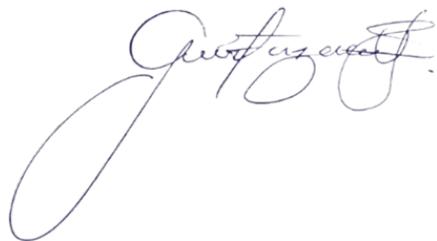
CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA

Yo, Jorge Santiago Guartazaca Uyaguari con documento de identificación N° 0105473847, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del Proyecto Técnico: "Predicción de fallas mediante un modelo de aprendizaje automático en motores de combustión interna", el cual ha sido desarrollado para optar por el título de: Ingeniero en Mecatrónica, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, 31 de julio del 2024

Atentamente,



Jorge Santiago Guartazaca Uyaguari
0105473847

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Néstor Diego Rivera Campoverde, con documento de identificación N° 0103898995, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: PREDICCIÓN DE FALLAS MEDIANTE UN MODELO DE APRENDIZAJE AUTOMÁTICO EN MOTORES DE COMBUSTIÓN INTERNA, realizado por Jorge Santiago Guartazaca Uyaguari con documento de identificación N° 0105473847, obteniendo como resultado final el trabajo de titulación bajo la opción Proyecto Técnico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Cuenca, 31 de julio del 2024

Atentamente,



Néstor Diego Rivera Campoverde
0103898995

Dedicatoria

Dedico este trabajo:

A mi madre Lilian, por su apoyo incondicional en este trayecto de mi vida, eres el ángel de mi vida.

A mi tío Fidel por su cariño y sus enseñanzas.

A mi padre, abuelos y toda mi familia que siempre me han estado apoyando constantemente.

Agradecimientos

Agradezco a Dios por permitirme cumplir mis sueños.

Al Ingeniero Néstor Rivera, por su apoyo constante, correcciones, y su amistad.

Gracias totales.

Este documento fue realizado enteramente en L^AT_EX

Índice

Certificado de responsabilidad y autoría del trabajo de titulación	I
Certificado de cesión de derechos de autor del trabajo de titulación a la Universidad Politécnica Salesiana	II
Certificado de dirección del trabajo de titulación	III
Dedicatoria	IV
Agradecimientos	V
Resumen	XIV
Abstract	XV
1. Introducción	1
2. Problema	2
2.1. Descripción del problema	2
2.2. Antecedentes	2
2.3. Importancia y alcances	3
2.4. Delimitación	3
2.4.1. Espacial o geográfica	3
2.4.2. Temporal	4
2.4.3. Sectorial o institucional	4
3. Objetivos	4
3.1. Objetivo general	4
3.2. Objetivos Específicos	5
4. Hipótesis	5
4.1. Hipótesis General	5
4.2. Hipótesis Específicas	5
5. Marco Teórico	5
5.1. Motor de combustión interna	5

5.1.1.	Ciclos de funcionamiento de un motor de combustión interna	6
5.1.2.	Sistema de inyección electrónica	8
5.1.3.	Sensores	8
5.1.4.	Sensor de Temperatura del Aire (IAT)	8
5.1.5.	Sensor de flujo de masa de aire (MAF)	9
5.1.6.	Sensor de presión absoluta de la admisión (MAP)	9
5.1.7.	Sensor de posición del cigüeñal (CKP)	9
5.1.8.	Avance del tiempo de Encendido (ATE)	10
5.1.9.	Sensor de temperatura del motor (ECT)	11
5.2.	Ajuste de combustible a largo plazo (LTFT)	11
5.3.	Ajuste de combustible a corto plazo (STFT)	13
5.4.	Sensor de posición del acelerador (TPS)	14
5.5.	Sensor de velocidad del vehículo (VSS)	15
5.6.	Mantenimiento Correctivo	16
5.7.	Mantenimiento Preventivo	17
5.8.	Mantenimiento Predictivo (PdM)	17
5.9.	Aprendizaje Automático (ML)	18
5.10.	Modelos de aprendizaje automático.	21
5.10.1.	Árbol de decisión (árbol fino)	21
5.10.2.	Máquina de vectores de soporte lineal SMVL	21
5.10.3.	Árbol de decisión (árbol medio)	22
5.10.4.	K-Nearest Neighbors (KNN fino)	23
5.10.5.	SVM gaussiana gruesa (Coarse Gaussian SVM)	23
5.10.6.	Red neuronal media (Medium Neural Network)	24
5.11.	Protocolo de red de área de control (CAN)	25
5.12.	Desviación Estándar.	26
5.13.	Máximos y Mínimos	27
5.14.	Matriz de correlación	27
5.15.	Freematics ONE+	28
5.16.	Scanner MaxiSys MS906	29
6.	Marco metodológico	30
6.1.	Diagrama del proceso de adquisición de parámetros mediante las herramientas Freematics ONE+ y Scanner MaxisSys MS906	31

6.2.	Desarrollo de la programación mediante el entorno de Visual Studio Code para el dispositivo "Freematics ONE+" para la adquisición y almacenamiento de parámetros	32
6.3.	Parámetros adquiridos	34
6.4.	Análisis de los datos adquiridos y estructurados empleando técnicas estadísticas multivariantes.	34
6.4.1.	Avance del tiempo de encendido (ATE).	34
6.4.2.	Sensor de temperatura del refrigerante del motor (ECT)	37
6.4.3.	Temperatura del aire de admisión (IAT).	39
6.4.4.	Flujo de masa de aire (MAF)	42
6.4.5.	Tensión positiva de la batería	45
6.4.6.	Ajuste de combustible a largo plazo (LTFT)	48
6.4.7.	Ajuste de combustible a corto plazo (STFT)	51
6.4.8.	Régimen de giro (RPM)	53
6.4.9.	Sensor de posición del acelerador (TPS)	55
6.4.10.	Sensor de velocidad del vehículo (VSS)	57
6.5.	Análisis de la matriz de correlación.	59
6.6.	Entrenamiento de los modelos de aprendizaje automático	67
6.6.1.	Árbol de decisiones fino (Tree)	67
6.6.2.	KNN F (KNN Fino)	69
6.6.3.	Red Neuronal Estrecha	71
6.7.	Entrenamiento de los modelos de aprendizaje automático Máquina de Vectores de Soporte Lineal (SVML).	73
6.7.1.	Resultados del modelo entrenado	73
6.7.2.	Matriz del número de observaciones	74
6.7.3.	Matriz de confusión TPR y FNR	77
6.7.4.	Resultados del modelo entrenado SVML	78
6.7.5.	Curva ROC de desempeño del modelo SVML entrenando	81
6.7.6.	Coordenadas paralelas del algoritmo de predicción de fallas SVML	83
7.	Resultados	85
8.	Cronograma	87
9.	Presupuesto	89
9.1.	Talento humano	89

9.2. Recursos materiales	89
10. Conclusiones	90
11. Recomendaciones	91
Referencias	96
ANEXOS	97

Lista de Tablas

1.	Cuadro de metodología de la investigación	31
2.	Definiciones de Parámetros del Sensor	34
3.	Valores descriptivos del avance del tiempo de encendido	36
4.	Valores descriptivos de la temperatura del refrigerante del motor	39
5.	Valores descriptivos de la temperatura del aire de admisión.	42
6.	Valores descriptivos del flujo de masa de aire.	45
7.	Valores descriptivos de la tensión de la batería.	48
8.	Valores descriptivos del ajuste de combustible a largo plazo.	50
9.	Valores descriptivos del ajuste de combustible a corto plazo	52
10.	Valores descriptivos del régimen de giro (RPM).	54
11.	Valores descriptivos del sensor de posición del acelerador.	56
12.	Valores descriptivos del sensor de velocidad del vehículo (VSS)	59
13.	Correlación de LTFT con otras variables	61
14.	Correlación de MAP con otras variables	62
15.	Correlación de TPS con otras variables	63
16.	Correlación de VSS con otras variables	64
17.	Correlación de ETQ1 con otras variables	65
18.	Correlaciones Fuertes entre Parámetros	66
19.	Parámetros del Modelo 1: Árbol de Decisión (Fine Tree)	67
20.	Hiperparámetros y Resultados del Modelo KNN	69
21.	Resultados del Entrenamiento e Hiperparámetros del Modelo de Red Neuronal Estrecha	71
22.	Definiciones de los parámetros de entrada.	73
23.	Etiquetas de las condiciones de falla	74
24.	Resultados de Precisión y Falsos Positivos por Clase	78
25.	Resultados del modelo SVM	79
26.	Cronograma de actividades.	88
27.	Recurso de talento humano	89
28.	Recurso de talento humano	89
29.	Resultados del Modelo SVM	98
30.	Resultados del Modelo SVM	101
31.	Resultados del Modelo SVM	104

Lista de Figuras

1.	Ubicación Universidad Politécnica Salesiana	4
2.	Componentes de un motor de combustión interna	6
3.	Esquema del funcionamiento del motor de cuatro tiempos	7
4.	Esquema del sensor de posición del cigüeñal (CKP)	10
5.	Sensor de temperatura del motor (ECT)	11
6.	Programación tradicional y aprendizaje automático	19
7.	Machine Learning	20
8.	Protocolo de red de área de control (CAN)	26
9.	Freematics ONE+	29
10.	Scanner MaxiSys MS906	30
11.	Esquema para el entrenamiento del modelo de aprendizaje final	32
12.	En torno de programación de adquisición de datos para el dispositivo Freematics ONE+	33
13.	Avance del tiempo de encendido	35
14.	Avance del tiempo de encendido	36
15.	Sensor de temperatura del refrigerante del motor	37
16.	Temperatura del refrigerante del motor, ECT	38
17.	Temperatura del aire de admisión, IAT	40
18.	Temperatura del aire de admisión	41
19.	Flujo de masa de aire (MAF)	43
20.	Flujo de masa de aire (MAF)	44
21.	Tensión positiva de la batería	46
22.	Tensión positiva de la batería	47
23.	Ajuste de combustible a largo plazo.	49
24.	Ajuste de combustible a largo plazo	50
25.	Ajuste de combustible a corto plazo.	51
26.	Histograma del ajuste de combustible a corto plazo.	52
27.	Régimen de giro (RPM)	53
28.	Régimen de giro (RPM).	54
29.	Sensor de posición del acelerador.	55
30.	Sensor de posición del acelerador.	56
31.	Sensor de velocidad del vehículo (VSS)	57
32.	Histograma sensor de velocidad del vehículo (VSS.	58

33.	Matriz de correlación.	60
34.	Matriz de confusión modelo de aprendizaje Tree	68
35.	Matriz de confusión modelo de aprendizaje Fine KNN	70
36.	Matriz de confusión modelo de aprendizaje Red Neuronal Estrecha	72
37.	Número de observaciones (SVML).	75
38.	Validación de la matriz de confusión (SVML).	77
39.	Curva ROC del desempeño del algoritmo SVML.	82
40.	Coordenadas paralelas del algoritmo de predicción de fallas SVML.	84
41.	Matriz de confusión modelo SVML para vehículo 1	98
42.	Curva ROC del desempeño del algoritmo SVML.	99
43.	Coordenadas paralelas del algoritmo de predicción de fallas SVML.	100
44.	Matriz de confusión modelo SVML para vehículo 2	101
45.	Curva ROC del desempeño del algoritmo SVML.	102
46.	Coordenadas paralelas del algoritmo de predicción de fallas SVML.	103
47.	Matriz de confusión modelo SVML para vehículo 3	104
48.	Curva ROC del desempeño del algoritmo SVML.	105
49.	Coordenadas paralelas del algoritmo de predicción de fallas SVML.	106

Resumen

El presente trabajo de titulación propone un modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna. Inicialmente, se recopiló una cantidad significativa de datos relevantes, identificando los parámetros críticos que influirían en la precisión del modelo predictivo. Utilizando dispositivos como el Freematics ONE+, escaner MaxiSys MS906 y herramientas de software avanzadas como MATLAB, se logró una extracción y clasificación detallada de los parámetros, lo que permitió la aplicación de diversos métodos estadísticos para garantizar la calidad de los datos. Se incluyeron cálculos de desviación estándar, máximos y mínimos, así como interpolación y una matriz de correlaciones, esenciales para reducir redundancias y mejorar la interpretabilidad del modelo.

Posteriormente, se analizó el comportamiento de los modelos, entrenándolos y validándolos con conjuntos de datos de prueba. Se analizó el entrenamiento de los modelos de aprendizaje automático, árbol de decisiones fino (97.2%), KNN (97.3%), y red neuronal estrecha (96.2%) que fueron considerados, pero no fueron seleccionados debido a altas posibilidades de sobre ajuste. Se seleccionó el modelo Support Vector Linear Machine (SVML) por su capacidad para manejar datos de alta dimensión y relaciones lineales. Los resultados obtenidos mostraron una precisión de validación del 77,6%, con tiempos de predicción y entrenamiento satisfactorios, y un tamaño del modelo eficiente. Las curvas ROC y la matriz de confusión demostraron un sólido rendimiento del modelo, aunque se identificaron áreas de posibles mejoras en algunas clases específicas. Por último, la validación del modelo con datos independientes confirmó su robustez y universalidad. La precisión global del 77,6% y una alta precisión en la clase 4 (89,3%) indicaron que el modelo es particularmente eficaz en la identificación de fallos críticos, estableciendo así una herramienta fiable para el diagnóstico y el mantenimiento preventivo de los motores de combustión interna. Los resultados obtenidos subrayan la importancia y la eficacia del uso del aprendizaje automático para mejorar el rendimiento y la fiabilidad de los sistemas de motores modernos.

Palabras clave: Aprendizaje Automático, Mantenimiento Predictivo, Máquina de Vectores de Soporte, Motor de combustión interna.

Abstract

This thesis proposes a failure prediction model using machine learning for internal combustion engines. Initially, a significant amount of relevant data was collected, identifying the critical parameters that would influence the accuracy of the predictive model. Using devices such as the Freematics ONE+, MaxiSys MS906 scanner and advanced software tools such as MATLAB, a detailed extraction and classification of the parameters was achieved, allowing the application of various statistical methods to ensure data quality. This included calculations of standard deviation, maxima and minima, as well as interpolation and a correlation matrix, essential to reduce redundancies and improve the interpretability of the model.

Subsequently, the behaviour of the models was analysed by training and validating them with test data sets. The training of the machine learning, fine decision tree (97.2%), KNN (97.3%), and narrow neural network (96.2%) models that were considered, but not selected due to high chances of overfitting, were analysed. The Support Vector Linear Machine (SVML) model was selected for its ability to handle high-dimensional data and linear relationships. The results obtained showed a validation accuracy of 77.6%, with satisfactory prediction and training times, and an efficient model size. The ROC curves and the confusion matrix demonstrated a robust model performance, although areas for improvement were identified in some specific classes. Finally, validation of the model with independent data confirmed its robustness and universality. The overall accuracy of 77.6% and a high accuracy in class 4 (89.3%) indicated that the model is particularly effective in identifying critical failures, thus establishing a reliable tool for the diagnosis and preventive maintenance of internal combustion engines. The results obtained underline the importance and effectiveness of using machine learning to improve the performance and reliability of modern engine systems.

Keywords: Machine Learning, Predictive Maintenance, Support Vector Machine, Internal combustion engine.

1. Introducción

La integración de tecnologías avanzadas como el aprendizaje automático en los sistemas de motores de combustión interna ha transformado la forma de diagnosticar y prevenir averías. Tradicionalmente, el mantenimiento de los motores se basaba en un enfoque correctivo y preventivo, en el que las reparaciones se realizaban después de que se produjera un fallo o por recomendaciones del fabricante al cumplir cierto kilometraje. Estos métodos, aunque funcionales, se traducen en costes elevados y tiempos de inactividad prolongados, lo que repercuten negativamente en la eficiencia operativa y la seguridad. El presente trabajo de titulación se centra en el entrenamiento y la aplicación de un modelo de predicción de fallos mediante técnicas de aprendizaje automático. Este enfoque proactivo no solo anticipa posibles fallos antes de que se produzcan, sino que también optimiza el mantenimiento, reduce los costes y mejora la seguridad y la vida útil del motor. Para lograr este objetivo, se ha recopilado y analizado datos operativos clave utilizando dispositivos de adquisición como el Freematics ONE+ y el escáner MaxiSys MS906. Los datos recogidos incluyen parámetros críticos como la temperatura del refrigerante del motor (ECT), la presión absoluta del colector (MAP), la posición del sensor del acelerador (TPS), entre otros. Estos parámetros se seleccionaron por su relevancia en el diagnóstico de fallos comunes en motores de combustión interna. El análisis de estos datos se realizó utilizando el software MATLAB®, donde aplicamos técnicas estadísticas y de correlación para identificar patrones y relaciones significativas entre los parámetros. Estos análisis no solo ayudaron a mejorar la precisión del modelo predictivo, sino que también redujeron la redundancia de datos, haciendo que el modelo fuera más eficiente y fácil de interpretar. El desarrollo del modelo de predicción de fallos incluyó el entrenamiento de modelos como: Árbol de decisiones fino, KNN, Red Neuronal Estrecha y Máquina de vectores de soporte lineal (SVML), siendo este último elegido, ya que muestra una gran precisión y capacidad para manejar datos de alta dimensión. La validación del modelo con conjuntos de datos independientes confirmó su eficacia y coherencia, destacando su aplicabilidad en entornos reales. Esta investigación no solo demuestra la viabilidad y eficacia del uso del aprendizaje automático en el mantenimiento predictivo de motores de combustión interna, sino que también sienta las bases para futuras investigaciones y aplicaciones en el campo de la ingeniería mecatrónica.

2. Problema

2.1. Descripción del problema

Dentro del sistema de control electrónico automotriz, todos los sensores que están asociados al funcionamiento del motor están representados por medio de PID's, estos son los encargados de proporcionar información para detectar, analizar y corregir los fallos.

Al realizar un mantenimiento correctivo o preventivo a un determinado problema dentro del motor, no se considera que otros sensores y/o elementos podrían encontrarse afectados de manera incipiente. Lo que provocará que con el transcurso del tiempo y del recorrido del vehículo se presenten daños descendientes de dichas averías no observadas con antelación, debido a que no se puede determinar un posible fallo sin tener datos que nos permitan realizar análisis y comparaciones que nos ayuden a predecir una falla determinada.

2.2. Antecedentes

Los motores de combustión interna desempeñan un rol esencial en un automóvil; sin embargo, están sujetos a fallas y averías que pueden provocar interrupciones costosas y peligrosas durante su funcionamiento. Ante esto, la detección y predicción anticipada de fallas se ha convertido en una área de investigación decisiva para garantizar la confiabilidad y su rendimiento óptimo.

Los enfoques tradicionales de mantenimiento basados en el tiempo o en uso de umbrales predefinidos para la detección de fallas tienen limitaciones significativas. Ya que estos métodos no son capaces de adquirir las sutilezas e interacciones no lineales en los datos operativos del motor que podrían indicar la aparición de una falla. Adicionalmente, estos enfoques no permiten aprovechar el potencial de las técnicas actuales de aprendizaje automático, las cuales están demostrando ser eficaces en la detección y predicción de fallos en diversos campos.

Ante esto, se plantea el diseño de un modelo de predicción de fallas mediante aprendizaje automático adaptado a los motores de combustión interna. Esta tendrá técnicas, como algoritmos de clasificación, regresión o agrupamiento, que nos permitan analizar grandes volúmenes de datos operativos del motor para identificar patrones y tendencias asociadas con posibles fallas incipientes. Permitiendo, analizar y comprender los factores que influyen en las fallas de los motores de combustión interna.

2.3. Importancia y alcances

- Realizar un modelo de predicción de fallos basado en el aprendizaje automático se considera una práctica importante que ayuda a prevenir fallos y averías no contempladas dentro de un mantenimiento correctivo o preventivo. Esto nos permitirá tener reducción de costos, mejora en el rendimiento y en la eficiencia, seguridad, alargar la vida útil del vehículo, tener una planificación y programación de actividades de servicio en momentos convenientes para nosotros. Y finalmente tener un registro de un historial detallado del vehículo, que permitirá dar seguimiento de las reparaciones, piezas reemplazadas y su tiempo de duración. Estos registros ayudarán para futuras supervisiones, ventas y o aplicaciones de garantías.
- El alcance del proyecto solo abarcará el diseño de un modelo de predicción de fallas mediante aprendizaje automático de un motor de combustión interna.
- La obtención de los datos necesarios de las señales de los diferentes sensores se lo hará mediante el dispositivo Freematics ONE+, y Escáner MaxiSys MSgo6, y con el software de ingeniería denominado MATLAB® , se diseñará el algoritmo de aprendizaje automático.
- Finalmente, se realizará el análisis del modelo obtenido.

2.4. Delimitación

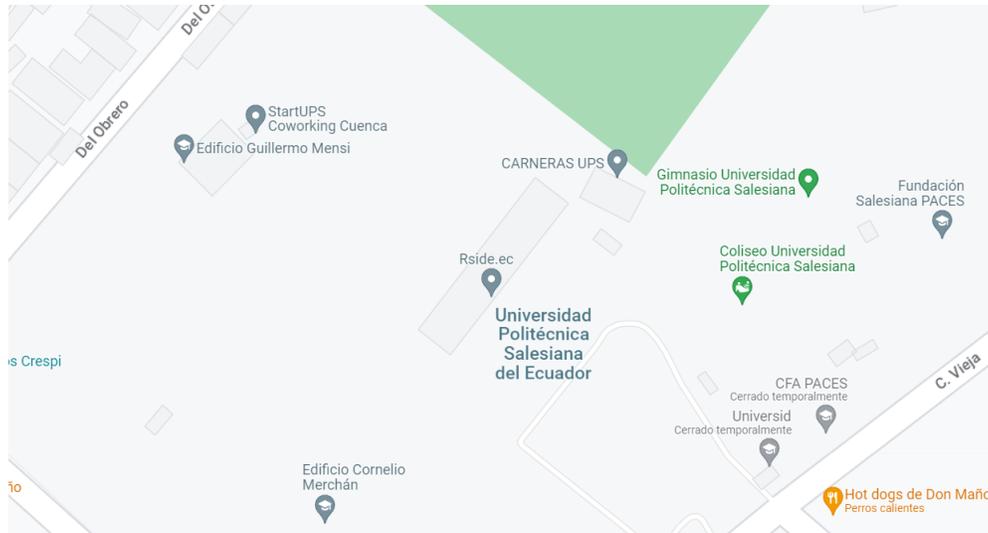
El problema de estudio se delimitará en las siguientes dimensiones:

2.4.1. Espacial o geográfica

El presente proyecto se realizará dentro de la Universidad Politécnica Salesiana, sede Cuenca, en la provincia del Azuay.

Figura 1

Universidad Politécnica Salesiana.



Nota: Se observa la Universidad Politécnica Salesiana, tomado desde (*Universidad Politécnica Salesiana del Ecuador*, 2023).

2.4.2. Temporal

El tiempo seleccionado para la investigación y desarrollo del proyecto será de 400 horas, las cuales se encuentran distribuidos en las asignaturas de trabajo de titulación 1 y 2.

2.4.3. Sectorial o institucional

Según la Norma NTE INEN 2204 Segunda revisión 2017-01, el presente proyecto está enfocado en los vehículos automotores que emplean gasolina.

3. Objetivos

3.1. Objetivo general

- Predecir fallas mediante un modelo de aprendizaje automático en motores de combustión interna.

3.2. Objetivos Específicos

- Obtener la información y parámetros iniciales para el modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna.
- Analizar el comportamiento del modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna.
- Validar el modelo de predicción de fallas obtenido.

4. Hipótesis

4.1. Hipótesis General

- La predicción de fallas mediante un modelo de aprendizaje automático en motores de combustión interna permitirá la detección fiable y temprana de averías, lo cual resultará en una mejora significativa en la eficiencia del mantenimiento, la disponibilidad del motor y la seguridad durante su funcionamiento.

4.2. Hipótesis Específicas

- Se obtendrá la información y los parámetros iniciales para el modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna.
- Se analizará el comportamiento del modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna.
- Se validará el modelo de predicción fallas.

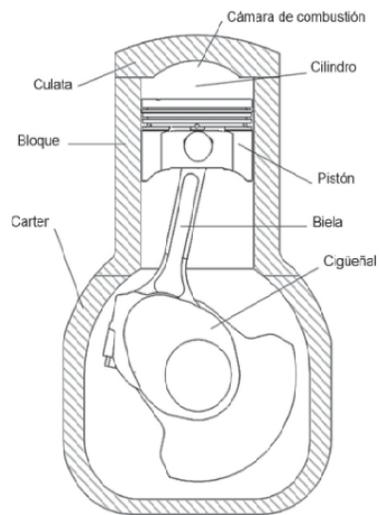
5. Marco Teórico

5.1. Motor de combustión interna

Se denomina motor de combustión interna a una máquina que es capaz de cumplir un ciclo abierto de la cual su objetivo principal es convertir la energía termodinámica en energía mecánica, está formada por componentes fijos y móviles como se muestra en la figura 2 (De Antonio y Muñoz Domínguez, 2016).

Figura 2

Componentes de un motor de combustión interna.



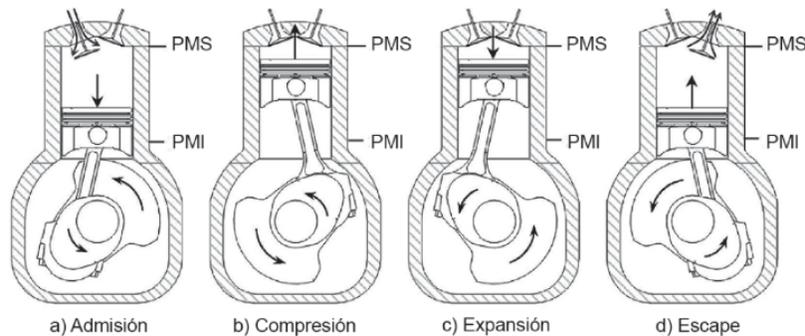
Nota: Componentes de un motor de combustión interna, tomado desde (De Antonio y Muñoz Domínguez, 2016).

5.1.1. Ciclos de funcionamiento de un motor de combustión interna

En los motores de combustión interna de 4 tiempos, el ciclo de trabajo completo es igual al giro de 720 grados (dos vueltas del cigüeñal), como se muestra en la figura 3 (De Antonio y Muñoz Domínguez, 2016).

Figura 3

Esquema del funcionamiento del motor de cuatro tiempos.



Nota: Esquema del funcionamiento del motor de cuatro tiempos, tomado desde (De Antonio y Muñoz Domínguez, 2016).

Los procesos que se realiza en cada tiempo son:

- **Proceso de admisión:** Durante esta fase, las válvulas de admisión están abiertas, mientras que las de escape permanecen cerradas. El pistón se desplaza desde el punto muerto superior (PMS) hasta el punto muerto inferior (PMI), lo cual permite que la mezcla de aire y combustible necesaria entre en la cámara de combustión (De Antonio y Muñoz Domínguez, 2016).
- **Proceso de compresión:** Durante esta etapa, tanto las válvulas de admisión como las de escape permanecen cerradas. El pistón se mueve desde el punto muerto inferior (PMI) hacia el punto muerto superior (PMS), comprimiendo la mezcla en el proceso (De Antonio y Muñoz Domínguez, 2016).
- **Proceso de expansión:** En esta fase, el pistón se encuentra en la parte superior del cilindro (PMS). La chispa generada en la bujía enciende la mezcla de aire y combustible comprimida en la cámara. Esta ignición provoca una rápida expansión de los gases, impulsando el pistón de vuelta hacia el PMI (De Antonio y Muñoz Domínguez, 2016).
- **Proceso de escape:** en este intervalo se abren las válvulas de escape, permitiendo expulsar los gases quemados hacia el exterior de la cámara, de esta manera terminando el ciclo. (De Antonio y Muñoz Domínguez, 2016).

Este funcionamiento varía de acuerdo a los niveles de la altura sobre el nivel del mar que se encuentre el vehículo, así lo analizan Rivera Campoverde, Chica, y Zambrano (2015), donde explican que el comportamiento de un motor de ciclo Otto con inyección electrónica en relación con la estequiometría de la mezcla y el adelanto al encendido, específicamente para la ciudad de Cuenca, que se encuentra a 2550 metros sobre el nivel del mar.

5.1.2. Sistema de inyección electrónica

Estos se encargan de gestionar la mezcla de aire y combustible, ajustándola de manera óptima según las condiciones del motor. Esta integración, conocida como "estequiométrica," se caracteriza por una proporción de 14,7 de aire combustible en gramos. (Sánchez, 2012) Estos sistemas permiten alcanzar una mayor eficiencia en comparación con los mecanismos de inyección mecánica y carburador, cumpliendo así con las directrices establecidas para la formación de la mezcla.

Rivera, Molina, Bermeo, Bermeo, y Figueroa (2022) Explican que los sistemas de inyección electrónica permiten regular la mezcla de combustible-aire que ingresa al motor, lo que contribuye a reducir la generación de emisiones contaminantes. Esto implica que los ajustes de combustible pueden ser tanto a corto como a largo plazo, dependiendo de la tecnología utilizada y de las condiciones de conducción.

5.1.3. Sensores

Es un aparato capaz de identificar y reaccionar a diversos estímulos ambientales, tales como la temperatura, la distancia, la aceleración, el movimiento, la humedad y la presión. Estos estímulos se convierten en señales que pueden ser entendidas por las personas o procesadas por otros dispositivos electrónicos. Los sensores son vitales en muchos sistemas modernos, incluyendo automóviles, equipos médicos, dispositivos de monitoreo ambiental y tecnología de consumo. (Tovar-Lopez, 2023)

5.1.4. Sensor de Temperatura del Aire (IAT)

- **Función.**

El sensor de temperatura del aire de admisión (IAT) trabaja con el coeficiente de temperatura negativo (NTC) en donde desciende la resistencia según la temperatura del sensor aumenta (Vacacela Romero y Rivera Carrión, 2018).

Se ubica en el ducto de admisión, o formando un solo cuerpo con el sensor.

5.1.5. Sensor de flujo de masa de aire (MAF)

El medidor de flujo de aire (MAF) incluye una resistencia de hilo caliente que funciona como el componente sensible y cuantifica el volumen de aire que entra al cilindro. En algunos vehículos, se observa que tienen 5 o 6 cables, incorporando el sensor IAT. Este dispositivo requiere una alimentación de 12v debido a la necesidad de este voltaje para el hilo caliente (Vacacela Romero y Rivera Carrión, 2018).

5.1.6. Sensor de presión absoluta de la admisión (MAP)

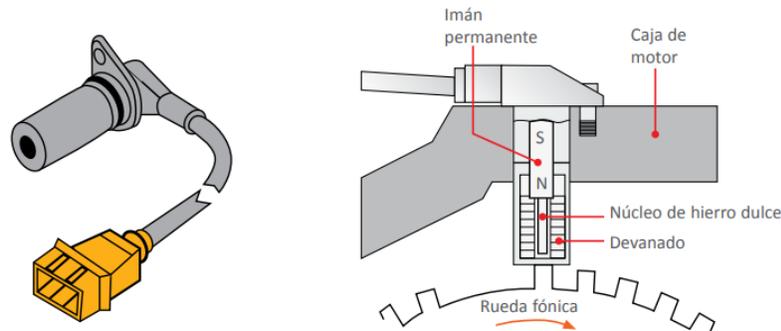
El dispositivo tiene el rol de detectar la presión aérea en el sistema de admisión del vehículo, convirtiéndola en un indicador eléctrico que es enviada a la memoria del vehículo (ECU) la cual regulara le mezcla estequiométrica (Jachero Arízaga, 2016), de acuerdo con (GmbH, 2019) algunas variantes se pueden utilizar para medir la presión absoluta del aceite.

5.1.7. Sensor de posición del cigüeñal (CKP)

Este dispositivo es un elemento crucial en los motores de vanguardia para el seguimiento de la posición y velocidad del cigüeñal. La ECU emplea la información del CKP para ajustar el momento de la inyección de combustible y la ignición. Existen dos tipos principales de Sensores CKP: los inductivos, que generan voltaje mediante inducción electromagnética, y los de efecto Hall, que producen señales digitales mediante la variación del campo magnético. Un CKP defectuoso puede causar problemas de arranque, ralentí irregular y un uso de combustible inesperadamente alto. Es extremadamente importante que el CKP esté funcionando de manera adecuada para que pueda proporcionar sincronización y eficiencia (Bosch, 2014).

Figura 4

Esquema del sensor de posición del cigüeñal(CKP).



Nota: La gráfica se muestra el esquema del sensor de posición del cigüeñal (CKP).(Calle Jara y Vicuña Pacheco, 2015).

5.1.8. Avance del tiempo de Encendido (ATE)

Eficiencia del Combustible:

- Un avance del encendido adecuado permite que la mezcla de aire-combustible se quemara de manera más completa y eficiente, aumentando la potencia del motor y mejorando la economía de combustible.(Heywood, 1988)
- Si el encendido está demasiado retrasado (la chispa se produce después del PMS), la mezcla no se quemará completamente, lo que puede reducir la eficiencia del motor (Heywood, 1988)

■

Prevención de Detonaciones:

- Si el encendido está demasiado adelantado (la chispa se produce muy temprano), puede causar detonaciones, que son explosiones no controladas de la mezcla de aire-combustible.
- Las detonaciones pueden dañar el motor y reducir su vida útil (Stone, 2012).

Condiciones Operativas:

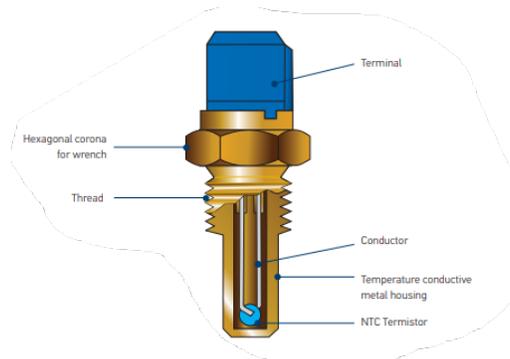
- La posición del avance del encendido varía dependiendo de las condiciones operativas del motor, como la carga, la velocidad del motor, y la temperatura del aire de admisión.
- Los sistemas modernos de gestión del motor ajustan el avance del encendido en tiempo real para optimizar el rendimiento y la eficiencia bajo diferentes condiciones (Pulkrabek, 2004).

5.1.9. Sensor de temperatura del motor (ECT)

El sensor ECT registra la temperatura del motor y vigila la cantidad de calor que emite. Este dispositivo, junto con el módulo de control del motor (ECM), garantiza que el motor opere a la temperatura adecuada. Emplea un termistor NTC en la que su resistencia cambia con la temperatura; el ECM transporta un voltaje al sensor y utiliza la variación de resistencia para rastrear el ajuste de temperatura. La información del sensor se emplea para ajustar la inyección del carburante, el momento de encendido, controlar la velocidad del ventilador del radiador y actualizar el indicador de temperatura en el tablero. El ECT se suele colocar en la carcasa del termostato y es fundamental para la supervisión térmica del motor (Ahmed, 2020).

Figura 5

Sensor de temperatura del motor (ECT).



Nota: Sensor de temperatura del motor Hella (Hella, 2023).

5.2. Ajuste de combustible a largo plazo (LTFT)

El ajuste a largo plazo de la proporción de combustible (LTFT) es una calibración efectuada por la unidad de control del motor (ECU o PCM) para conservar la proporción

aire-combustible en niveles idóneos a lo largo de un extenso período. Este ajuste se fundamenta en el feedback proporcionado por los sensores de oxígeno, que monitorean el contenido de oxígeno en los gases de escape para determinar si la mezcla aire-combustible es demasiado rica (exceso de combustible) o demasiado pobre (exceso de aire) (Car Truck, 2024).

Características:

- Propósito: El LTFT ayuda a compensar las desviaciones en la mezcla aire-combustible que pueden resultar de factores como el desgaste del motor, cambios en las condiciones ambientales, o la acumulación de depósitos en los inyectores de combustible (General Technologies Corp., 2024).

- Funcionamiento: Ajustes continuos: La ECU ajusta constantemente la cantidad de combustible inyectado para mantener la relación ideal aire-combustible (λ). Si los sensores de oxígeno detectan una mezcla rica o pobre, la LTFT aumentará o disminuirá la cantidad de combustible suministrado.

Almacenamiento de datos: A diferencia del ajuste de combustible a corto plazo (STFT), que ajusta la mezcla instantáneamente, los cambios en la LTFT se almacenan en el registro de la ECU y se actualizan lentamente para reflejar las adaptaciones a largo plazo (Trade Mechanic, 2024).

- Valores normales:

- Cerca del 0%: Idealmente, los valores de LTFT deberían estar cerca del 0% cuando el motor funciona a una velocidad constante. Esto indica que la mezcla aire-combustible está equilibrada (General Technologies Corp., 2024).
- Rango aceptable: En la práctica, los valores entre -10% y +10% se consideran normales. Valores fuera de este rango pueden indicar problemas en el circuito de combustible, sensores defectuosos o fugas en el circuito (Trade Mechanic, 2024).

- Interpretación de los valores: Valores Positivos: indican que la ECU está añadiendo más combustible para corregir una mezcla demasiado pobre (exceso de aire).

- Valores Negativos: Indican que la ECU está disminuyendo la cantidad de gasolina para corregir una mezcla sobrealimentada (exceso de combustible) Trade Mechanic (2024).

- Problemas comunes:

- Sensor de oxígeno defectuoso: Un mal funcionamiento del sensor de oxígeno puede conducir a ajustes LTFT incorrectos.

- Fugas del sistema: Las fugas del sistema de vacío o de escape pueden alterar las lecturas del sensor y afectar a la LTFT.
 - Fallo del sensor de flujo de aire: Un sensor de flujo de masa de aire (MAF) defectuoso puede enviar datos incorrectos a la ECU, lo que resulta en ajustes LTFT incorrectos (The Drive, 2024).
- Recomendaciones:
 - Arias Montaña y Ludeña Ayala (2018) recomienda que antes de las pruebas, es crucial que el motor esté en perfectas condiciones. Se debe realizar un mantenimiento preventivo para evitar fallas durante la recopilación de datos. Se debe preparar el vehículo y los equipos necesarios para medir el consumo de combustible y las emisiones de gases contaminantes.

5.3. Ajuste de combustible a corto plazo (STFT)

El Ajuste de Combustible a Corto Plazo (STFT) es una corrección que realiza la ECU o PCM para equilibrar la proporción aire/combustible, reaccionando de manera rápida a los cambios en las condiciones del motor. Esta corrección se basa en los valores registrados por los sensores de oxígeno que monitorean los gases de escape antes del catalizador. Dependiendo de si la integración es excesivamente rica o pobre, la ECU modifica el nivel de combustible inyectado para corregirlo (General Technologies Corp., 2024) (The Tuning School, 2024).

Características:

- Finalidad: El STFT realiza ajustes inmediatos de la combinación aire-combustible, lo que permite al motor reaccionar rápidamente a los cambios de carga, como aceleraciones repentinas o variaciones de velocidad (General Technologies Corp., 2024).
- Funcionamiento:
 - Ajustes inmediatos: La ECU modifica la inyección de combustible varias veces por segundo en función de las lecturas del sensor de oxígeno. Si la combinación es demasiado rica, la ECU reducirá el suministro de combustible; si es demasiado pobre, lo aumentará.
 - Temporalidad: A diferencia de la LTFT, los ajustes de la STFT no se almacenan en el registro de la ECU. Estos ajustes son temporales y se recalculan continuamente mientras el motor está en marcha (General Technologies Corp., 2024; The Tuning School, 2024).

- Valores Normales:
 - Fluctuaciones Rápidas: Los valores STFT pueden cambiar rápidamente y generalmente permanecen dentro de un rango de $\pm 5\%$. En motores antiguos, este rango puede ser mayor, llegando hasta $\pm 10\%$ (The Tuning School, 2024).
 - Indicadores de problemas: Los valores STFT consistentemente fuera del rango normal pueden señalar problemas tales como fugas en los inyectores de combustible, fugas de vacío o sensores defectuosos (The Tuning School, 2024).

- Interpretación de los Valores:
 - Valores Positivos: indican que la ECU está añadiendo más combustible para rectificar una combinación pobre (exceso de aire).
 - Valores negativos: indican que la ECU está atenuando la entrega de gasolina para corregir la integración rica (exceso de combustible) (General Technologies Corp., 2024)).

- Problemas Comunes:
 - Fallas del Sensor de Oxígeno: Un sensor de O_2 defectuoso puede causar ajustes incorrectos en el STFT.
 - Fugas de vacío: Las fugas en el sistema de admisión pueden alterar las lecturas del sensor de oxígeno y afectar al STFT.
 - Problemas con el sensor de flujo de aire: Un sensor de flujo de masa de aire (MAF) sucio o defectuoso puede causar lecturas incorrectas y ajustes incorrectos en el STFT (CarParts.com, 2024; General Technologies Corp., 2024).

5.4. Sensor de posición del acelerador (TPS)

Es un dispositivo esencial en los motores de los vehículos. Este sensor determina y supervisa la ubicación de la válvula de mariposa, proporcionando parámetros en tiempo real a la ECU.

Los parámetros obtenidos permite a la ECU ajustar con precisión la inyección de combustible y el tiempo de encendido, lo cual es crucial para un rendimiento óptimo del motor, la eficiencia del combustible y el control de emisiones (NAPA Know How, 2024; Wikipedia, 2024).

Características:

- **Ubicación:** El TPS se encuentra normalmente en el cuerpo del acelerador. Esta posición le permite monitorear directamente la apertura del acelerador, facilitando así los ajustes necesarios a la mezcla aire/combustible que entra al motor (The Motor Guy, 2024).
- **Funcionamiento:**
 - **Detección de posición:** El TPS detecta la ubicación del acelerador y transporta los datos a la ECU. Basándose en estos datos, la ECU ajusta la cantidad de gasolina inyectado y el tiempo de encendido para mantener una combustión óptima.
 - **Tipos de TPS:** Los sensores modernos incluyen tecnologías como los sensores de efecto Hall, inductivos y magnetorresistivos, que no requieren contacto físico. En los sensores de tipo potenciómetro, una escobilla metálica se mueve sobre una banda resistiva, alterando la resistencia medida y enviando la señal resultante a la ECU (NAPA Know How, 2024; Wikipedia, 2024).
- **Importancia para el rendimiento del motor:**
 - **Eficiencia y Rendimiento:** Un TPS que funciona correctamente asegura una aceleración suave y un funcionamiento adecuado del motor, optimizando el consumo de la gasolina y disminuyendo las emisiones.
 - **Problemas Comunes:** Si el TPS falla, pueden producirse problemas como un ralentí áspero, vacilación durante la aceleración o incluso la parada del motor. Estos problemas pueden afectar significativamente al rendimiento del vehículo y a la seguridad de la conducción (Montgomery y Runger, 2014).

5.5. Sensor de velocidad del vehículo (VSS)

El Sensor de Velocidad del Vehículo (VSS) brinda datos de velocidad del vehículo, que la Unidad de Control del Motor (PCM) utiliza para diversas funciones.

Estas incluyen:

- **Determinar la velocidad mínima de conducción.** Comunicar al conductor de la velocidad actual mediante del cuadro de mandos eléctrico-digital.

- Ajustar la sincronización del encendido. Controlar la cantidad de inyección de combustible. Existen varios tipos de sensores VSS, como los de tipo interruptor de línea (interruptor de láminas), ópticos y de efecto Hall.
- Ubicación: El VSS suele encontrarse en la caja del diferencial, la caja de cambios o al reverso del marco de instrumentos.

Sensor de tipo interruptor de línea (interruptor de láminas): Este sensor consiste principalmente en un imán y un interruptor de láminas, con una de las láminas hecha de material ferromagnético, y el cable del velocímetro. Cuando el imán rota, atrae la red ferromagnética, doblándolo hasta que hace contacto con el otro red, cerrando el circuito. Cuando el imán se separa, la lámina vuelve a su posición inicial y el circuito se abre (Andrés Gustavo Loja Cajas, 2012).

Este proceso genera cuatro impulsos por cada revolución del imán. El PCM utiliza el número de impulsos emitidos por el VSS para calcular la velocidad del vehículo. El sensor genera una señal digital, similar a la del sensor de efecto Hall, que incrementa de frecuencia a medida que incrementa la velocidad del imán (Andrés Gustavo Loja Cajas, 2012).

5.6. Mantenimiento Correctivo

El mantenimiento correctivo se centra en la reparación o sustitución de componentes tras un fallo. Es una de las estrategias de mantenimiento más tradicionales y se basa en la idea de “arreglarlo cuando se rompe”. Este tipo de mantenimiento no requiere una supervisión constante ni un análisis previo del riesgo de fallo (Jambor-Sadeghi, Ketabchi, Chue, y Ghiassi, 1994).

Características:

- Acción posterior al fallo: solo se realiza después de que se produzca un fallo, sin medidas preventivas previas (Jambor-Sadeghi y cols., 1994).
- Coste a corto plazo: Puede ser más económico a corto plazo, ya que las reparaciones no se realizan hasta que son absolutamente necesarias.
- Tiempo de inactividad: Puede generar tiempos de inactividad no planificados, afectando a la producción y a la eficiencia operativa.
- Ejemplo de aplicación: En la industria manufacturera, el mantenimiento correctivo se utiliza para resolver problemas urgentes en maquinaria crítica, garantizando que los equipos vuelvan a funcionar lo antes posible.

5.7. Mantenimiento Preventivo

El mantenimiento preventivo se refiere a las inspecciones y reparaciones planificadas que se realizan en equipos e instalaciones para evitar fallos inesperados. Esta estrategia se aplica a intervalos regulares, en función del tiempo de uso o de un calendario, y su principal objetivo es mejorar la fiabilidad y extender la utilidad de los equipos.

Características:

- Programación regular: las actividades de mantenimiento preventivo se llevan a cabo en momentos predefinidos, como cada mes, cada 100 horas de funcionamiento o después de determinados kilómetros recorridos. Esto permite una gestión sistemática y estructurada del mantenimiento (Road to Reliability, 2024).
- Prevención de fallos: El principal objetivo del mantenimiento preventivo es reconocer y corregir los problemas antes de que causen fallos graves. Esto ayuda a mantener los equipos en buen estado y evita interrupciones inesperadas en las operaciones (Basri y otros, 2017).

Tipos de mantenimiento preventivo:

- Basado en el tiempo: Los componentes se sustituyen o renuevan a intervalos fijos, independientemente de su estado actual.
- Basado en el estado: El estado de los equipos se supervisa continuamente para detectar signos de desgaste o fallos inminentes, lo que permite intervenir antes de que se produzcan.
- Predictivo: Utiliza tecnologías avanzadas y análisis de datos para predecir cuándo es probable que se produzca un fallo, lo que permite planificar la intervención a tiempo (Road to Reliability, 2024).
- Mejora de la fiabilidad: Al prevenir los fallos, el mantenimiento preventivo aumenta la fiabilidad de los equipos y reduce los tiempos de inactividad imprevistos, lo que se traduce en un funcionamiento más eficiente y menos costoso a largo plazo (Basri y otros, 2017).

5.8. Mantenimiento Predictivo (PdM)

La industria 4.0 está vinculado con la combinación de los sistemas físicos y digitales dentro del escenario de producción. Esta combinación facilita el aparcamiento de una gran cantidad

de datos obtenidos por los distintos equipos dentro del centro productivo.

El mantenimiento predictivo (PdM) utiliza herramientas de previsión para establecer cuándo se necesitan las prácticas de mantenimiento. Está basado en el monitoreo permanente de la condición de la máquina o el procedimiento, lo que facilita el realizar el mantenimiento tan solo si es necesario. Por otra parte, se puede realizar la detección de anticipada de fallas utilizando herramientas de pronósticos basados en el aprendizaje automático, entre otras (Carvalho y cols., 2019).

El mantenimiento predictivo se basa en la supervisión periódica del estado mecánico real, la eficiencia operativa, y otros indicadores del estado de proceso de operabilidad, que proporcionaran datos que nos permitirán alargar la distancia entre reparaciones y disminuir el coste por interrupciones no programadas. El mantenimiento predictivo es un medio estratégico que busca mejorar la productividad, excelencia del producto, y la eficacia de la máquina y su entorno (Gutiérrez, 2009).

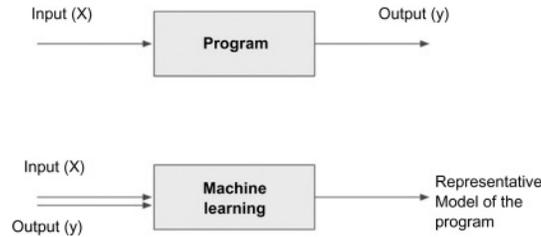
5.9. Aprendizaje Automático (ML)

El aprendizaje automático es un subconjunto de inteligencia artificial que permite que un sistema comprenda y se optimice de forma autónoma mediante redes neuronales y aprendizaje profundo, es decir, dar la capacidad a las máquinas de aprender de la experiencia. La experiencia para las máquinas se basa en datos, que son denominados datos de entrenamiento (Carlos, 2020) (Kotu y Deshpande, 2019).

El ML difiere totalmente de la programación tradicional, ya que este toma los parámetros de ingreso y los parámetros de salida que permita detectar un modelo que permita convertir la entrada en salida, como se muestra en la fig (Kotu y Deshpande, 2019).

Figura 6

Programación tradicional y aprendizaje automático.



Nota: Programación tradicional y aprendizaje automático (Kotu y Deshpande, 2019).

MathWorks (2024) El aprendizaje automático, una sub disciplina de la inteligencia artificial, se enfoca en crear algoritmos que capaciten a las computadoras para aprender a partir de los datos y realizar predicciones o tomar decisiones sin necesidad de una programación explícita. En MATLAB, este proceso se lleva a cabo a través de varios pasos específicos: recolección de datos, preprocesamiento, extracción de características, entrenamiento de modelos, validación y, finalmente, implementación de los modelos entrenados.

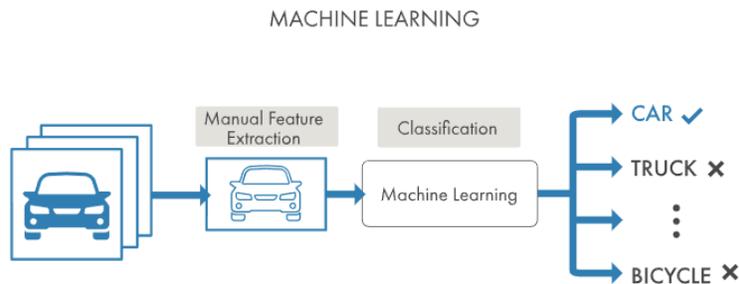
Pasos del flujo de trabajo en el aprendizaje automático con MATLAB

- Acceso y carga de datos: Los datos son capaces de proceder de diversas fuentes, como bases de datos, dispositivos de streaming, etc. MATLAB permite importar fácilmente estos datos y gestionar las variables en el espacio de trabajo.
- Preprocesamiento de datos: Esta fase es crucial para cambiar los datos en un formato adecuado para los algoritmos de ML. Incluye tareas como la limpieza de datos, la normalización y la extracción de características. En MATLAB, existen herramientas que pueden simplificar el proceso de aplicación de funciones de extracción de características a los datos.
- Extracción de características: A partir de los datos preprocesados, se obtienen características que ayudarán a construir el modelo. Esto puede incluir el cálculo de medias, desviaciones estándar y análisis de componentes principales (PCA).
- Entrenamiento del modelo: Dependiendo del tipo de tarea (clasificación o regresión), se eligen diferentes algoritmos de aprendizaje automático. MATLAB proporciona aplicaciones como Clasificación Lineal y Regresión lineal que facilitan la interacción con varios modelos y permiten comparar su rendimiento.

- Validación: Para evitar el sobre ajuste, se utiliza la validación cruzada u holdout validación. Este paso garantiza que el modelo funcione bien no solo con los datos de entrenamiento, sino también con datos nuevos.
- Aplicación: Una vez entrenado y validado el modelo, puede implantarse en entornos de producción. MATLAB permite generar código C/C++ para implementarlo en sistemas integrados o de producción.

Figura 7

Machine Learning



Nota: Esquema Machine Learning (MathWorks, 2024).

A continuación se puede observar aplicaciones de modelos de aprendizaje automático dentro del área automotriz.

En el proyecto planteado por Néstor Diego, Molina Campoverde, Quirola Novillo, y Naula Bermeo (2020) se observa la aplicación de un modelo de aprendizaje automático, aquí “un algoritmo es capaz de visualizar el comportamiento de las señales PID de un vehículo mediante la identificación de maniobras de conducción comunes tales como: arranque, cambio de marcha y frenado del motor durante una prueba en carretera”.

Asimismo, Molina Campoverde, Rivera Campoverde, Novillo Quirola, y Bermeo Naula (2020) proponen “un algoritmo que es capaz de identificar eventos de frenado y embrague, además de clasificar si el vehículo tiene un sistema de aceleración del cuerpo motorizado o mecánico. Con el algoritmo utilizado, es posible determinar el estilo de conducción durante las pruebas piloto y el cambio más utilizado en una ruta”.

5.10. Modelos de aprendizaje automático.

5.10.1. Árbol de decisión (árbol fino)

- Ventajas:

- Interpretabilidad: Los árboles de decisión son sencillos de entender y visualizar. Cada nodo en el árbol refleja una decisión basada en una característica particular, lo que simplifica la comprensión del proceso de clasificación.
- Predicción rápida: Tienen una alta velocidad de predicción, lo que los hace adecuados para aplicaciones en tiempo real (Hastie, Tibshirani, y Friedman, 2009).
- Manejo de características no lineales: Pueden capturar relaciones no lineales entre características sin necesidad de complejas transformaciones (Breiman, Friedman, Olshen, y Stone, 1984).
- No necesitan estandarización: No requieren que las características estén estandarizadas, ya que la métrica de distancia no se utiliza en el modelo (James, Witten, Hastie, y Tibshirani, 2013).

- Desventajas:

- Sobreajuste: Los árboles de decisión pueden sobre ajustarse fácilmente a los datos de entrenamiento si no se podan adecuadamente, especialmente cuando se permiten muchas divisiones.
- Sesgo hacia características con más niveles: Pueden estar sesgados hacia características con más niveles/categorías (Hastie y cols., 2009).

5.10.2. Máquina de vectores de soporte lineal SMVL

Una SVM clasifica los datos determinando el límite de decisión lineal (o hiperplano) que separa los puntos de una clase de los de otra. El hiperplano ideal para una SVM es aquel que maximiza el margen entre las dos clases cuando los datos son separables linealmente. Si los datos no son linealmente separables, se aplica una función de pérdida que penaliza los puntos que quedan en el lado incorrecto del hiperplano. Las SVM también pueden usar una función de núcleo para proyectar datos no separables linealmente a dimensiones superiores, donde es posible encontrar un límite de decisión lineal (MathWorks, 2024)

- Ventajas:

- Eficiencia: Muy eficiente para problemas de clasificación binaria con datos linealmente separables (Schölkopf y Smola, 2002).
 - Generalización: SVM con margen máximo tiene buena capacidad de generalización, evitando el sobreajuste (Smola y Schölkopf, 2004).
 - Espacio de alta dimensión: funciona bien en espacios de alta dimensión (Bishop, 2006).
- Desventajas:
 - Eficiencia en problemas multiclase: Puede ser menos eficiente en problemas multiclase debido a la necesidad de construir múltiples clasificadores (Hsu, Chang, y Lin, 2002).
 - Requiere estandarización: Necesita que los datos estén estandarizados para un rendimiento óptimo (Smola y Schölkopf, 2004).
 - Limitaciones en relaciones no lineales: No maneja bien las relaciones no lineales sin el uso de un kernel adecuado (Bishop, 2006).

5.10.3. Árbol de decisión (árbol medio)

Un árbol de decisión predice resultados analizando las decisiones desde la raíz hasta los nodos hoja. El árbol está constituido por condiciones de ramificación donde el valor de un predictor se compara con un umbral específico durante el proceso de entrenamiento. Este proceso establece tanto el número de ramas como los valores de esos umbrales. Para simplificar el modelo, se puede utilizar una técnica adicional llamada poda (MathWorks, 2024).

- Ventajas:
 - Equilibrio entre complejidad y precisión: Proporciona un buen equilibrio entre la capacidad de modelar relaciones complejas y evitar el sobreajuste (Breiman y cols., 1984).
 - Rapidez en las Predicciones: Al igual que el Árbol Fino, tiene una alta velocidad de predicción (Hastie y cols., 2009).
 - Interpretabilidad: Sigue siendo relativamente fácil de interpretar y visualizar (Breiman y cols., 1984).
- Desventajas:

- Capacidad limitada: La capacidad de modelar relaciones muy complejas es limitada en comparación con modelos más profundos o con más nodos.
- Sobre ajuste: Aunque menos probable que Fine Tree, todavía puede realizar el sobreajuste si no se controla adecuadamente (James y cols., 2013).

5.10.4. K-Nearest Neighbors (KNN fino)

- Ventajas:

- Simplicidad: El algoritmo es sencillo de entender e implementar (Bishop, 2006).
- No hace suposiciones sobre la forma funcional: No hace suposiciones sobre la distribución de los datos (Hastie y cols., 2009).
- Adaptabilidad local: Puede capturar patrones locales en los datos.

- Desventajas:

- Costoso desde el punto de vista informático: Tanto en términos de tiempo como de memoria, especialmente para grandes conjuntos de datos (Bishop, 2006).
- Efecto del ruido: Muy sensible al ruido en los datos de entrenamiento, especialmente con k pequeños (Hastie y cols., 2009).
- Necesita estandarización: Requiere que las características estén estandarizadas para que la métrica de distancia funcione correctamente.

5.10.5. SVM gaussiana gruesa (Coarse Gaussian SVM)

- Ventajas:

- Captura relaciones no lineales: Utiliza un kernel gaussiano que puede capturar relaciones no lineales en los datos (Schölkopf y Smola, 2002).
- Generalización: Tiene buena capacidad de generalización con máximo margen (Smola y Schölkopf, 2004).
- Eficiencia: Más costoso computacionalmente en términos de tiempo de entrenamiento y predicción en comparación con los modelos lineales (Bishop, 2006).

- Desventajas:

- Complejidad en la selección de hiperparámetros: La selección de parámetros como la escala del kernel y la restricción de caja puede ser compleja (Hsu y cols., 2002).
- Coste computacional: Más caro computacionalmente en términos de tiempo de entrenamiento y predicción en comparación con los modelos lineales (Bishop, 2006).
- Requiere estandarización: Necesita que los datos estén estandarizados para un rendimiento óptimo (Smola y Schölkopf, 2004).

5.10.6. Red neuronal media (Medium Neural Network)

Basada en la estructura del cerebro humano, una red neuronal está compuesta por nodos interconectados, denominados neuronas, organizados en capas para conectar las entradas con las salidas deseadas. Durante el entrenamiento del modelo de aprendizaje automático, se ajustan iterativamente las intensidades de estas conexiones para que las entradas correspondan correctamente con las salidas esperadas (MathWorks, 2024).

Las neuronas situadas entre las capas de entrada y salida se conocen como capas ocultas. Las redes neuronales superficiales cuentan con pocas capas ocultas, mientras que las redes neuronales profundas tienen muchas más, a menudo hasta cientos de capas ocultas (MathWorks, 2024).

Las redes neuronales se pueden diseñar para resolver problemas de clasificación o regresión, añadiendo una capa de salida específica al final de la red. Para tareas de aprendizaje profundo, como el reconocimiento de imágenes, se pueden utilizar modelos de aprendizaje profundo preentrenados. Entre los tipos más comunes de redes neuronales profundas se encuentran las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN) (MathWorks, 2024).

■ Ventajas:

- Capacidad para modelar la complejidad: Puede capturar relaciones complejas y no lineales en los datos (Goodfellow, Bengio, y Courville, 2016).
- Alta Precisión: Generalmente ofrece una alta precisión en comparación con otros modelos simples (Nielsen, 2015).
- Adaptabilidad: La función de disparo ReLU ayuda a manejar problemas de desvanecimiento de gradiente, mejorando el entrenamiento (Goodfellow y cols., 2016).

■ Desventajas:

- Tiempo de entrenamiento: Puede ser más lento de entrenar en comparación con otros modelos más simples (Goodfellow y cols., 2016).
- Riesgo de sobreajuste: Sin regularización ($\lambda=0$), puede sobreajustarse a los datos de entrenamiento (Nielsen, 2015).
- Necesidad de grandes datos: Las redes neuronales suelen requerir grandes cantidades de datos para entrenarse eficazmente (Goodfellow y cols., 2016). Requieren estandarización: Los datos deben ser estandarizados para un rendimiento óptimo (Nielsen, 2015).

Para realizar el entrenamiento de los diferentes modelos de aprendizaje es necesario disponer de una gran cantidad de datos, para lo cual disponemos de la herramienta Freematics, Escáner, y como lo proponen Vergara, Ramos, Rivera-Campoverde, y Rivas-Echeverría (2023) que utilizaron “instrumentos como el analizador de gases NGA 6000 y la tarjeta de adquisición de datos USB 6008 de National Instruments”. Estos dispositivos garantizarán la alta precisión de los datos capturados y la cobertura de una gran variedad de parámetros del motor.

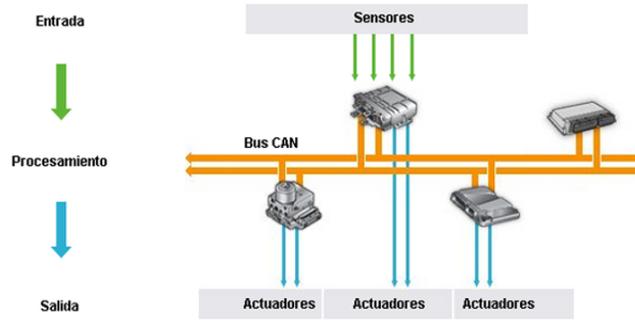
5.11. Protocolo de red de área de control (CAN)

El Protocolo de Red de Área de Control (CAN) es un estándar de comunicación robusto y eficiente utilizado principalmente en automóviles, pero también en otros contextos industriales. CAN permite que microcontroladores y dispositivos se comuniquen entre sí sin necesidad de un ordenador central, lo que resulta ideal para aplicaciones en las que la fiabilidad y la velocidad son cruciales.

- Características:
 - Comunicaciones multimaestro: Permite que varios nodos de la red transmitan datos, lo que mejora la flexibilidad y redundancia del sistema, así mismo aumenta la robustez y elimina los puntos únicos de fallo (Boland, Burgett, Etienne, y III, 2021).
 - Velocidad de transferencia de datos: Admite velocidades de hasta 1 Mbps. Adecuado para aplicaciones que requieren altas velocidades de datos (Boland y cols., 2021).
 - Eficiencia y baja latencia: El protocolo es eficiente en ancho de banda, tiene baja latencia de comunicación, permitiendo almacenar grandes volúmenes de datos (Boland y cols., 2021).

Figura 8

Protocolo de red de área de control (CAN)



Nota: Esquema del protocolo de red de área de control (CAN) (CAM2, 2024).

5.12. Desviación Estándar.

La desviación estándar es una métrica que mide el grado de variación o dispersión en un conjunto de datos. Una desviación estándar baja sugiere que los valores están cercanos a la media del conjunto, mientras que una desviación estándar alta indica que los valores están distribuidos en un rango más extenso. (Montgomery y Runger, 2014).

Para una población de tamaño N con valores x_i y media μ , la desviación estándar σ se define como:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$$

Para una muestra de tamaño n , la desviación estándar s se calcula como:

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

donde:

- x_i representa cada valor en el conjunto de datos.
- μ es la media de todos los valores en la población.
- \bar{x} es la media de la muestra.

- N es el número de valores en la población.
- n es el número de valores en la muestra.

5.13. Máximos y Mínimos

En matemáticas, un máximo (o valor máximo) de una función es el punto en el cual la función alcanza su valor más alto en una región específica o en todo su dominio. De manera similar, un mínimo (o valor mínimo) es el punto donde la función alcanza su valor más bajo. Estos puntos son cruciales en el análisis de funciones, ya que proporcionan información sobre el comportamiento de la función y su tendencia (Stewart, 2015).

Para una función $f(x)$:

- Un **máximo local** es un punto $x = a$ donde $f(a) \geq f(x)$ para todos los x en una vecindad alrededor de a .
- Un **mínimo local** es un punto $x = b$ donde $f(b) \leq f(x)$ para todos los x en una vecindad alrededor de b .
- Un **máximo global** es el punto $x = c$ donde $f(c) \geq f(x)$ para todos los x en el dominio de la función.
- Un **mínimo global** es el punto $x = d$ donde $f(d) \leq f(x)$ para todos los x en el dominio de la función.

5.14. Matriz de correlación

La matriz de correlación es una herramienta esencial en el análisis estadístico multivariante, empleada para evaluar la relación entre diversas variables. En el libro “Applied Multivariate Statistical Analysis” Johnson y Wichern (2007) explica en detalle cómo estas matrices pueden ser utilizadas para identificar y cuantificar la fuerza y dirección de las relaciones entre múltiples variables.

Definición y Cálculo

Una matriz de correlación contiene los coeficientes de correlación de Pearson para cada par de variables en un conjunto de datos. Cada valor en la matriz varía entre -1 y 1, donde:

- 1 indica una correlación positiva perfecta.

- 0 indica que no hay correlación lineal.
- -1 indica una correlación negativa perfecta.

El coeficiente de correlación de Pearson se calcula utilizando la fórmula:

$$r_{xy} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (1)$$

5.15. Freematics ONE+

El dispositivo Freematics ONE+ es una mochila OBD compacta y avanzada que se conecta directamente al puerto OBD-II de un vehículo. Está diseñado para supervisar y registrar los datos del vehículo, así como para transmitir información en tiempo real. Algunas de sus características clave incluyen:

- Integración de ESP32 MCU: un sistema en chip (SoC) programable con WiFi y Bluetooth, que permite la conectividad y el control a través de una aplicación móvil.
- Módulo celular 4G LTE-M y GNSS de 10 Hz: Proporciona geolocalización de alta precisión y capacidad de transmisión de datos en tiempo real a través de la red celular.
- Compatibilidad con todos los PID OBD-II estándar: Permite acceder a los códigos de diagnóstico de problemas (DTC), al VIN y a los datos del bus CAN, proporcionando una supervisión completa del vehículo
- Sensores integrados: Incluye un sensor de movimiento ICM-42627 para la detección de fuerza G y movimiento, y un módulo GNSS u-blox M10 para una geolocalización precisa.
- Almacenamiento y transmisión de datos: Admite tarjetas microSD de hasta 32 GB para almacenamiento masivo y ofrece transmisión de datos en tiempo real a través de WiFi y red celular.
- E/S externas: Dispone de un zócalo de E/S externas con pines configurables que permiten la conexión de sensores y controladores adicionales, facilitando la ampliación de sus funcionalidades.
- Amplia compatibilidad: Funciona con varios protocolos OBD-II, incluyendo CAN 500Kbps/29bit, CAN 250Kbps/29bit, CAN 500Kbps/11bit, CAN 250Kbps/11bit y KWP2000.

- El dispositivo también mide el voltaje de la batería del coche y puede configurarse y controlarse a través de una aplicación móvil mediante Bluetooth Low Energy (BLE). Con unas dimensiones compactas de 60 x 48 x 20 mm, el Freematics ONE+ es una potente herramienta de telemetría y diagnóstico de vehículos

Figura 9

Freematics ONE+



Nota: Dispositivo de adquisición de datos Freematics ONE+ (Freematics, 2024).

Se puede observar en el trabajo propuesto por Campoverde, Campoverde, Espinoza, Fernandez, y Novillo (2022) un modelo de estimación de NOx (Óxidos Nitrosos) que se realiza con la adquisición de datos utilizando este dispositivo, donde permite tener la geolocalización con la ayuda del posicionamiento global.

5.16. Scanner MaxiSys MS906

MaxiSys MS906 - autel (s.f.) describe que el dispositivo cuenta con nuevas y mejoradas características que se detalla a continuación:

- Procesador Samsung Exynos de seis núcleos extraordinariamente potente.
- Pantalla capacitiva Multi Touch brillante, con iluminación LED de 8,0"1024 x 768 con tecnología IPS.

- Disco duro interno de estado sólido SSD fiable, de 32GB para el mejor rendimiento.
- Cámara trasera integrada de 8 megapíxeles, con autoenfoco y flash.
- La cobertura más completa y amplia de Sistemas, para más de 80 marcas de vehículos Americanos, Asiáticos y Europeos.
- Cobertura excepcional, a nivel OE para todos los Sistemas electrónicos a bordo.
- Capacidades completas para el despliegue de información de ECU, Códigos de falla, y Datos en vivo, y ejecución de Pruebas Activas, Funciones de Servicio, Calibraciones, Ajustes, Resets, Adaptaciones, Hermanamiento, Programaciones, y más.
- Tecnología inteligente AutoVIN y AutoScan, para identificar fácil y automáticamente los vehículos y sus sistemas a bordo

Figura 10

Scanner MaxiSys MS906



Nota: Dispositivo de adquisición de datos Scanner MaxiSys MS906 (*MaxiSys MS906 - autel, s.f.*).

6. Marco metodológico

Para el trabajo de titulación se realizó una investigación con enfoque cuantitativo, ya que se analizará los resultados del modelo de predicción de fallas.

La investigación es de tipo aplicado, ya que representa el funcionamiento del modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna.

Mientras que los alcances para el proyecto es de carácter exploratorio debido a que se analizará distintas fuentes bibliográficas para lograr un diseño apropiado del modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna. Esto se explica de mejor forma en la tabla 1.

Tabla 1

Cuadro de metodología de la Investigación

Investigación de:	Alcances	
Enfoque	<p>Cuantitativo: Análisis de datos: tipos y cantidad de variables a almacenar información</p>	<p>Exploratorio Identificar los componentes electrónicos, mecánicos necesarios para la adquisición de datos.</p>
De tipo	<p>Aplicada: Diseño de un modelo de predicción de fallas con el fin de identificar posibles fallas en motores de combustión interna.</p>	

Nota: En la tabla se observa la metodología de investigación para el trabajo de titulación.

6.1. Diagrama del proceso de adquisición de parámetros mediante las herramientas Freematics ONE+ y Scanner MaxisSys MS906

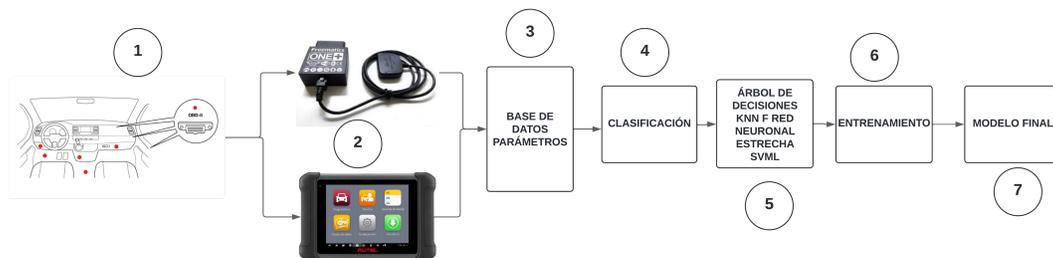
Se observa en el siguiente esquema la ruta del proceso para realizar el modelo de predicción de fallas mediante aprendizaje automático.

- 1. Vehículo a inyección electrónica con OBDII.
- 2. Herramientas de adquisición.
- 3. Parámetros adquiridos en formato (.CSV).
- 4. MATLAB y aplicación de modelos estadísticos.
- 5. Modelos de aprendizaje automático entrenados:
 - Árbol de decisiones.

- KNN fino.
- Red Neuronal Estrecha.
- Máquina de vectores de soporte lineal (SVML)

Figura 11

Esquema para el entrenamiento del modelo de aprendizaje final.



Nota: Esquema para el entrenamiento del modelo de aprendizaje final. (Guartazaca, 2024).

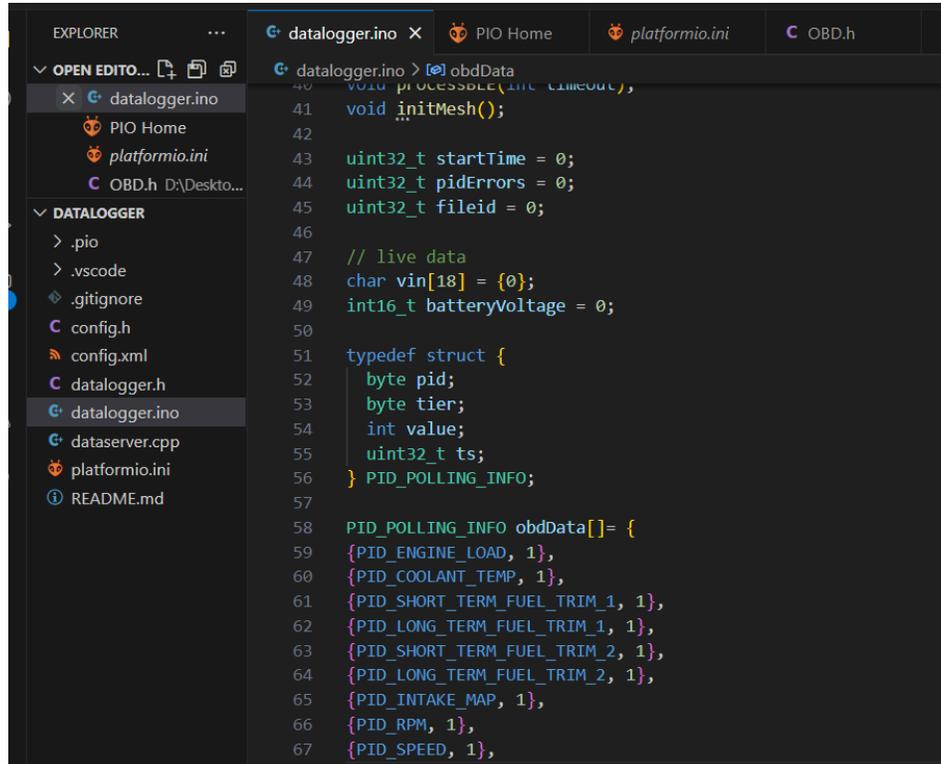
- 6. Entrenamiento modelo SVML.
- 7. Modelo de aprendizaje SVML final.

6.2. Desarrollo de la programación mediante el entorno de Visual Studio Code para el dispositivo "Freemetics ONE+" para la adquisición y almacenamiento de parámetros

Para mejorar la precisión y la capacidad de generalización del modelo de predicción de fallas en motores de combustión interna, se desarrolló un programa específico para la adquisición de datos utilizando el dispositivo Freemetics ONE+. Este programa está diseñado para recopilar datos clave de diferentes sensores del vehículo, lo que permite una mejor comprensión y análisis de las diversas condiciones operativas y fallas potenciales.

Figura 12

En torno de programación de adquisición de datos para el dispositivo Freematics ONE+.



```
40 void processBLE(int timeout),
41 void initMesh();
42
43 uint32_t startTime = 0;
44 uint32_t pidErrors = 0;
45 uint32_t fileid = 0;
46
47 // live data
48 char vin[18] = {0};
49 int16_t batteryVoltage = 0;
50
51 typedef struct {
52     byte pid;
53     byte tier;
54     int value;
55     uint32_t ts;
56 } PID_POLLING_INFO;
57
58 PID_POLLING_INFO obdData[] = {
59     {PID_ENGINE_LOAD, 1},
60     {PID_COOLANT_TEMP, 1},
61     {PID_SHORT_TERM_FUEL_TRIM_1, 1},
62     {PID_LONG_TERM_FUEL_TRIM_1, 1},
63     {PID_SHORT_TERM_FUEL_TRIM_2, 1},
64     {PID_LONG_TERM_FUEL_TRIM_2, 1},
65     {PID_INTAKE_MAP, 1},
66     {PID_RPM, 1},
67     {PID_SPEED, 1},
```

Nota: En torno de programación de adquisición de datos para el dispositivo Freematics ONE+ (Quartazaca, 2024).

6.3. Parámetros adquiridos

Tabla 2

Definiciones de Parámetros del Sensor

Parámetro	Descripción
ATE	Avance del Tiempo de Encendido
ECT	Temperatura del Refrigerante del Motor
LTFT	Ajuste a Largo Plazo de Combustible
MAP	Presión Absoluta del Colector
STFT	Ajuste a Corto Plazo de Combustible
RPM	Régimen de giro
IAT	Temperatura del Aire de Admisión
TPS	Posición del Sensor del Acelerador
VSS	Velocidad del Vehículo
CMV	Voltaje del Módulo de Control
MAF	Flujo de masa de aire
O ₂	Sensor de oxígeno

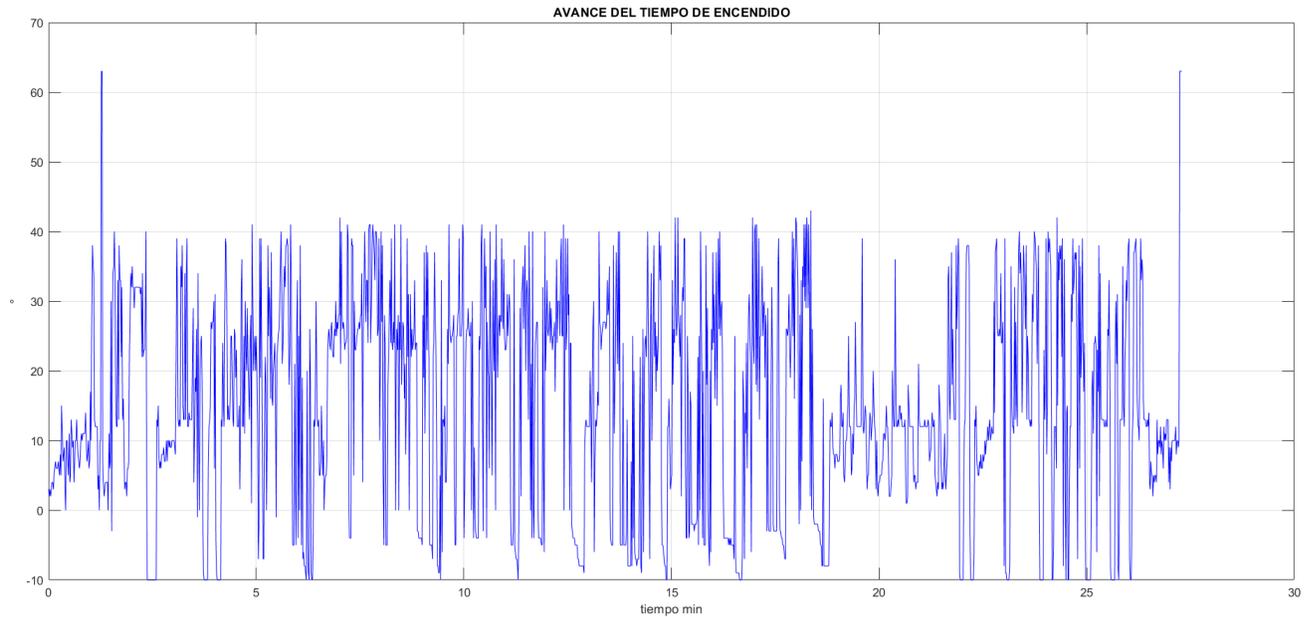
6.4. Análisis de los datos adquiridos y estructurados empleando técnicas estadísticas multivariantes.

6.4.1. Avance del tiempo de encendido (ATE).

La gráfica temporal del avance del tiempo de encendido muestra una notable variabilidad en los grados de avance a lo largo del tiempo. Durante los primeros 5 minutos, se observan fluctuaciones frecuentes entre 0° y 40°, lo cual indica ajustes constantes en respuesta a las condiciones del motor. Entre los 5 y 15 minutos, las variaciones se intensifican, alcanzando picos de hasta 60°, reflejando la adaptación del sistema a diversas demandas de conducción. Hacia el final del período, de 25 a 30 minutos, se observa una tendencia a estabilizarse alrededor de los 10° a 20°, aunque todavía presenta picos significativos.

Figura 13

Avance del tiempo de encendido.

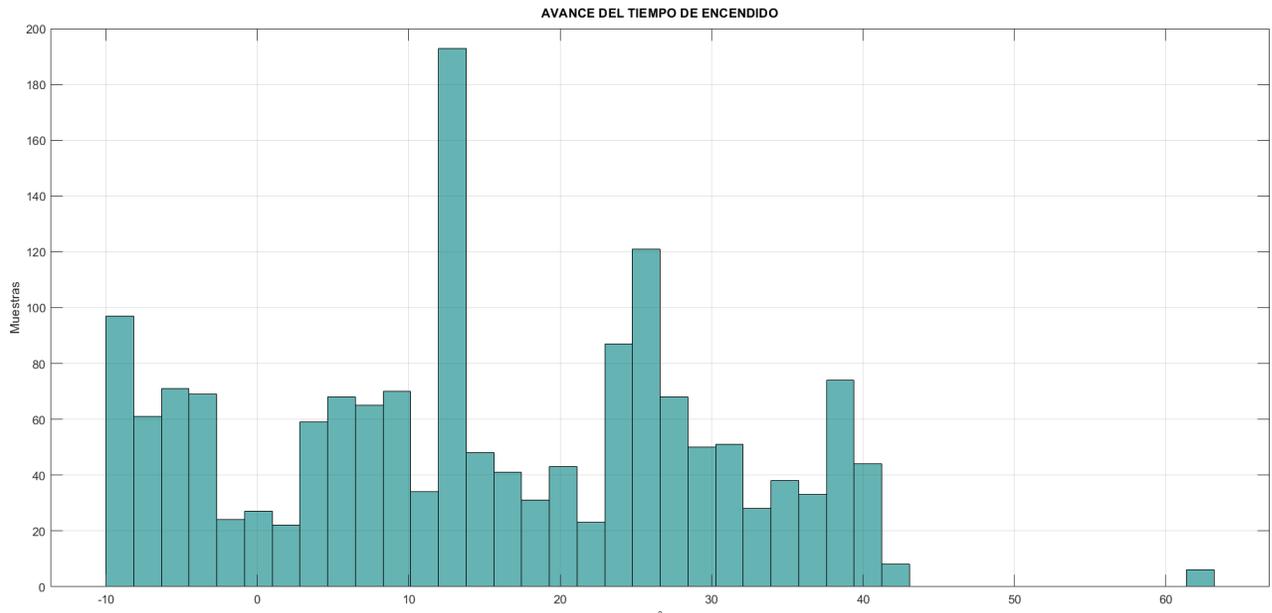


Nota: Gráfica temporal del avance del tiempo de encendido. (Guartazaca, 2024).

El histograma del avance del tiempo de encendido presenta una distribución que se centra alrededor de los 10° y 20° , con una media de 14.9177° . La mayor concentración de muestras se encuentra entre los 10° y 20° , lo que indica que el motor opera con mayor frecuencia en este rango de avance. Sin embargo, también se observan valores extremos, tanto negativos como positivos, que sugieren ajustes dinámicos bajo diversas condiciones operativas. La desviación estándar de 14.9186° refleja la alta variabilidad en los datos, destacando la capacidad del sistema de ajuste del encendido para adaptarse rápidamente a diferentes situaciones.

Figura 14

Histograma 1.



Nota: Histograma de avance del tiempo de encendido (ATE) (Guartazaca, 2024).

Tabla 3

Valores descriptivos del avance del tiempo de encendido

Propiedad	Valor	Unidad
Muestras	1654	°
Max	63	°
Min	-10	°
Desviación Estándar	14.9186	°
Media	14.9177	°
NumBins	40	

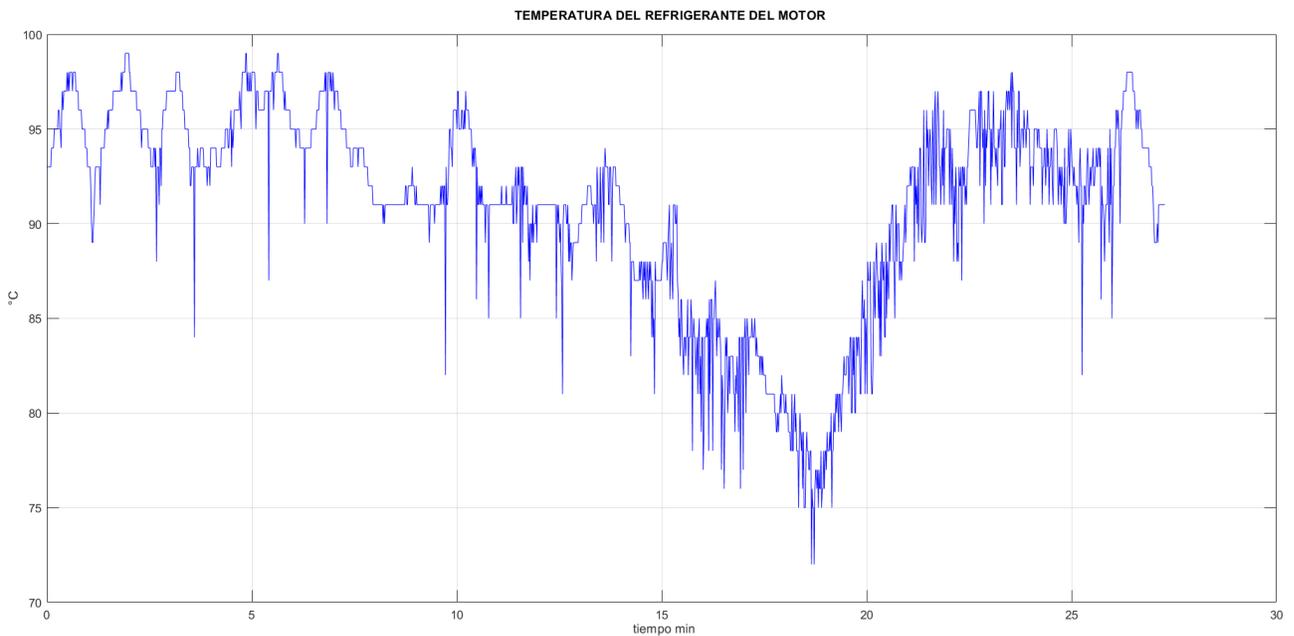
Nota: En la tabla se observa los valores máximos, mínimos, la desviación estándar, el número de bins, el número de muestras, de los parámetros adquiridos.

6.4.2. Sensor de temperatura del refrigerante del motor (ECT)

La figura 15 temporal ilustra cambios de la temperatura del refrigerante desde 70 °C a 100 °C, es decir, sobre-calentamiento y enfriamiento intermitentes del motor. Las cimas alrededor de 100 °C muestran una carga alta, y las depresiones equivalen a la inactividad o paro de las revoluciones del motor en esos instantes de tiempo.

Figura 15

Temperatura del refrigerante del motor, ECT.

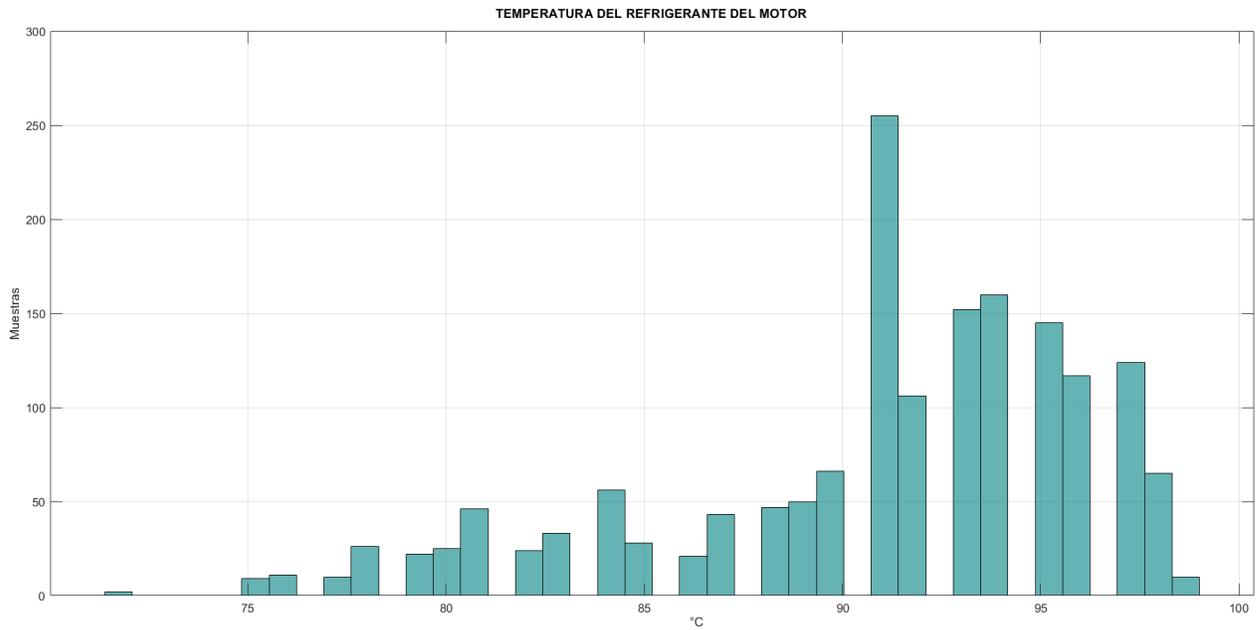


Nota: Gráfica de la temperatura del motor. (Guartazaca, 2024).

En el histograma 2 de la figura 16 se observa que las temperaturas se distribuyen en el rango de 85°C a 100°C, con un pico pronunciado alrededor de los 90 °C que indica que es la temperatura de funcionamiento óptima del motor de este vehículo.

Figura 16

Histograma 2.



Nota: Histograma de la temperatura del motor. (Guartazaca, 2024).

Con el valor de la desviación estándar $\sigma = 5.3925 \text{ }^\circ\text{C}$ indicada en la tabla 4, sugiere que las temperaturas se concentran alrededor del valor de la *media* = 90.9310°C , con algunas variaciones. La ausencia de valores extremos tanto máximos como mínimos indican que el sistema de enfriamiento del motor está funcionando eficientemente y la temperatura se mantiene dentro de un rango controlado.

Tabla 4*Valores descriptivos de la temperatura del refrigerante del motor*

Propiedad	Valor	Unidad
Muestras	1653	
Max	99	°C
Min	71	°C
Desviación Estándar	5.3925	°C
Media	90.9310	°C
NumBins	40	

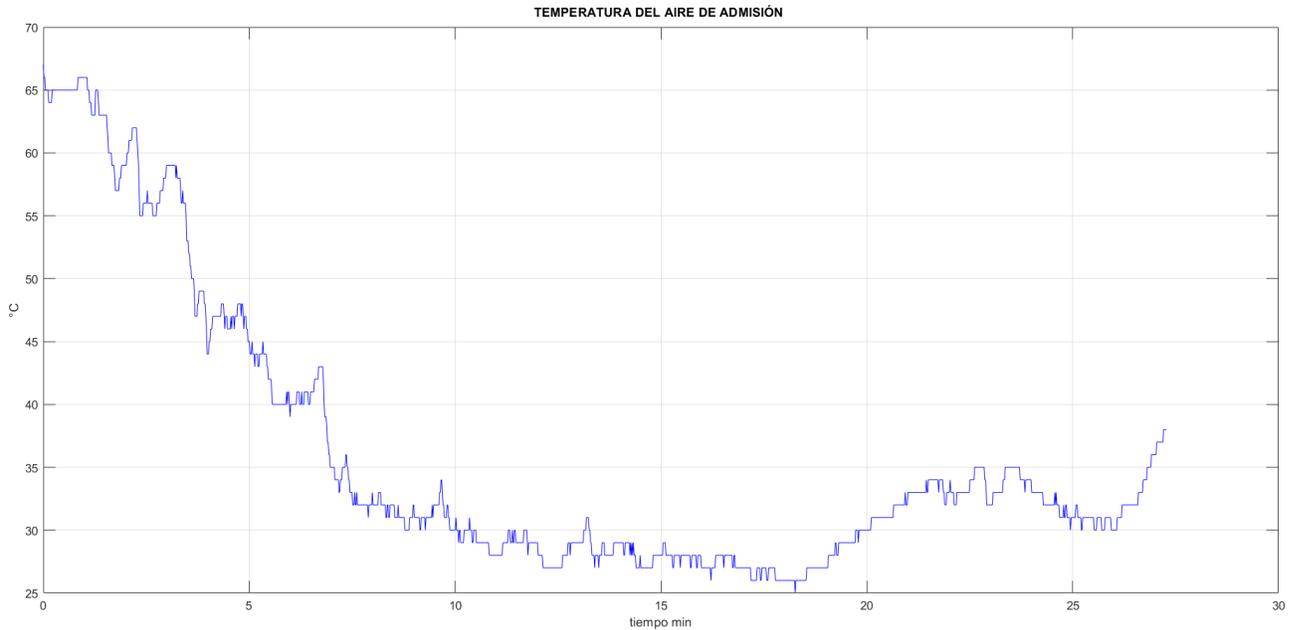
Nota: *En la tabla se observa los valores máximos, mínimos, la desviación estándar, el número de bins, el número de muestras, la media de los parámetros adquiridos del sensor ECT.*

6.4.3. Temperatura del aire de admisión (IAT).

En la figura 17 se puede observar la variación de la temperatura del aire de admisión del motor de combustión interna a lo largo del tiempo. La temperatura está en grados Celsius °C y el tiempo en minutos. La temperatura del aire de admisión varía entre aproximadamente 25 °C y 65 °C. La temperatura alrededor de los 65 °C y disminuye rápidamente debido al arranque del motor y la entrada de aire fresco. En el rango de 5 a 10 min la temperatura disminuye hasta alcanzar 30 °C, puede darse debido a la estabilidad del motor y a la entrada continua de aire. La temperatura se estabiliza en el rango de los 26 ° - 35 °C, el incremento que se observa a partir del minuto 26 se debe que a que las condiciones normales han cambiado, se considera que el vehículo ingreso en zona de tráfico.

Figura 17

Temperatura del aire de admisión.



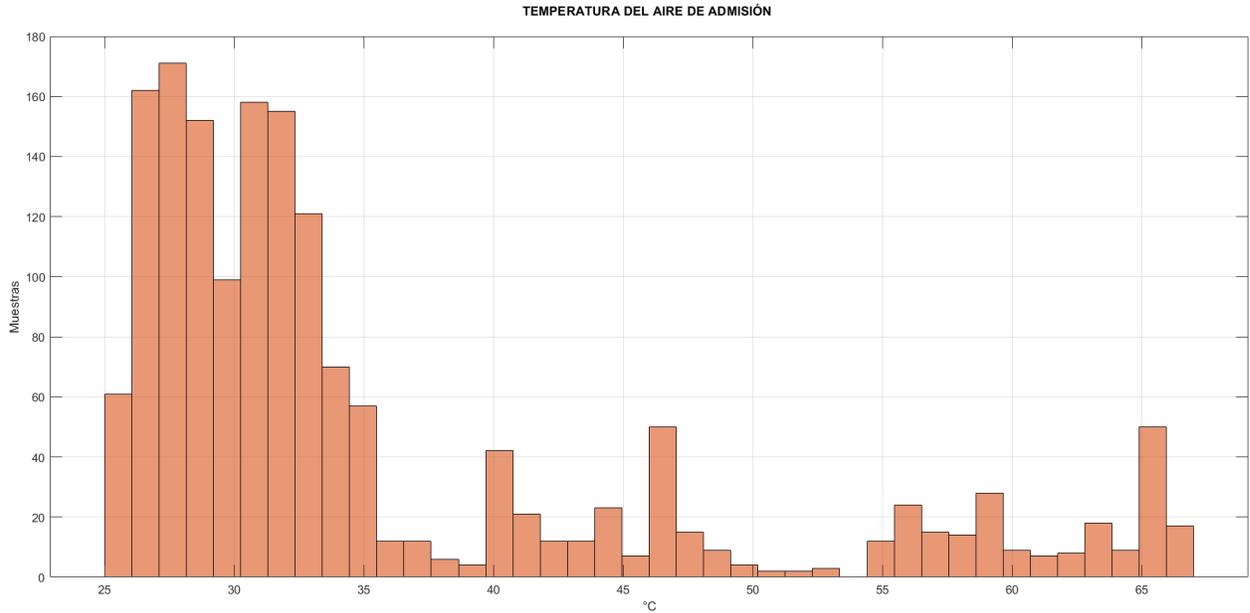
Nota: Gráfica de la temperatura del aire de admisión del motor (Guartazaca, 2024).

En el histograma 2 se muestran las distribuciones de las muestras de temperatura del aire de admisión.

30 °C es el valor que más frecuente con aproximadamente 160 muestras en este bin. La distribución tiene colas de picos de temperaturas altas, esto indica que la temperatura de admisión en ocasiones tiene temperaturas elevadas.

Figura 18

Histograma 2.



Nota: Histograma de la temperatura del aire de admisión de motor (Guartazaca, 2024).

Los valores mostrados en la tabla 5 nos sugiere que la media de la temperatura del aire de admisión es aproximadamente 36 °C. La desviación estándar nos indica una variabilidad moderada en la temperatura, estos cambios pueden darse debido a las condiciones de operación del motor, como la carga, la velocidad y las condiciones ambientales. Así mismo se observan para los valores máximos y mínimos, todos estos parámetros tomados de una muestra de 1653 parámetros.

Tabla 5

Valores descriptivos de la temperatura del aire de admisión.

Propiedad	Valor	Unidad
Muestras	1653	
Max	67	°C
Min	25	°C
Desviación Estándar	11.0057	°C
Media	35.9522	°C
NumBins	40	

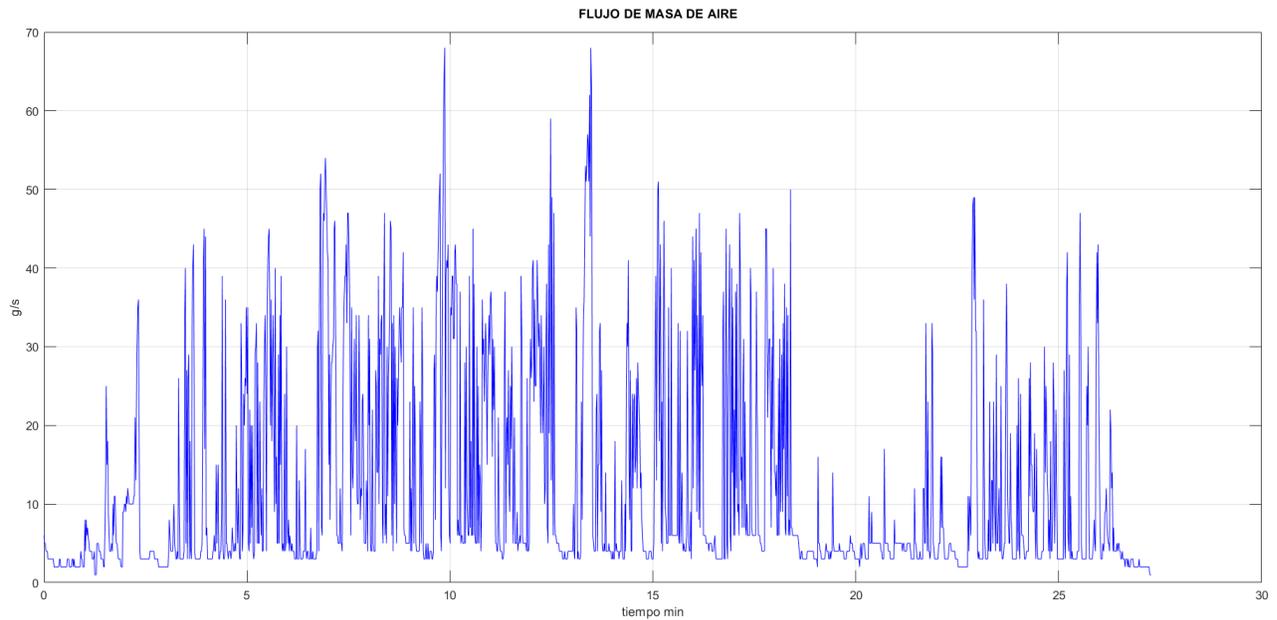
6.4.4. Flujo de masa de aire (MAF)

La figura 19 muestra la variación del flujo de masa de aire en gramos por segundo a lo largo del tiempo medido en minutos.

El flujo de masa de aire inicia en valores bajos y aumenta rápidamente, con picos significativos de hasta 40 g/s , este comportamiento sugiere que el motor está acelerando desde un estado de reposo.

Figura 19

Flujo de masa de aire (MAF).



Nota: Gráfica del flujo de masa de aire del motor. (Guartazaca, 2024).

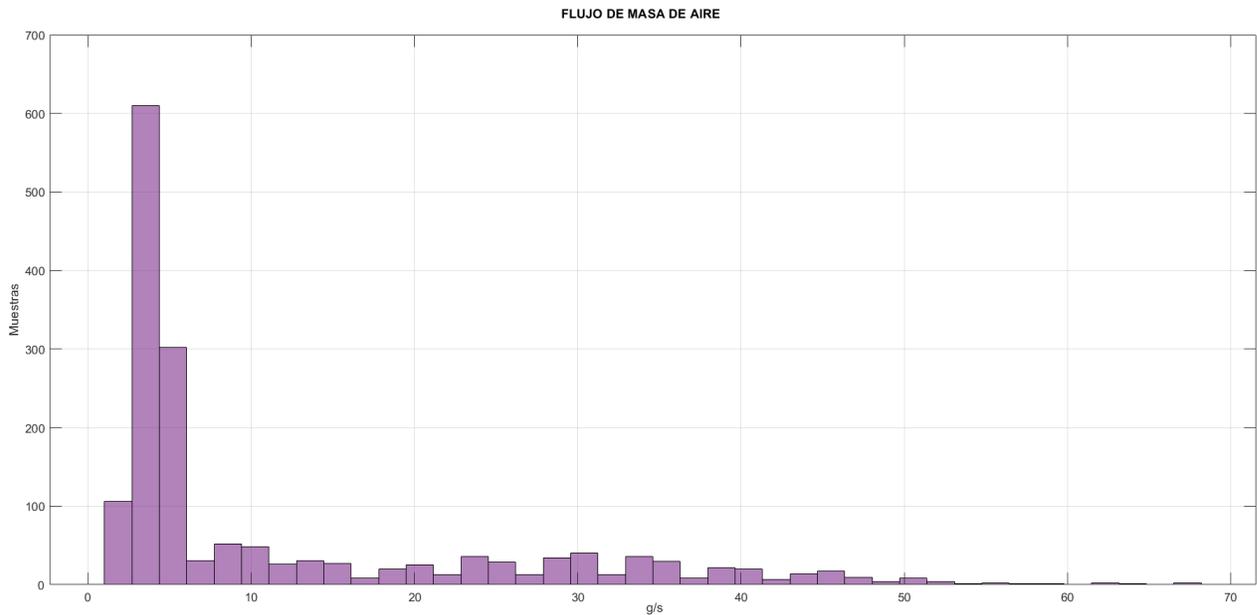
El histograma permite observar la distribución de las muestras del flujo de masa de aire.

La mayoría de las muestras se encuentran entre 0 y 10 g/s, con un pico significativo alrededor de 5 g/s. Hay menos muestras a flujos de masa de aire más altos, con algunos valores dispersos que alcanzan hasta los 68 g/s.

Se puede observar que existe una concentración de alrededor de 600 muestras en este bien con un valor de 5 g/s.

Figura 20

Histograma 3.



Nota: Histograma del flujo de masa de aire. (Guartazaca, 2024).

La media del flujo de masa de aire es aproximadamente 12 g/s, lo que nos indica un flujo moderado hacia el motor. La alta desviación estándar de 13.0995 g/s refleja una considerable variabilidad en los datos, atribuible a cambios en la carga del motor, velocidad y condiciones ambientales.

El rango de valores 1 g/s a 68 g/s muestra que el sistema de admisión de aire maneja diversas condiciones operativas. Los valores más altos se observan durante periodos de alta demanda, como aceleraciones rápidas o cargas elevadas.

Tabla 6

Valores descriptivos del flujo de masa de aire.

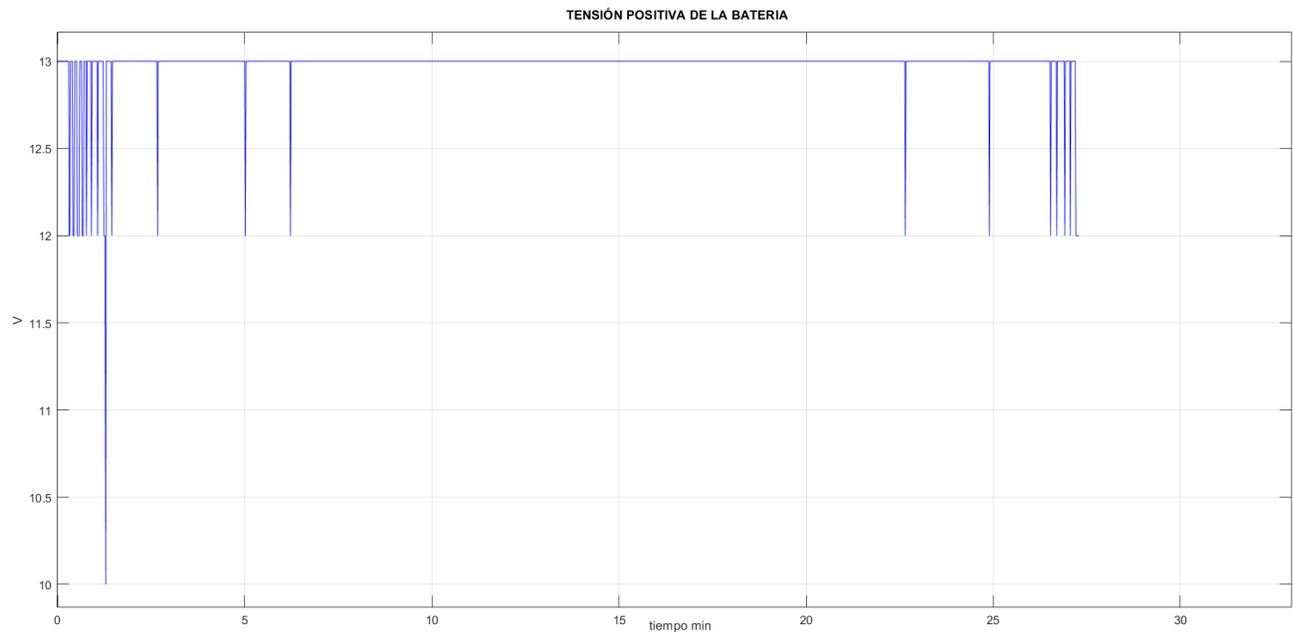
Propiedad	Valor	Unidad
Muestras	1653	
Max	68	g/s
Min	1	g/s
Desviación Estándar	13.0995	g/s
Media	11.9819	g/s
NumBins	40	

6.4.5. Tensión positiva de la batería

La gráfica temporal de la tensión de la batería muestra un comportamiento típico del sistema de carga y descarga de un vehículo, Se muestra la variación de la tensión de la batería en voltios (V) a lo largo del tiempo, medido en minutos. La tensión de la batería varía entre aproximadamente 10 y 13 V.

Figura 21

Tensión positiva de la batería.



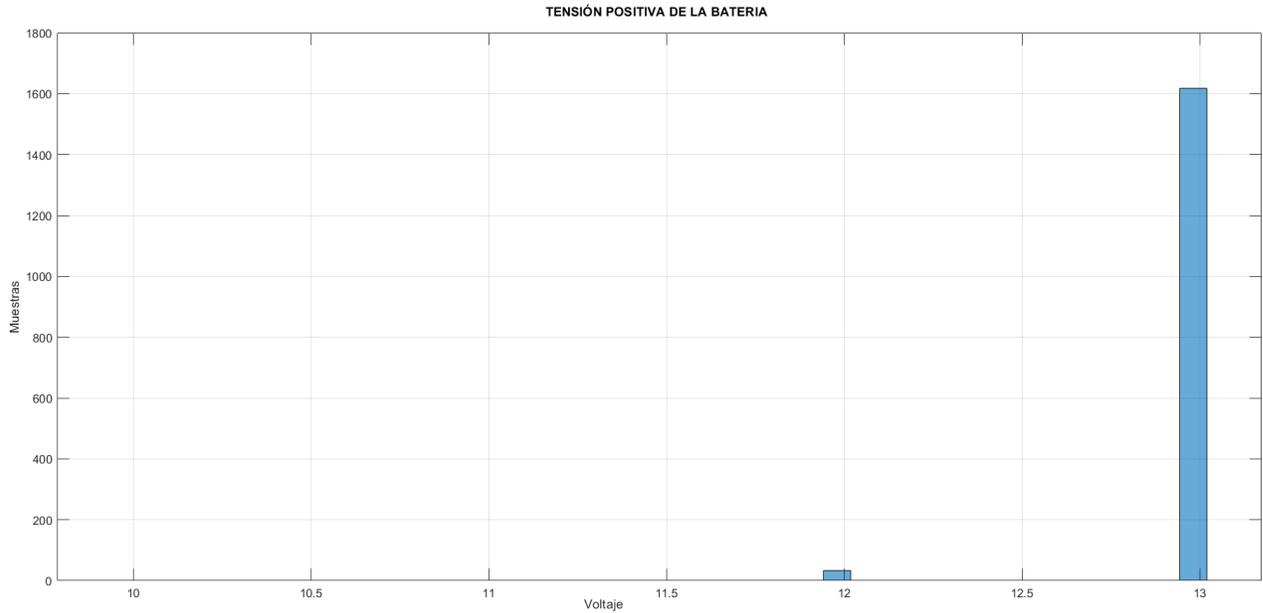
Nota: Gráfica de la tensión positiva de la batería. (Guartazaca, 2024).

En el histograma observamos la distribución de las muestras de los parámetros de la tensión de la batería.

Inicia la tensión de la batería alrededor de los 12.5 V con fluctuaciones rápidas, alcanzados picos de hasta 13 V, probablemente debido al arranque del motor y la estabilización del sistema eléctrico. Entre los rangos de 5 -25 min, la tensión se estabiliza en los 13 V con 1800 muestras para este bin, existen algunas caídas ocasionales, indicando que el alternador está cargando la batería eficientemente.

Figura 22

Histograma 4



Nota: Histograma de la tensión de la batería.A (Guartazaca, 2024).

La media de la tensión de la batería es de aproximadamente de 13 V, lo que nos sugiere que está manteniendo una tensión alta y constante durante la mayoría del tiempo. Este valor es consistente con un sistema de carga eficiente que mantiene la batería en un estado óptimo. La desviación estándar de 0.1597 V indica una variabilidad muy baja en los parámetros adquiridos, lo que indica que el sistema de carga es estable, donde la tensión no fluctúa significativamente.

Tabla 7

Valores descriptivos de la tensión de la batería.

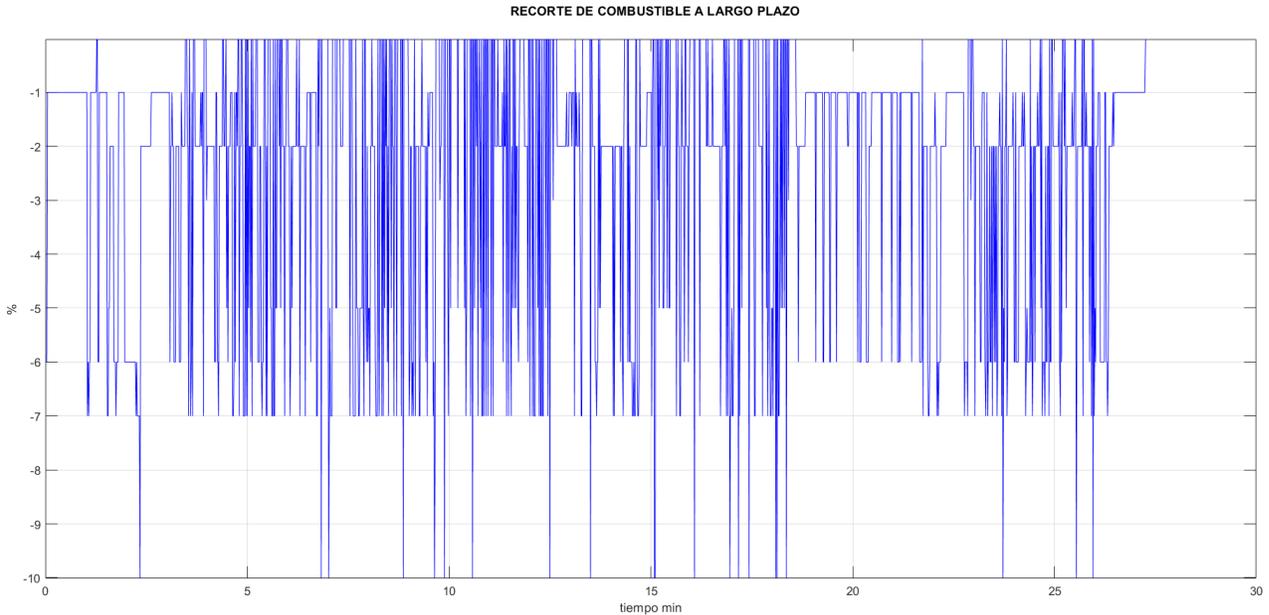
Propiedad	Valor	Unidad
Data	1654	
Max	13	V
Min	10	V
Desviación Estándar	0.1597	V
Media	12.9776	V
NumBins	40	

6.4.6. Ajuste de combustible a largo plazo (LTFT)

La gráfica muestra la variación del ajuste de combustible a largo plazo (LTFT) en% a lo largo del tiempo, medido en minutos. La gráfica del ajuste de combustible a largo plazo (LTFT) muestra cómo el motor ajusta continuamente la mezcla de aire y combustible durante 30 minutos. Al principio, el LTFT varía rápidamente entre -1% y -10%, debido a los ajustes iniciales tras arrancar el motor. Durante los siguientes 20 minutos, estas fluctuaciones continúan, indicando que el motor sigue ajustando la mezcla para mantener un rendimiento óptimo bajo diferentes condiciones. Hacia el final del periodo, las variaciones se vuelven menos frecuentes, lo que sugiere que el motor ha alcanzado una operación más estable. Los valores negativos de LTFT son una buena señal, ya que indican que el motor está funcionando eficientemente y evitando una mezcla demasiado rica en combustible.

Figura 23

Ajuste de combustible a largo plazo.

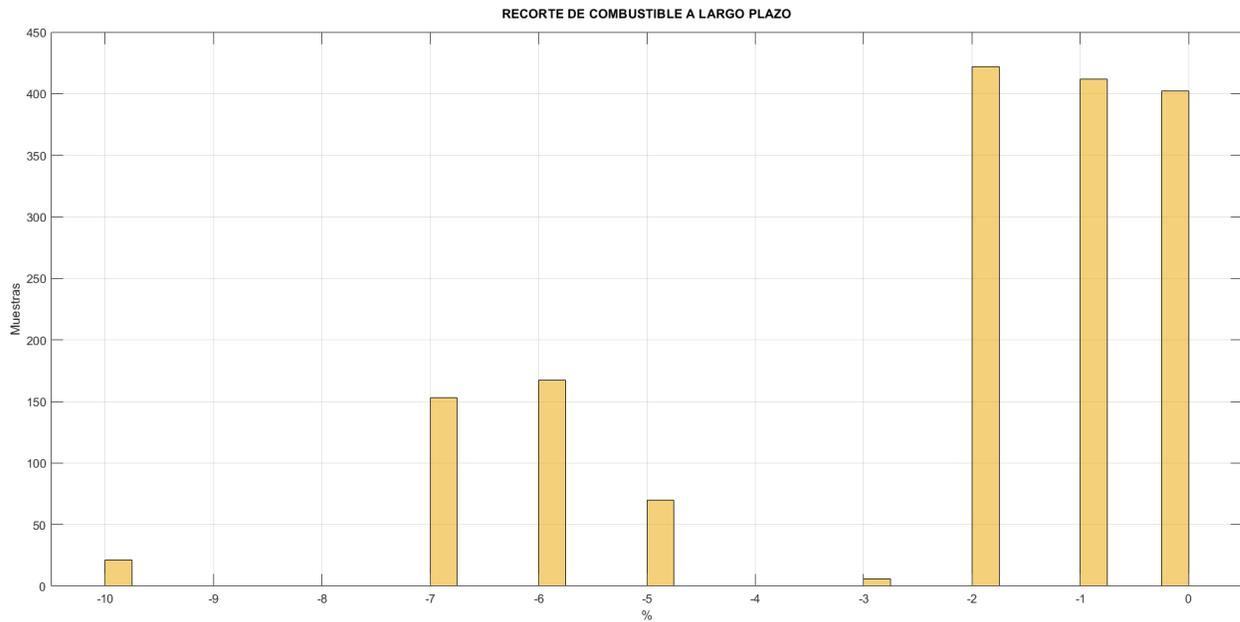


Nota: Gráfica del ajuste de combustible a largo plazo. (Guartazaca, 2024).

La gráfica 23 y el histograma 5 del ajuste de combustible a largo plazo (LFTF) muestran que la mayoría de los valores se encuentran entre -1% 0%, con una media de -2.36% y una desviación estándar de 2.4944% mostrados en la tabla 8. Estos datos indican que el sistema de gestión del motor está ajustando eficientemente la mezcla aire-combustible para mantener la eficiencia del motor, evitando una mezcla rica. La presencia de valores extremos sugiere que el sistema puede realizar ajustes significativos cuando es necesario.

Figura 24

Histograma 5.



Nota: Histograma del ajuste de combustible a largo plazo (Guartazaca, 2024).

Tabla 8

Valores descriptivos del ajuste de combustible a largo plazo.

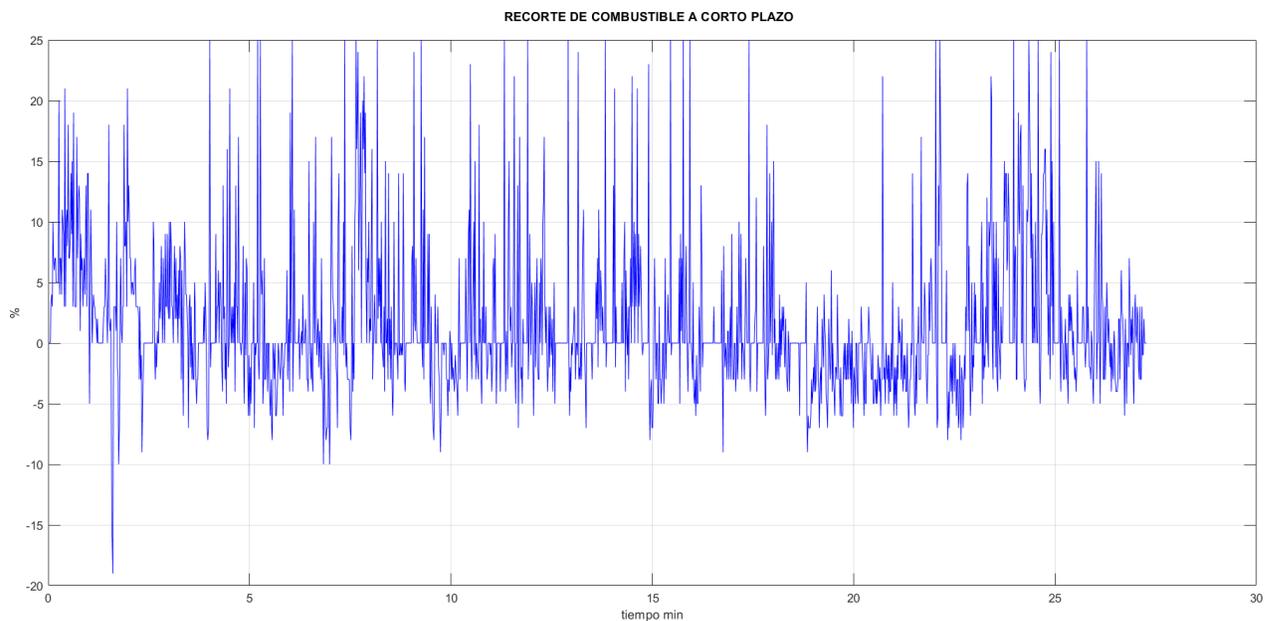
Propiedad	Valor	Unidad
Muestras	1653	
Max	10	%
Min	-10	%
Desviación Estándar	2.4944	%
Media	-2.3636	%
NumBins	40	

6.4.7. Ajuste de combustible a corto plazo (STFT)

La gráfica 25 muestra la variación del ajuste de combustible a corto plazo (STFT) en porcentaje (%) a lo largo del tiempo, medido en minutos. Aquí se observa un comportamiento típico del sistema de gestión del motor, con ajustes rápidos y constantes para mantener la eficiencia del combustible. Las fluctuaciones rápidas y continuas reflejan un sistema que responde dinámicamente a las condiciones cambiantes del motor, mientras que la estabilización parcial hacia el final indica una condición operativa más estable. Mantener un STFT en valores tanto positivos como negativos es un buen indicativo de un motor eficiente y bien ajustado.

Figura 25

Ajuste de combustible a corto plazo.



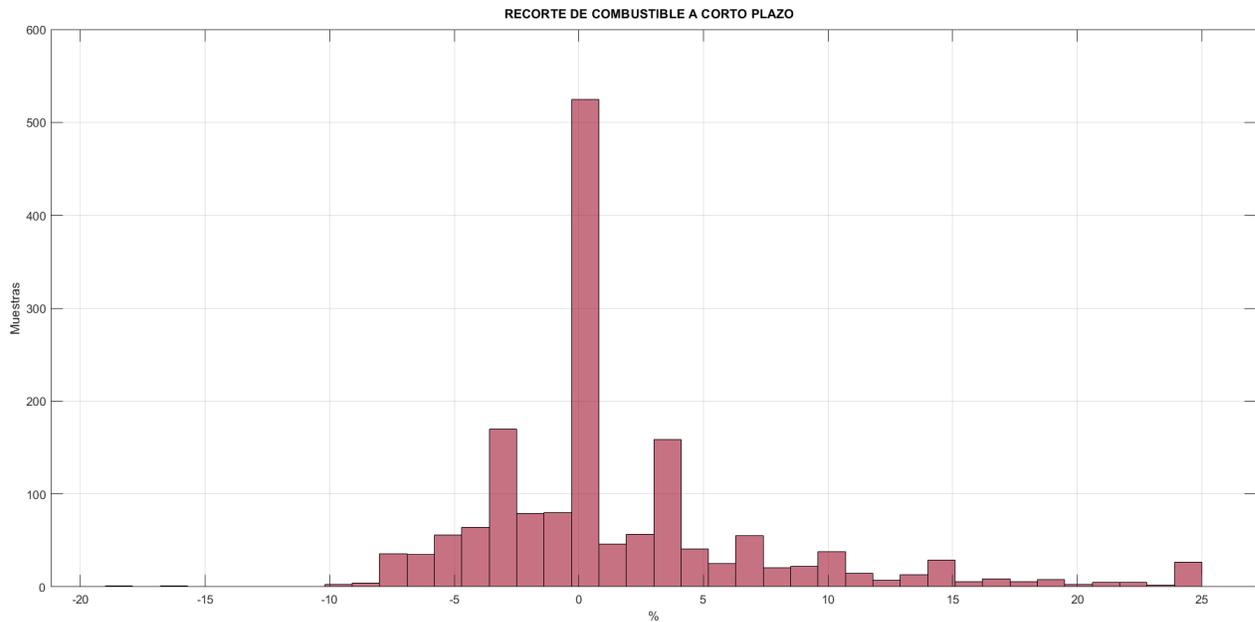
Nota: Gráfica del ajuste de combustible a corto plazo (Guartazaca, 2024).

El histograma 6 del ajuste de combustible a corto plazo (STFT) muestra una distribución centrada alrededor de 0%, con una media de 1.60% y una desviación estándar de 6.1050%. Los datos mostrados en la tabla 9 indican que el sistema de gestión del motor está ajustando eficientemente la mezcla aire-combustible, con pequeños ajustes frecuentes para mantener la eficiencia del motor. La presencia de valores extremos sugiere que el sistema puede realizar

ajustes significativos cuando es necesario, reflejando un sistema dinámico y responsivo a las condiciones operativas del motor.

Figura 26

Histograma 6.



Nota: Histograma del ajuste de combustible a corto plazo. (Guartazaca, 2024).

Tabla 9

Valores descriptivos del ajuste de combustible a corto plazo

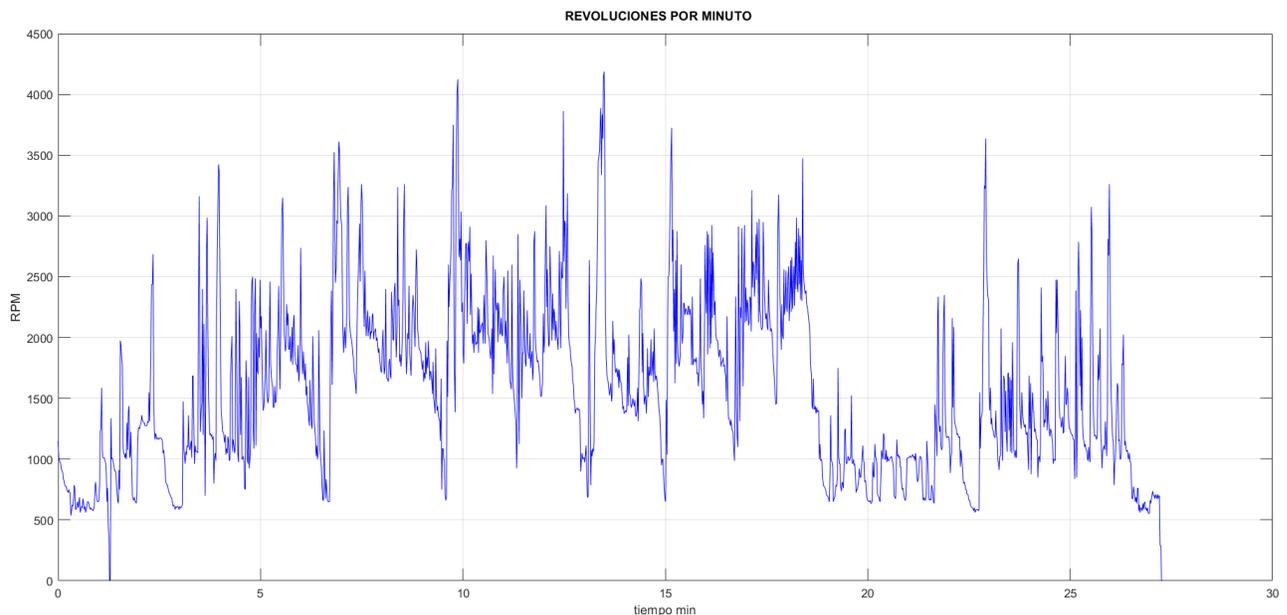
Propiedad	Valor	Unidad
Muestras	1653	
Max	25	%
Min	-19	%
Desviación Estándar	6.1050	%
Media	1.5965	%
NumBins	40	

6.4.8. Régimen de giro (RPM)

La gráfica 27 temporal de RPM abarca 30 minutos de recorrido aproximadamente, con un rango de 0 a 4187 RPM. Durante los primeros 5 minutos, las RPM comienzan en niveles bajos, con fluctuaciones y picos iniciales de hasta 2000 RPM, probablemente debido al arranque del motor y ajustes iniciales. Entre los 5 y 25 minutos, las RPM muestran fluctuaciones constantes, alcanzando picos de hasta 4000 RPM, reflejando cambios en la carga y velocidad del motor durante su operación normal. En los últimos 5 minutos, las RPM tienden a estabilizarse, aunque con picos significativos, indicando que el motor puede estar alcanzando una condición de operación más estable.

Figura 27

Régimen de giro (RPM)



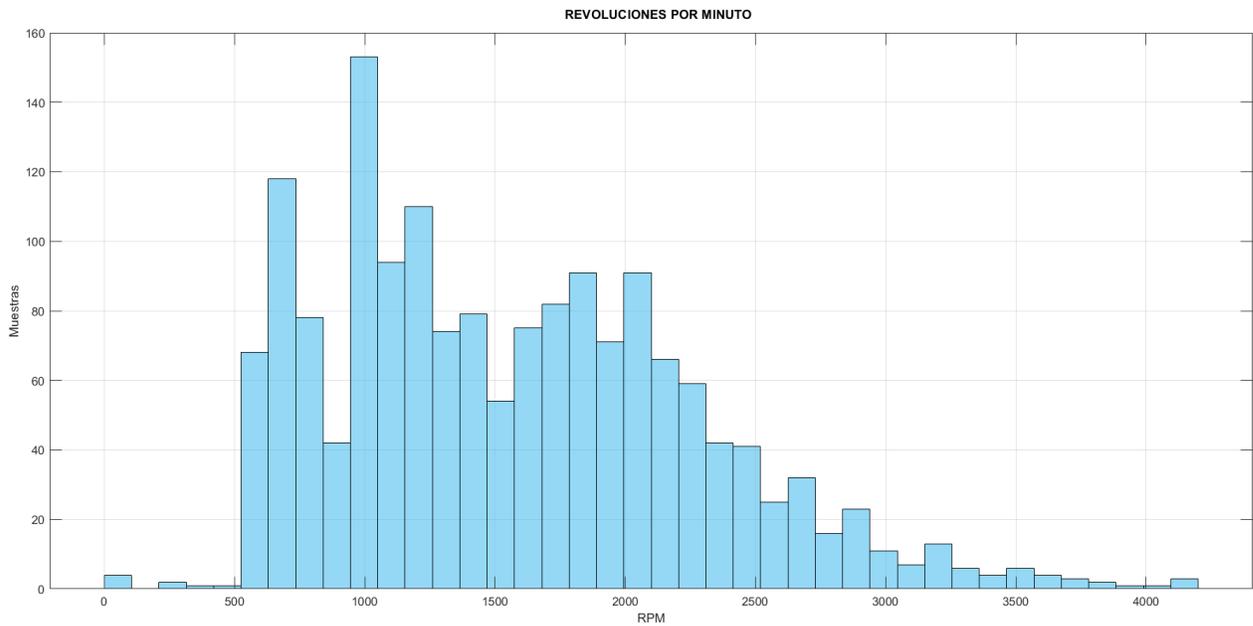
Nota: Gráfica del régimen de giro (RPM)(Guartazaca, 2024).

En el histograma 7 se observa que la mayoría de las muestras se concentran entre 500 y 2000 RPM, con una media aproximadamente de 1570 RPM, así mismo con un pico alrededor de las 100 RPM. La desviación estándar que se observa en la tabla 10 indica una variabilidad

alta en los datos de RPM, por lo que se puede interpretar que esta variabilidad refleja que los cambios rápidos y dinámicos en la velocidad del motor es debido a las condiciones operativas.

Figura 28

Histograma 7.



Nota: Histograma del régimen de giro (RPM) (Guartazaca, 2024).

Tabla 10

Valores descriptivos del régimen de giro (RPM).

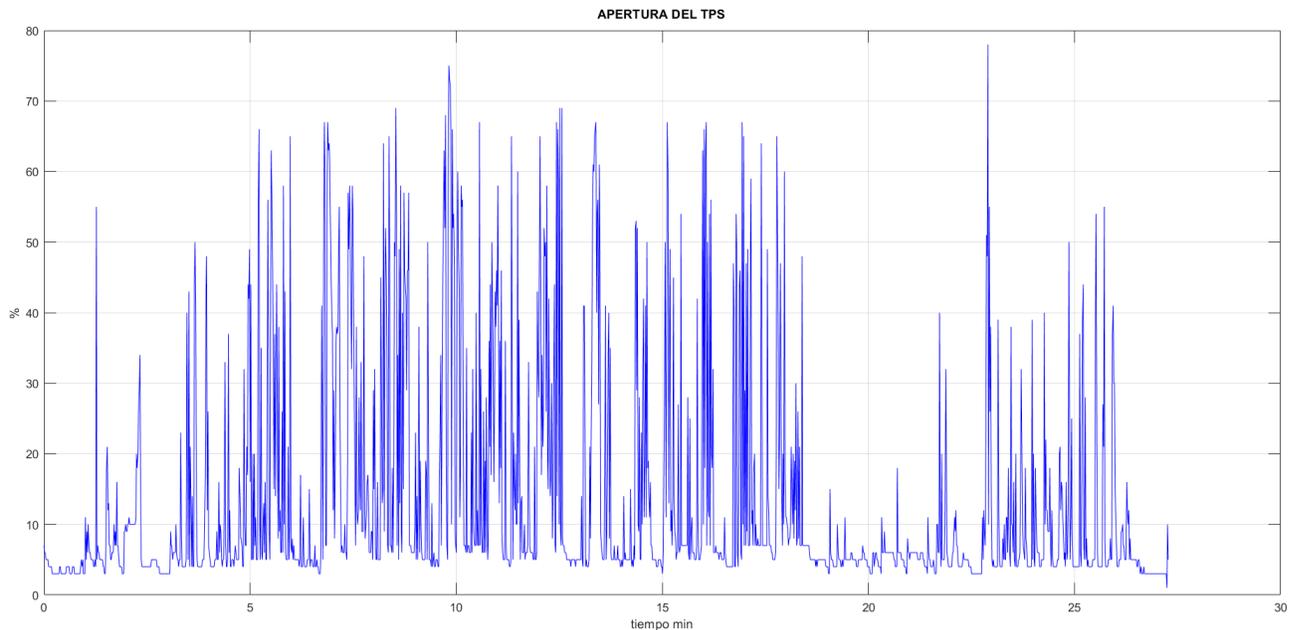
Propiedad	Valor	Unidad
Muestras	1653	
Max	4187	RPM
Min	0	RPM
Desviación Estándar	701.4028	RPM
Media	1569.554	RPM
NumBins	50	

6.4.9. Sensor de posición del acelerador (TPS)

La gráfica temporal del sensor de posición del acelerador (TPS) muestra fluctuaciones significativas en la apertura del acelerador durante el periodo de 30 minutos. Se observan picos frecuentes que alcanzan hasta el 70% de apertura, lo que indica variaciones constantes en la aceleración del vehículo.

Figura 29

Sensor de posición del acelerador.

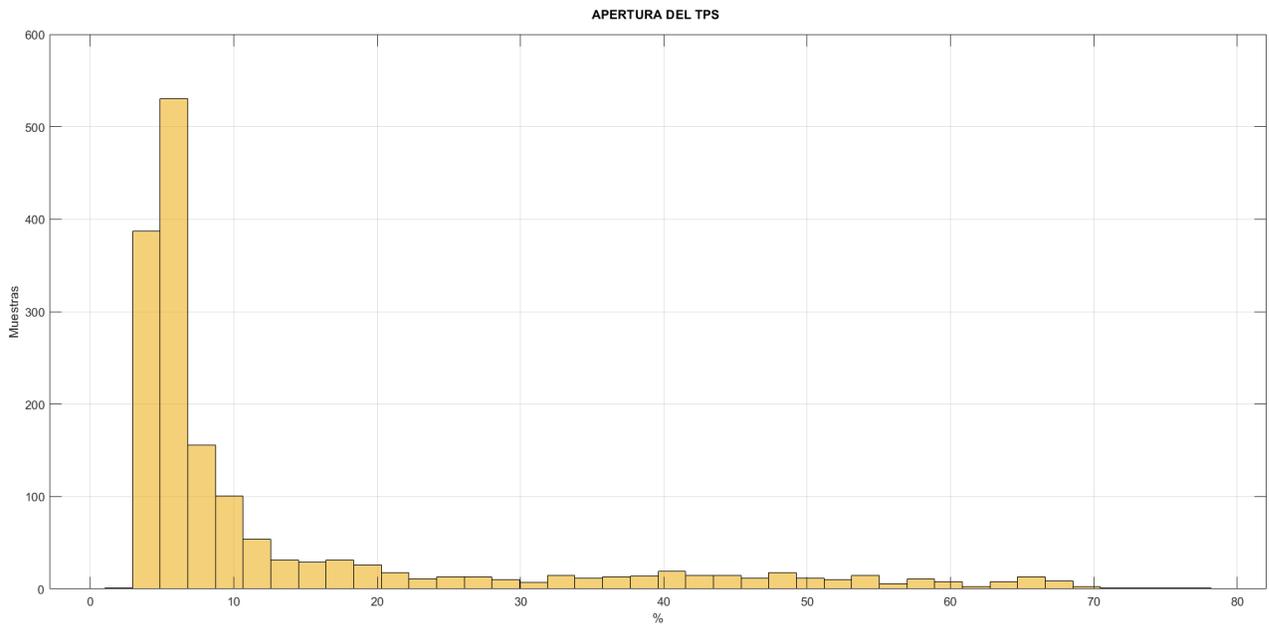


Nota: Gráfica del sensor de posición del acelerador.(Guartazaca, 2024).

El histograma de la apertura del TPS revela que la mayoría de las muestras se concentran en niveles bajos de apertura, principalmente entre 0% y 10%. Esto sugiere que el acelerador se mantiene en posiciones bajas la mayor parte del tiempo. La media es de 13.4089%, con una desviación estándar de 15.8082%, lo que indica una gran variabilidad en las posiciones del acelerador.

Figura 30

Histograma 10.



Nota: Histograma del sensor de posición del acelerador. (Guartazaca, 2024).

Tabla 11

Valores descriptivos del sensor de posición del acelerador.

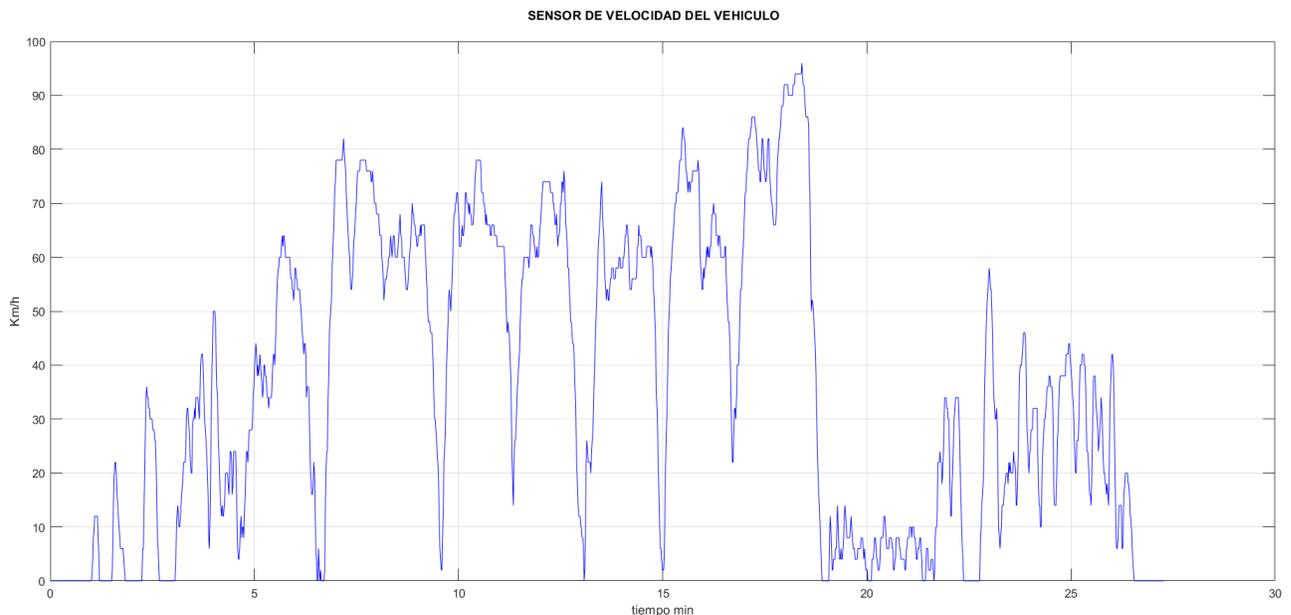
Propiedad	Valor	Unidad
Muestras	1653	
Max	78	%
Min	1	%
Desviación Estándar	15.8082	%
Media	13.4089	%
NumBins	40	

6.4.10. Sensor de velocidad del vehículo (VSS)

La gráfica temporal del VSS muestra las fluctuaciones en la velocidad del vehículo durante un periodo de 30 minutos. Al inicio, la velocidad aumenta gradualmente con varias fluctuaciones, alcanzando picos cercanos a los 70 km/h. Durante el periodo central, la velocidad varía constantemente, con subidas y bajadas reflejando cambios en las condiciones de conducción, alcanzando un máximo de 96 km/h. Hacia el final del periodo, la velocidad disminuye progresivamente, con algunos momentos de casi detención, indicando posibles paradas o reducciones significativas en la velocidad.

Figura 31

Sensor de velocidad del vehículo (VSS)



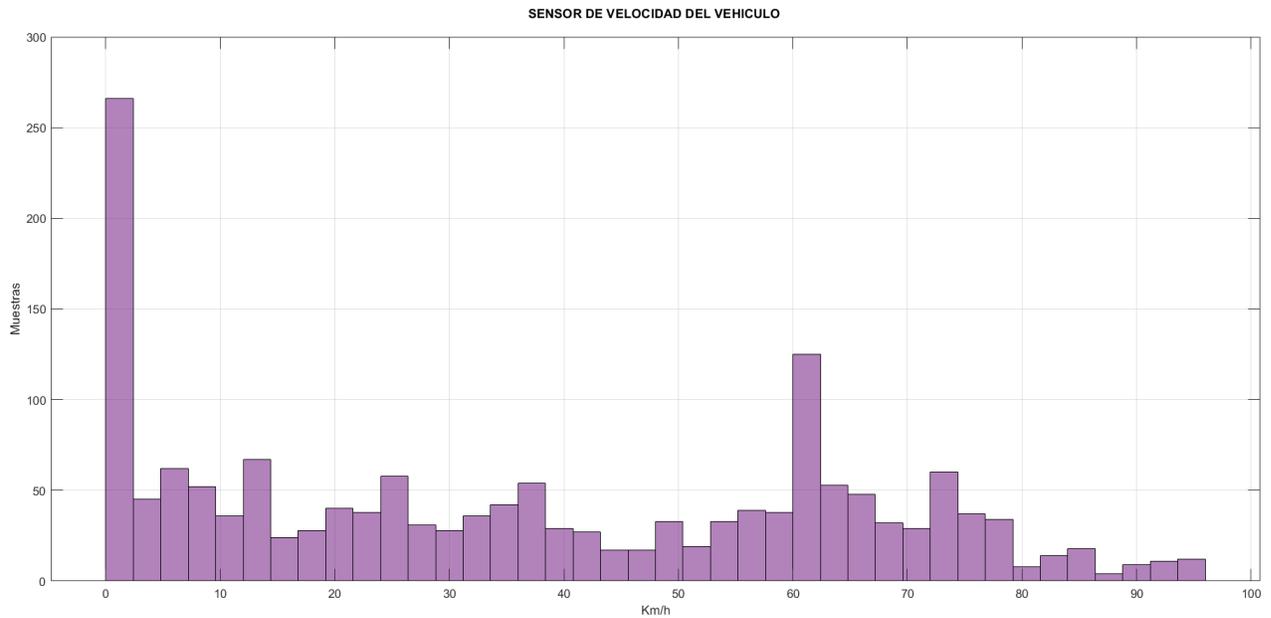
Nota: Gráfica del sensor de velocidad del vehiculo (VSS)(Guartazaca, 2024).

El histograma del VSS muestra la distribución de las velocidades registradas. La mayor concentración de muestras se encuentra entre 0 y 60 km/h, con picos significativos alrededor de 10 km/h y 60 km/h. Las velocidades superiores a 60 km/h tienen una menor frecuencia de ocurrencia, reflejando que la mayoría del tiempo el vehículo opera a velocidades bajas a moderadas. La desviación estándar de 27.8469 km/h indica una alta variabilidad en las

velocidades durante el periodo analizado.

Figura 32

Histograma 11.



Nota: Histograma del sensor de velocidad del vehiculo (VSS)(Guartazaca, 2024).

Los datos estadísticos del VSS revelan que se registraron 1653 muestras. La velocidad máxima registrada es de 96 km/h, mientras que la mínima es de 0 km/h. La media de la velocidad es de 36.2807 km/h, y la desviación estándar es de 27.8469 km/h, indicando una alta variabilidad en las velocidades del vehículo durante el periodo de 30 minutos.

Tabla 12

Valores descriptivos del sensor de velocidad del vehículo (VSS)

Propiedad	Valor	Unidad
Muestras	1653	
Max	96	Km/h
Min	0	Km/h
Desviación Estándar	27.8469	Km/h
Min	36.2807	Km/h
NumBins	40	

6.5. Análisis de la matriz de correlación.

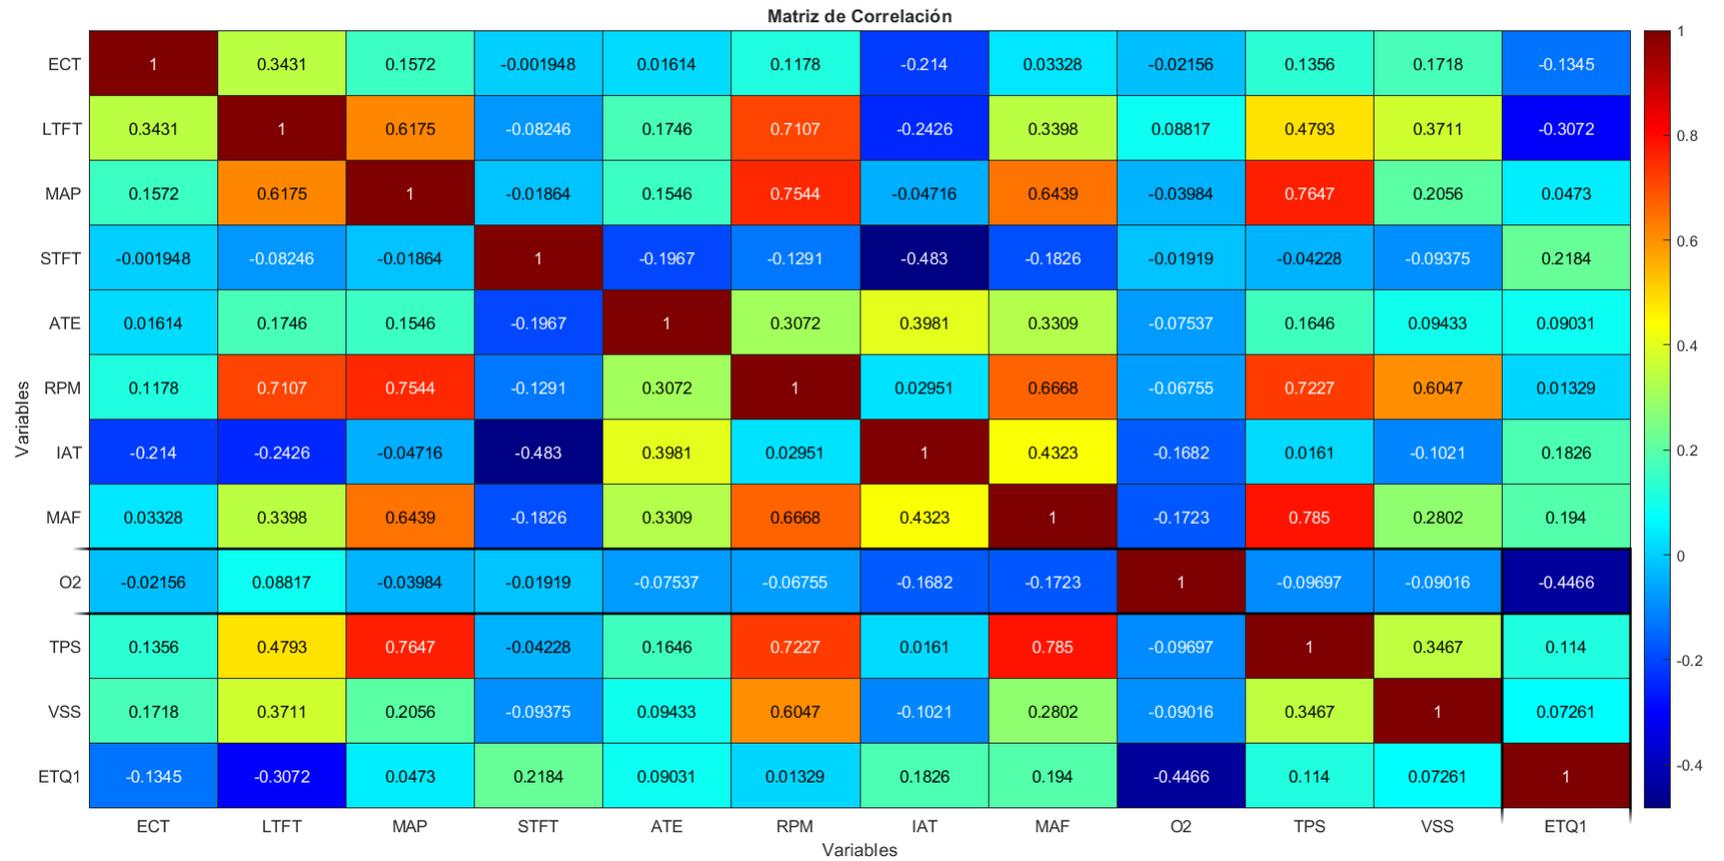


Figura 33

Matriz de correlación.

Tabla 13*Correlación de LTFT con otras variables*

Variable	Valor de la correlación	Descripción
MAP	0.6175	Existe una fuerte correlación positiva entre LTFT y MAP. A medida que aumenta la presión del colector, el ajuste de combustible a largo plazo también tiende a aumentar.
RPM	0.7107	Existe una fuerte correlación positiva entre LTFT y las RPM del motor. Esto indica que a medida que aumentan las RPM, el ajuste de combustible a largo plazo también aumenta.
MAF	0.3398	Existe una correlación positiva moderada entre LTFT y MAF. A medida que aumenta el caudal de aire medido por el MAF, el ajuste de combustible a largo plazo también tiende a aumentar.
TPS	0.4793	Existe una correlación positiva moderada entre LTFT y TPS. A medida que aumenta la posición del acelerador, también aumenta el ajuste del combustible a largo plazo.
VSS	0.3711	Existe una correlación positiva moderada entre LTFT y VSS. A medida que aumenta la velocidad del vehículo, el ajuste de combustible a largo plazo también tiende a aumentar.

Tabla 14*Correlación de MAP con otras variables*

Variable	Valor de la correlación	Descripción
RPMS	0.7544	Hay una fuerte correlación positiva entre MAP y RPM del motor. A medida que aumentan las RPM, la presión del colector también tiende a aumentar.
TPS	0.7647	Existe una fuerte correlación positiva entre MAP y TPS. A medida que aumenta la posición del acelerador, la presión del colector también aumenta.
LTFT	0.6175	Existe una fuerte correlación positiva entre MAP y LTFT. A medida que aumenta la presión del colector, el ajuste de combustible a largo plazo también tiende a aumentar.
MAF	0.6439	Existe una fuerte correlación positiva entre MAP y MAF. A medida que aumenta el caudal de aire medido por el MAF, también aumenta la presión del colector.
VSS	0.2056	Existe una correlación positiva débil entre MAP y VSS. A medida que aumenta la velocidad del vehículo, la presión del colector también tiende a aumentar.

Tabla 15*Correlación de TPS con otras variables*

Variable	Valor de la correlación	Descripción
MAP	0.7647	Existe una fuerte correlación positiva entre TPS y MAP. A medida que la posición del acelerador aumenta, la presión del colector también tiende a aumentar.
RPM	0.7227	Hay una fuerte correlación positiva entre TPS y RPM del motor. A medida que el acelerador se abre más, las revoluciones por minuto del motor también aumentan.
MAF	0.785	Existe una fuerte correlación positiva entre TPS y MAF. Cuando la posición del acelerador aumenta, el flujo de aire masivo medido por el MAF también tiende a aumentar.
LTFT	0.4793	Hay una correlación positiva moderada entre TPS y LTFT. A medida que la posición del acelerador aumenta, el ajuste de combustible a largo plazo también tiende a aumentar.
O2	-0.09697	Existe una correlación negativa débil entre TPS y el sensor de oxígeno. A medida que aumenta la posición del acelerador, la señal del sensor de oxígeno tiende a disminuir ligeramente.

Tabla 16*Correlación de VSS con otras variables*

Variable	Valor de la correlación	Descripción
RPM	0.6741	Existe una fuerte correlación positiva entre VSS y RPM del motor. A medida que la velocidad del vehículo aumenta, las revoluciones por minuto del motor también tienden a aumentar.
MAP	0.2056	Hay una correlación positiva moderada entre VSS y MAP. A medida que la velocidad del vehículo aumenta, la presión absoluta del colector también tiende a aumentar.
TPS	0.2535	Existe una correlación positiva moderada entre VSS y TPS. A medida que la velocidad del vehículo aumenta, la posición del acelerador también tiende a estar más abierta.
MAF	0.4187	Hay una correlación positiva moderada entre VSS y MAF. A medida que la velocidad del vehículo aumenta, el flujo de aire medido por el sensor MAF también tiende a aumentar.
O2	-0.2314	Existe una correlación negativa moderada entre VSS y el sensor de oxígeno. A medida que la velocidad del vehículo aumenta, la concentración de oxígeno tiende a disminuir ligeramente.

Tabla 17*Correlación de ETQ1 con otras variables*

Variable	Valor de la correlación	Descripción
VSS	0.3467	Existe una correlación positiva moderada entre ETQ1 y VSS. A medida que aumenta la velocidad del vehículo, también aumenta el valor de ETQ1.
MAF	0.194	Hay una correlación positiva débil entre ETQ1 y MAF. A medida que aumenta el flujo de aire medido por el sensor MAF, el valor de ETQ1 también tiende a aumentar.
O2	-0.4466	Existe una fuerte correlación negativa entre ETQ1 y el sensor de oxígeno. A medida que aumenta el valor de ETQ1, la señal del sensor de oxígeno tiende a disminuir significativamente.

Tabla 18*Correlaciones Fuertes entre Parámetros*

Parámetros	Valor	Descripción
RPM - VSS	0.6741	Existe una fuerte correlación positiva entre las RPM del motor y la velocidad del vehículo. A medida que la velocidad del vehículo aumenta, las RPM del motor también tienden a aumentar.
MAP - TPS	0.7647	Hay una fuerte correlación positiva entre la presión absoluta del colector y la posición del acelerador. A medida que la posición del acelerador aumenta, la presión del colector también tiende a aumentar.
RPM - TPS	0.7227	Existe una fuerte correlación positiva entre las RPM del motor y la posición del acelerador. A medida que la posición del acelerador aumenta, las RPM del motor también tienden a aumentar.
MAF - TPS	0.785	Hay una fuerte correlación positiva entre el flujo de aire masivo y la posición del acelerador. A medida que la posición del acelerador aumenta, el flujo de aire medido por el sensor MAF también tiende a aumentar.
O2 - ETQ1	-0.4466	Existe una fuerte correlación negativa entre la concentración de oxígeno y ETQ1. A medida que aumenta el valor de ETQ1, la concentración de oxígeno tiende a disminuir significativamente.

6.6. Entrenamiento de los modelos de aprendizaje automático

6.6.1. Árbol de decisiones fino (Tree)

Tabla 19

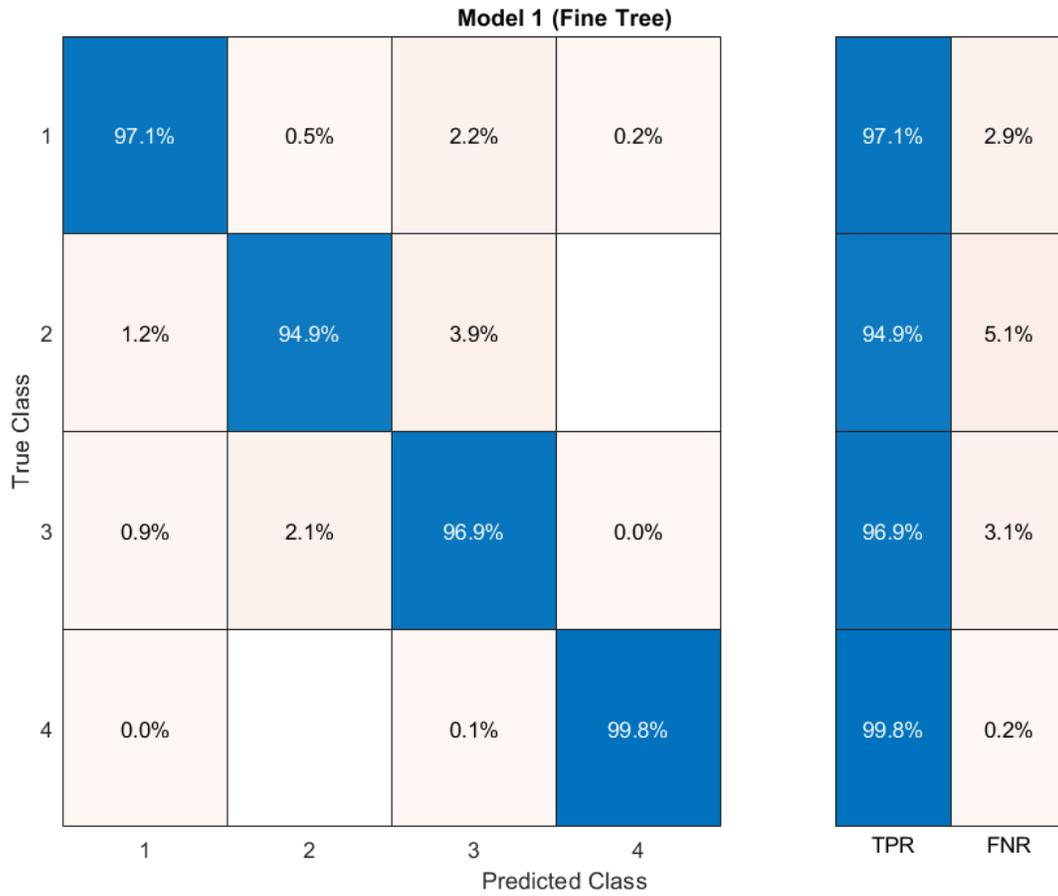
Parámetros del Modelo 1: Árbol de Decisión (Fine Tree)

Parámetro	Valor	Descripción
Precisión (Validación)	97.2%	La precisión del modelo en el conjunto de validación.
Costo total (Validación)	338	El costo total asociado con las predicciones del modelo en el conjunto de validación.
Velocidad de predicción	120000 obs/sec	Velocidad de predicción del modelo en observaciones por segundo.
Tiempo de entrenamiento	2.9374 sec	Tiempo total de entrenamiento del modelo en segundos.
Tamaño del modelo (Compacto)	37 kB	Tamaño del modelo entrenado en formato compacto.
Máximo número de divisiones	100	Número máximo de divisiones permitidas en el árbol de decisión.
Criterio de division	Gini's diversity index	Criterio utilizado para dividir los nodos del árbol.

El Modelo de Árbol de Decisión Fino (Fine Tree) presenta un alto rendimiento en la mayoría de las clases, con tasas de verdaderos positivos (TPR) superiores al 94% en todas las clases y una muy baja tasa de falsos negativos (FNR). Esto indica que este modelo puede contener una alta tasa de sobre ajuste de datos, ya que tiene un alto rango de precisión en la clasificación de las observaciones y tiene una alta capacidad de generalización, en especial en la clase 4 donde tiene un 99.8% de precisión.

Figura 34

Matriz de confusión modelo de aprendizaje Tree



Nota: Matriz de confusión modelo de aprendizaje Tree (Guartazaca, 2024).

6.6.2. KNN F (KNN Fino)

Tabla 20

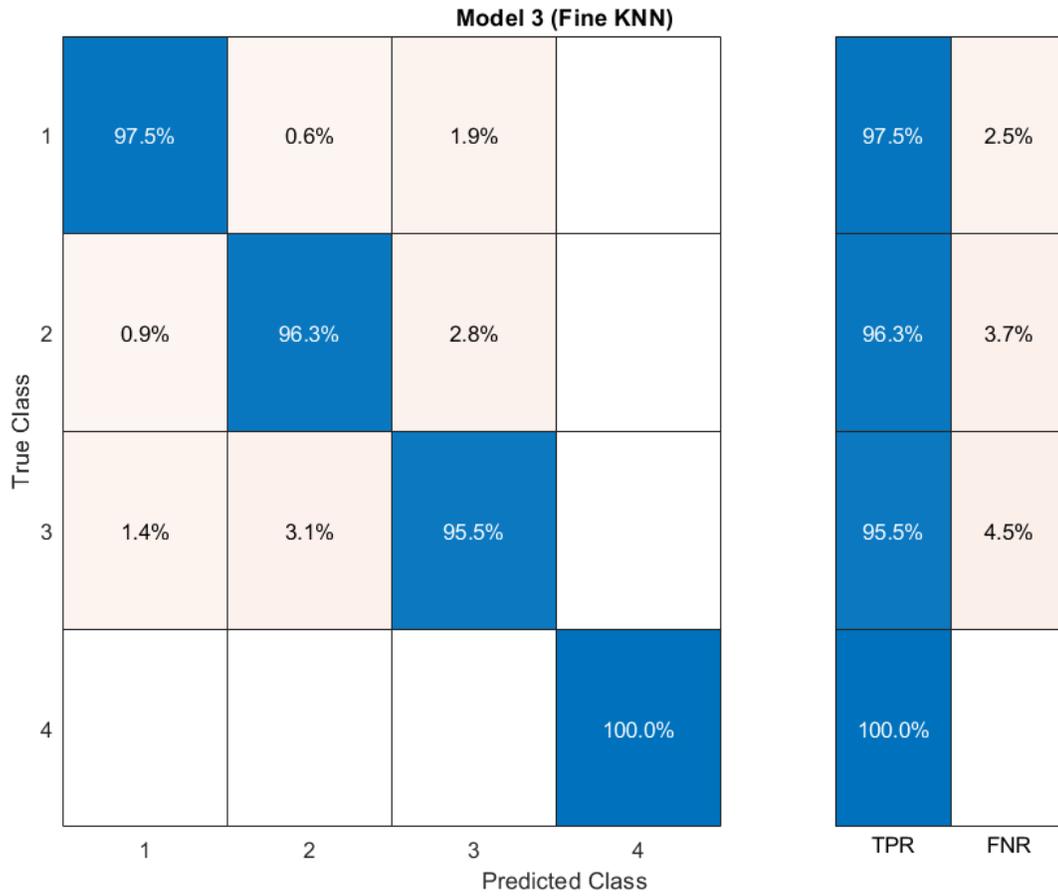
Hiperparámetros y Resultados del Modelo KNN

Parámetro	Descripción
Precisión (Validación)	97.3%
Costo total (Validación)	319
Velocidad de predicción	130000 obs/seg
Tiempo de entrenamiento	1.349 seg
Tamaño del modelo (Compacto)	1 MB
Hiperparámetros del Modelo	
Pre ajuste	Fine KNN
Número de vecinos	1
Métrica de distancia	Euclidiana
Peso de la distancia	Igual
Estandarizar datos	Sí

El modelo Fine KNN muestra un alto nivel de precisión en la mayoría de las clases, especialmente en la clase 4, donde alcanza el 100% de precisión y no comete errores. Este nivel de precisión puede indicar un posible sobreajuste, ya que el modelo puede estar ajustándose demasiado a los datos de entrenamiento y no generalizar bien en datos no vistos. Es importante evaluar el rendimiento del modelo en un conjunto de prueba independiente para confirmar si el modelo está realmente sobre ajustado o si estas métricas reflejan un buen desempeño general.

Figura 35

Matriz de confusión modelo de aprendizaje Fine KNN



Nota: Matriz de confusión modelo de aprendizaje FKNN (Guartazaca, 2024).

6.6.3. Red Neuronal Estrecha

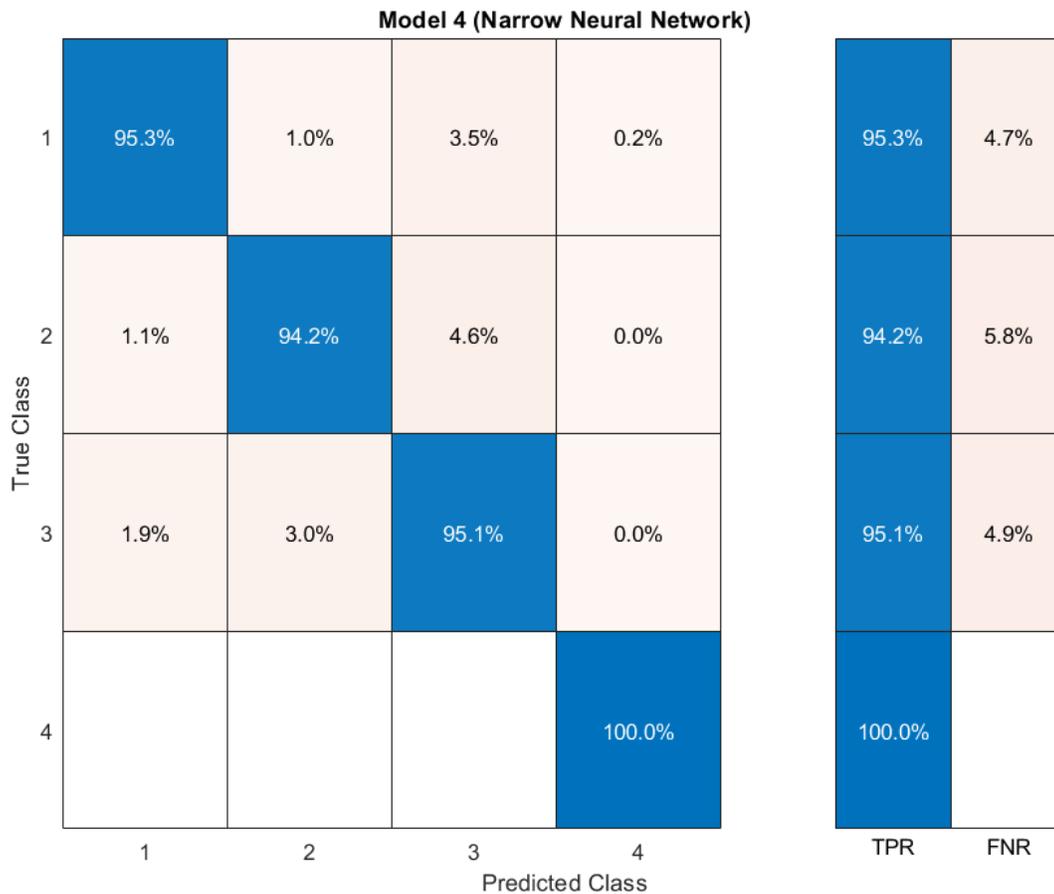
Tabla 21

Resultados del Entrenamiento e Hiperparámetros del Modelo de Red Neuronal Estrecha

Parámetro	Valor	Descripción
Precisión (Validación)	96.2%	Indica la proporción de predicciones correctas del modelo sobre el conjunto de validación.
Costo total (Validación)	461	Representa la suma de los errores de predicción en el conjunto de validación.
Velocidad de predicción	370000 obs/seg	Cantidad de observaciones que el modelo puede predecir por segundo.
Tiempo de entrenamiento	15.138 seg	Tiempo total que tomó entrenar el modelo.
Tamaño del modelo (Compacto)	7 kB	Tamaño del modelo entrenado en su forma compacta.
Hiperparámetro	Valor	Descripción
Pre configuración	Red Neuronal Estrecha	Tipo de red neuronal pre configurada para el modelo.
Número de capas totalmente conectadas	1	Número de capas en la red donde cada neurona está conectada a todas las neuronas de la siguiente capa.
Tamaño de la primera capa	10	Número de neuronas en la primera capa de la red neuronal.
Activación	ReLU	Función de activación utilizada en las neuronas para introducir no linealidades en el modelo.
Límite de iteraciones	1000	Número máximo de iteraciones permitidas durante el entrenamiento del modelo.
Fuerza de regularización (Lambda)	0	Parámetro que controla la penalización de la complejidad del modelo para evitar el sobreajuste.
Estandarizar datos	Sí	Indica si los datos de entrada fueron estandarizados antes del entrenamiento del modelo.

Figura 36

Matriz de confusión modelo de aprendizaje Red Neuronal Estrecha



Nota: Matriz de confusión modelo de aprendizaje Red Neuronal Estrecha (Guartazaca, 2024).

El modelo Narrow Neural Network demuestra una alta precisión en la mayoría de las clases, destacando particularmente en la clase 4, donde logra un 100% de precisión sin cometer errores. Aunque el rendimiento general en otras clases también es alto, este nivel de exactitud sugiere un posible sobreajuste. Esto podría indicar que el modelo está excesivamente adaptado a los datos de entrenamiento, comprometiendo su capacidad de generalizar a nuevos datos. Es crucial validar el desempeño del modelo con un conjunto de prueba independiente para determinar si realmente está sobre ajustado o si las métricas observadas reflejan un buen

rendimiento general.

6.7. Entrenamiento de los modelos de aprendizaje automático Máquina de Vectores de Soporte Lineal (SVML).

6.7.1. Resultados del modelo entrenado

Parámetros de entrada: Con el análisis realizado a través de la matriz de correlación, se determinó los siguientes parámetros de ingreso, para realizar el entrenamiento del modelo SVML, la longitud de los vectores deben ser de la misma longitud.

Tabla 22

Definiciones de los parámetros de entrada.

Parámetro	Descripción	Dimensión
ECT	Temperatura del Refrigerante del Motor	12000x1
LTFT	Ajuste a Largo Plazo de Combustible	12000x1
MAP	Presión Absoluta del Colector	12000x1
STFT	Ajuste a Corto Plazo de Combustible	12000x1
ATE	Avance del Tiempo de Encendido	12000x1
RPMS	Revoluciones por Minuto del Motor	12000x1
IAT	Temperatura del Aire de Admisión	12000x1
TPS	Posición del Sensor del Acelerador	12000x1
VSS	Velocidad del Vehículo	12000x1

Etiquetas de fallas establecidas para el entrenamiento:

Tabla 23*Etiquetas de las condiciones de falla*

Etiqueta	Condición de fallo	N
Clase 1	Condición Normal	CN
Clase 2	Flujo de masa de aire	MAF
Clase 3	Avance del tiempo de encendido	ATE
Clase 4	Temperatura del refrigerante del motor	ECT

6.7.2. Matriz del número de observaciones

La matriz de confusión mostrada proporciona un resumen del rendimiento del modelo SVM lineal (SVML) en términos del número de observaciones clasificadas en cada clase.

Figura 37

Número de observaciones (SVML).

Number of observations (Linear SVM)

True Class	1	2	3	4
1	2187	216	516	81
2	445	2102	332	121
3	360	419	2068	153
4		14	25	2961

Predicted Class

Nota: Se observa la matriz del número de observaciones del modelo de aprendizaje automático SVML (Guartazaca, 2024).

■ Clase 1

- Correctamente Clasificadas (Verdaderos Positivos): 2187 observaciones fueron correctamente identificadas como Clase 1.
- Falsos Negativos: 445 observaciones de Clase 1 fueron clasificadas incorrectamente como Clase 2, 360 como Clase 3 y 14 como Clase 4.
- Falsos Positivos: 216 observaciones fueron clasificadas incorrectamente como Clase

1 desde la Clase 2, 516 desde la Clase 3 y 81 desde la Clase 4.

■ Clase 2

- Correctamente Clasificadas (Verdaderos Positivos): 2102 observaciones fueron correctamente identificadas como Clase 2.
- Falsos Negativos: 216 observaciones de Clase 2 fueron clasificadas incorrectamente como Clase 1, 419 como Clase 3 y 25 como Clase 4.
- Falsos Positivos: 445 observaciones fueron clasificadas incorrectamente como Clase 2 desde la Clase 1, 332 desde la Clase 3 y 121 desde la Clase 4.

■ Clase 3

- Correctamente Clasificadas (Verdaderos Positivos): 2068 observaciones fueron correctamente identificadas como Clase 3.
- Falsos Negativos: 516 observaciones de Clase 3 fueron clasificadas incorrectamente como Clase 1, 332 como Clase 2 y 153 como Clase 4.
- Falsos Positivos: 360 observaciones fueron clasificadas incorrectamente como Clase 3 desde la Clase 1, 419 desde la Clase 2 y 153 desde la Clase 4.

■ Clase 4

- Correctamente Clasificadas (Verdaderos Positivos): 2961 observaciones fueron correctamente identificadas como Clase 4.
- Falsos Negativos: 81 observaciones de Clase 4 fueron clasificadas incorrectamente como Clase 1, 121 como Clase 2 y 153 como Clase 3.
- Falsos Positivos: 14 observaciones fueron clasificadas incorrectamente como Clase 4 desde la Clase 1, 25 desde la Clase 2 y 153 desde la Clase 3.

■ Observaciones:

- Alta precisión en la clase 4: La clase 4 muestra una alta precisión con 2961 observaciones correctamente clasificadas y muy pocos casos clasificados erróneamente en otras clases.
- Necesidad de mejora en las clases 1 y 2: Las clases 1 y 2 presentan un número significativo de falsos positivos y falsos negativos, lo que indica que el modelo

podría beneficiarse de ajustes adicionales o de la incorporación de más datos de entrenamiento para estas clases.

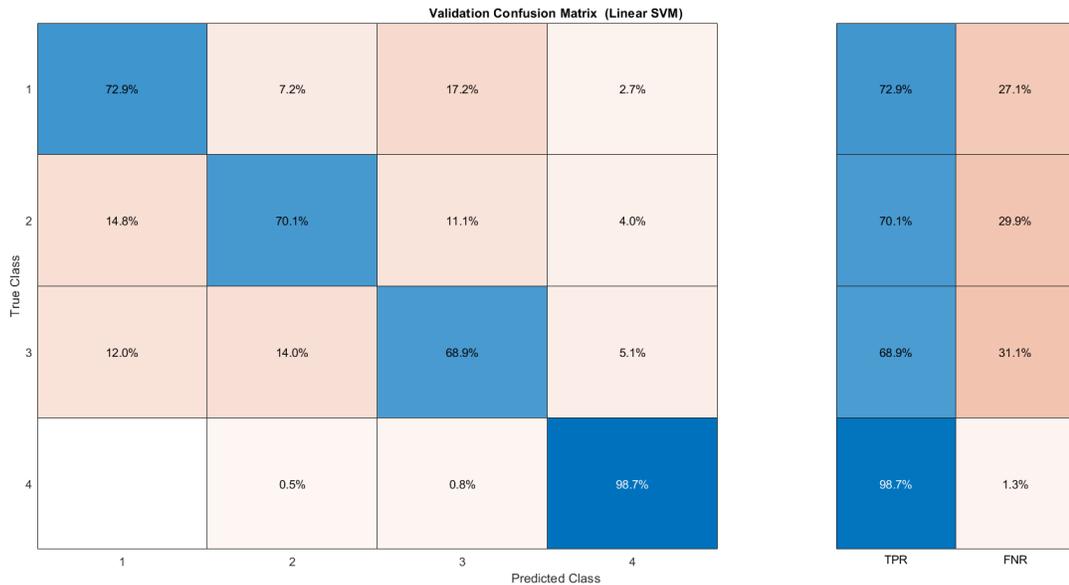
- Clase 3: Aunque la clase 3 tiene un buen número de verdaderos positivos, también muestra un número significativo de falsos negativos y falsos positivos, lo que sugiere la necesidad de optimización.

6.7.3. Matriz de confusión TPR y FNR

La imagen muestra una matriz de confusión y las tasas de verdaderos positivos (TPR) y falsos negativos (FNR) de cada clase.

Figura 38

Validación de la matriz de confusión (SVML).



Nota: Se observa la validación de la matriz de confusión del modelo de aprendizaje automático SVML (Guartazaca, 2024).

Tabla 24*Resultados de Precisión y Falsos Positivos por Clase*

Clase	Precisión	Falsos Positivos
Clase 1	72.9%	27.1%
Clase 2	70.1%	29.9%
Clase 3	68.9%	31.1%
Clase 4	98.7%	1.3%

- Clase 1: El modelo clasifica correctamente el 72,9% de las instancias, con un 7,2% y un 17,2% de las instancias clasificadas incorrectamente como Clase 2 y Clase 3, respectivamente.
- Clase 2: El modelo clasifica correctamente el 70,1% de las instancias, pero clasifica incorrectamente el 14,8% como Clase 1 y el 11,1% como Clase 3.
- Clase 3: La precisión es del 68,9%, con un 12% y un 14% de casos clasificados incorrectamente como Clase 1 y Clase 2, respectivamente.
- Clase 4: La mayor precisión se encuentra en la Clase 4 con un 98,7%, con muy pocos casos clasificados erróneamente.

6.7.4. Resultados del modelo entrenado SVM

Parametros de resultados

Tabla 25*Resultados del modelo SVM*

Categoría	Detalles
Resultados del Entrenamiento	
Precisión (Validación)	77.6%
Costo total (Validación)	2682
Velocidad de predicción	~230000 obs/seg
Tiempo de entrenamiento	11.604 seg
Tamaño del modelo (Compacto)	~36 kB
Hiperparámetros del Modelo	
Preconfiguración	SVM Lineal
Función del kernel	Lineal
Escala del kernel	Automática
Nivel de restricción de caja	1
Codificación multiclase	Uno contra uno
Estandarizar datos	Sí
Selección de Características	10/10 características individuales seleccionadas
PCA	Desactivado
Costos de Clasificación Incorrecta	Por defecto
Optimizador	No aplicable

Observaciones

El modelo utilizado es un SVM lineal (SVML) y ha sido entrenado y validado. A continuación se presentan los resultados y las características del modelo:

- Resultados de entrenamiento:
 - Precisión (Validación) 77.6%: La precisión indica que el modelo clasifica correctamente el 77,6% de las instancias del conjunto de validación. Esto significa que, en general, el modelo funciona bien, aunque puede mejorarse.

- Costo total (validación) 2682: Este valor representa la suma de los errores de clasificación ponderados por su coste. Un coste menor indica un mejor rendimiento.
 - Velocidad de predicción: 230000 observaciones/seg. La alta velocidad de predicción sugiere que el modelo es eficiente y puede procesar grandes volúmenes de datos rápidamente, lo que es beneficioso para aplicaciones en tiempo real
 - Tiempo de entrenamiento: 11.604 segundos El tiempo necesario para entrenar el modelo fue de aproximadamente 11,6 segundos, lo que es razonablemente rápido y muestra que el modelo no es excesivamente complejo.
 - Tamaño del modelo (compacto): 36 kB El tamaño compacto del modelo, 36 kB, sugiere que es eficiente en términos de almacenamiento y que podría implementarse fácilmente en dispositivos con limitaciones de memoria.
- Hiperparámetros del modelo.
 - Prestablecidos: SVM lineal El modelo utiliza una SVM con una función de núcleo lineal, adecuada para datos linealmente separables.
 - Función de núcleo Lineal: La función de núcleo lineal es sencilla y rápida de calcular, pero puede que no capture las complejidades no lineales de los datos.
 - Escala del núcleo: Automática La escala del núcleo se ajusta automáticamente, lo que ayuda a mejorar el rendimiento del modelo sin necesidad de ajustes manuales.
 - Nivel de restricción de caja: 1 El nivel de restricción de caja de 1 implica una regularización estándar que ayuda a evitar el sobreajuste.
 - Codificación multiclase: Uno contra uno El método Uno-vs-Uno es adecuado para problemas de clasificación multiclase, creando un clasificador para cada par de clases.
 - Estandarizar datos: Sí Los datos se estandarizan antes de entrenar el modelo, lo que ayuda a mejorar el rendimiento y la convergencia de la SVM.
 - Selección de características.
 - Selección de características: 10/10 características individuales seleccionadas Se seleccionaron todas las características disponibles, lo que indica que todas son relevantes para el modelo.
 - Configuración adicional.

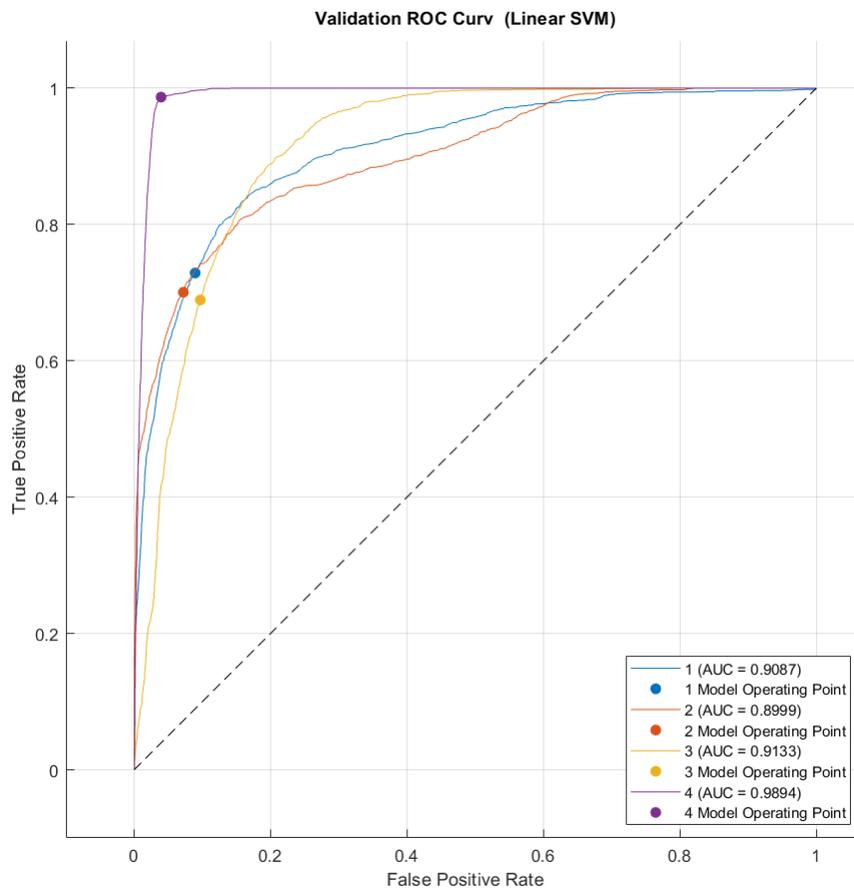
- PCA: desactivado El análisis de componentes principales (PCA) está desactivado, lo que significa que no se ha realizado ninguna reducción de la dimensionalidad.
- Costes de clasificación errónea: Por defecto
 - Los costes de clasificación errónea se mantienen por defecto, sin ajustes adicionales para penalizar aún más ciertos errores.
- Optimizador: No aplicable
 - No se utilizó un optimizador específico, posiblemente porque no es necesario para este tipo de SVM lineal.

6.7.5. Curva ROC de desempeño del modelo SVML entrenando

La imagen presenta las curvas ROC (Receiver Operating Characteristic) para el modelo SVML entrenado, mostrando el rendimiento del modelo en términos de Tasa de Verdaderos Positivos (TPR) y Tasa de Falsos Positivos (FPR) para cuatro clases diferentes.

Figura 39

Curva ROC del desempeño del algoritmo SVML.



Nota: Se observa la curva ROC del desempeño del algoritmo SVML. (Guartazaca, 2024).

■ Descripción general.

- Eje X (Tasa de falsos positivos): Representa la tasa de falsos positivos.
- Eje Y (Tasa de verdaderos positivos): Representa la tasa de verdaderos positivos.
- Curvas ROC: Cada línea representa la curva ROC para una de las clases de modelos SVML.
- Puntos operativos del modelo: Indica el rendimiento del modelo en puntos específicos.

- Análisis por clase:
 - Clase 1: AUC: 0.9087 Interpretación: Un AUC de 0,9087 indica un rendimiento excelente para la Clase 1, con una gran capacidad para distinguir entre clases positivas y negativas.
 - Clase 2: AUC: 0.8999 Interpretación: El AUC de 0,8999 muestra que el modelo también funciona bien para la Clase 2, aunque ligeramente por debajo de la Clase 1.
 - Clase 3: AUC: 0.9133 Interpretación: La Clase 3 tiene un AUC de 0,9133, lo que sugiere un rendimiento excelente, incluso mejor que la Clase 2.
 - Clase 4: AUC: 0.9894 Interpretación: La clase 4 tiene el AUC más alto de 0,9894, lo que indica un rendimiento casi perfecto, con una capacidad extremadamente alta para distinguir entre clases.

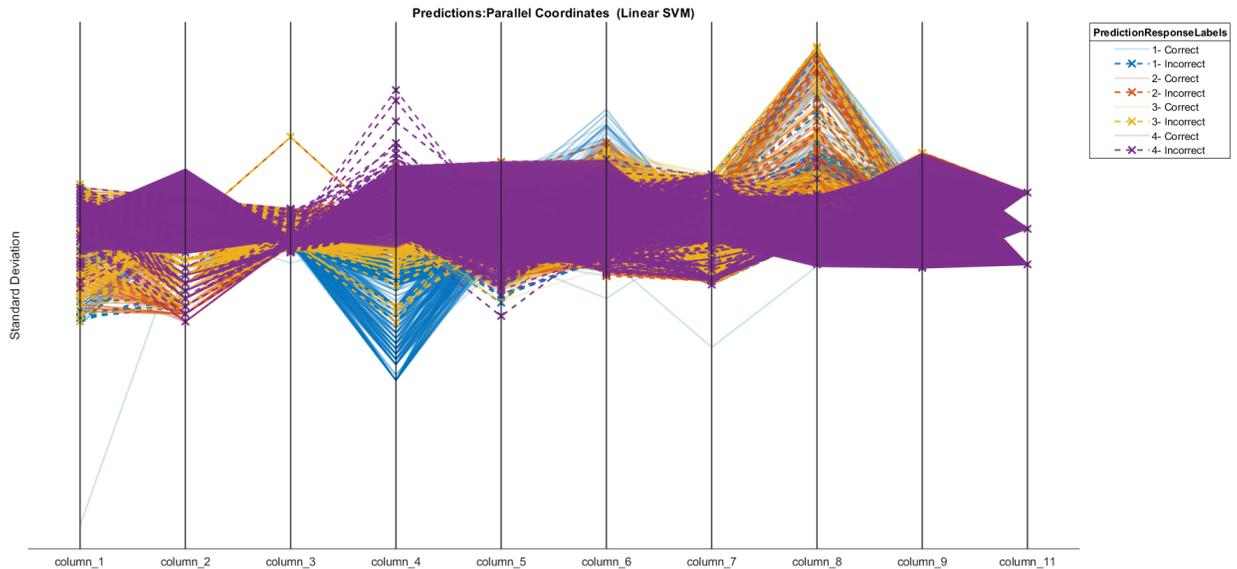
- Observaciones generales.
 - Curva ROC ideal: Una curva ROC ideal pasaría por el punto superior izquierdo (0,1), donde TPR es 1 y FPR es 0, indicando una clasificación perfecta.
 - Áreas bajo la curva (AUC): Las AUC altas (cercanas a 1) indican que el modelo tiene un alto rendimiento en la mayoría de las clases.
 - Comparación entre clases: La clase 4 muestra el mejor rendimiento con el AUC más alto, seguida de las clases 3, 1 y 2. Esto sugiere que el modelo tiene un rendimiento más preciso en la mayoría de las clases. Esto sugiere que el modelo clasifica con mayor precisión las instancias de la Clase 4 en comparación con las demás.
 - Puntos operativos del modelo: Los puntos operativos de la curva indican el rendimiento específico del modelo en determinados umbrales. Estos puntos son útiles para comprender cómo se comporta el modelo en situaciones específicas y para ajustar el umbral de decisión con el fin de optimizar el rendimiento.

6.7.6. Coordenadas paralelas del algoritmo de predicción de fallas SVM

Cada eje vertical representa una característica o variable del conjunto de datos. Los ejes están etiquetados de la columna 1 a la columna 11.

Figura 40

Coordenadas paralelas del algoritmo de predicción de fallas SVML.



Nota: Se observa las coordenadas paralelas obtenidas del algoritmo de predicción de fallas utilizando el modelo SVML. (Guartazaca, 2024).

Observaciones y patrones

- Clase 1 (azul y azul claro):
 - Las líneas azules representan predicciones correctas y las líneas azul claro predicciones incorrectas para la Clase 1.
 - Se observa una agrupación de líneas azules, lo que sugiere que ciertas combinaciones de características están bien clasificadas.
 - Las líneas azul claro indican áreas en las que el modelo puede tener dificultades, lo que sugiere características que pueden necesitar más atención o ajustes.
- Clase 2 (naranja y naranja claro):
 - Las líneas naranja (correctas) y naranja claro (incorrectas) muestran una variabilidad similar a la de la clase 1. Las líneas naranjas parecen más dispersas que las naranjas

- Las líneas naranjas parecen estar más dispersas, lo que podría indicar una mayor dificultad para clasificar correctamente esta clase.
- Clase 3 (amarillo y amarillo claro):
 - Las líneas amarillas y amarillo claro siguen un patrón en el que hay menos líneas correctas en comparación con las incorrectas, lo que indica una mayor tasa de error para esta clase.
- Clase 4 (morado y morado claro):
 - Las líneas moradas (correctas) dominan claramente, lo que indica que el modelo tiene un alto rendimiento en la clasificación de esta clase.
 - Las pocas líneas de color morado claro (incorrectas) sugieren que hay pocos errores en esta clase.

7. Resultados

- El primer paso de esta investigación fue la recopilación de datos relevantes y la identificación de los parámetros clave que influirían en el rendimiento del modelo de predicción de fallas en motores de combustión interna, estos se observan en la tabla 2.
La programación en el dispositivo Freematics permite establecer los parámetros requeridos y realizar su adquisición de los datos. La extracción, clasificación y estructuración de los parámetros adquiridos mediante la programación en el software MATLAB permite acceder a todos los datos y realizar posteriores análisis. Se aplicaron métodos estadísticos como la desviación estándar, máximos y mínimos e interpolación, de cada parámetro. La matriz de correlación que nos ayuda a identificar que tan fuertemente están relacionados, su influencia entre los diferentes parámetros. Así mismo, ayuda a reducir la redundancia de datos, y mejorar la interpretabilidad del modelo de predicción de fallas.
- Una vez obtenidos los datos, se procede a analizar el comportamiento del modelo de predicción de fallas mediante el entrenamiento y la validación con un conjunto de datos de prueba. Se utilizó el modelo SVM Lineal (SVML) debido a su eficacia en la clasificación de datos de alta dimensión y su capacidad para manejar relaciones lineales. Además, se realizó entrenamientos en los modelos de aprendizaje: árbol de decisiones fino (97.2%), KNN (97.3%), y red neuronal estrecha (96.2%). Sin embargo, estos modelos

no fueron escogidos como modelo final debido a que muestran un posible sobreajuste, ya que mostraron elevados porcentajes de precisión. En contraste, el modelo SVM fue seleccionado porque muestra un mejor manejo de datos.

Resultados del Análisis:

- Precisión (Validación): 77.6%
- Velocidad de Predicción: 230000 observaciones/s
- Tiempo de Entrenamiento: 11.604 segundos
- Tamaño del Modelo: 36 kB

Curvas ROC y Matriz de Confusión: Las curvas ROC mostraron un rendimiento sólido del modelo, con áreas bajo la curva (AUC) de 0.9087 para la Clase 1, 0.8999 para la Clase 2, 0.9133 para la Clase 3 y 0.9894 para la Clase 4. La matriz de confusión indicó que el modelo tiene un alto rendimiento general, aunque hay áreas específicas donde el modelo podría beneficiarse de ajustes adicionales, particularmente en las Clases 1, 2 y 3. Se realizó la validación del modelo utilizando un conjunto de datos independiente para asegurar que el modelo no solo tiene un buen rendimiento en el conjunto de entrenamiento, sino que también generaliza bien a datos no vistos.

Resultados de la Validación:

- Precisión Global: 77.6%

Precisión por Clase:

- Clase 1: 73.1
- Clase 2: 76.4
- Clase 3: 70.3
- Clase 4: 89.3

Los resultados de la validación confirman que el modelo tiene un rendimiento consistente y puede ser utilizado para la predicción de fallas en motores de combustión interna. La alta precisión en la Clase 4 indica que el modelo tiene un buen desempeño en dicha categoría.

- Se realizó la validación del modelo utilizando un conjunto de datos independiente para asegurar que el modelo no solo tiene un buen rendimiento en el conjunto de entrenamiento, sino que también generaliza bien a datos no vistos.

Resultados de la Validación:

- Precisión Global: 77.6%

Precisión por Clase:

- Clase 1: 73.1%
- Clase 2: 76.4%
- Clase 3: 70.3%
- Clase 4: 89.3%

Los resultados de la validación confirman que el modelo tiene un rendimiento consistente y puede ser utilizado para la predicción de fallas en motores de combustión interna. La alta precisión en la Clase 4 indica que el modelo es particularmente eficaz en la identificación de ciertas fallas críticas.

8. Cronograma

Tabla 26

Cronograma de actividades.

CRONOGRAMA DE ACTIVIDADES																										
OBJETIVOS ESPECÍFICOS	ACTIVIDADES	MES 1				MES 2				MES 3				MES 4				MES 5				MES 6				HORAS
		1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	
Recopilar información relacionada con el diseño de un modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna.	Primer acercamiento al Scanner MaxiSys MSgo6 y a motores de combustión interna de 4 tiempos .	X	X																							
	Revisión bibliográfica de modelos de predicción de fallas mediante aprendizaje automático.			X	X																					
	Identificación de los parámetros a ser adquiridos.					X	X																			
	Establecimiento de las condiciones iniciales del motor de combustión interna de 4 tiempos mediante el Scanner MaxiSys MSgo6 .							X	X																	
Obtener los parametros iniciales para el diseño de un modelo de predicción de fallas mediante aprendizaje automático.	Adquisición de los parámetros establecidos.	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
	Clasificación de los parámetros.									X	X															
	Revisión de los parámetros.										X	X														
	Depuración de los datos.												X	X												
Realizar el diseño de un modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna.	Diseñar algoritmo de predicción de fallas.														X	X										
	Realizar pruebas aisladas del modelo de predicción de fallas.															X	X									
	Armado del diseño de control.																X	X								
	Realizar pruebas del diseño de control.																			X	X					
	Implementar el diseño de control.																					X	X			
Evaluar el diseño de un modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna.	Pruebas del modelo de predicción de fallas mediante aprendizaje automático.																						X	X		
	Calibración del modelo de predicción de fallas mediante aprendizaje automático.																						X	X		
	Redacción de documento	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
Total de horas empleadas																									400	

Nota: La tabla presenta las actividades para cumplir con los objetivos planteados.

9. Presupuesto

9.1. Talento humano

Tabla 27

Recurso de talento humano.

Cargo	Nombre	Costo hora	horas al mes	Total de horas	Costo total
Tutor	Nestor Rivera	15\$	8	48	960 \$
Autor 1	Santiago Guartazaca	8\$	–	400	3200 \$

Nota: En la tabla se observa el costo de las 400horas establecidas en el cronograma de trabajo y el costo de las horas de revisión por parte del docente revisor que se calendarizarán al inicio de TT2.

9.2. Recursos materiales

Tabla 28

Recurso de talento humano.

Denominación	Cantidad	Costo Unitario	Costo total
Software	1	1000	1000 \$
Laboratorio	1	200	200 \$
Escáner MaxiSys MSgo6	1	120	2500 \$
Freematics ONE+	1	2500	120 \$

Nota: En la tabla se observa el costo a considerar de diferentes elementos para el desarrollo del trabajo de titulación, con referencia al uso del software MATLAB se coloca un aproximado del costo total de las licencias. De igual manera el costo por el uso de los laboratorios es un aproximado de acuerdo al número de horas proyectadas a utilizar.

10. Conclusiones

- El primer paso de la investigación fue recopilar datos relevantes y definir los parámetros clave que afectan el rendimiento del modelo de predicción de fallas en motores de combustión interna. Se programó el dispositivo Freematics ONE+ para adquirir los datos específicos necesarios y utilizamos MATLAB para extraer, clasificar y estructurar estos parámetros. Se aplicó métodos estadísticos como la desviación estándar, máximos y mínimos, e interpolación, y se procedió a utilizar la matriz de correlación para identificar relaciones entre los parámetros. Esto permitió reducir la redundancia de datos y mejorar la interpretación del modelo, estableciendo una base sólida de datos para la construcción del modelo predictivo.
- El análisis del comportamiento del modelo de predicción de fallas mediante aprendizaje automático en motores de combustión interna mostró resultados prometedores. La elección del modelo SVM Lineal (SVML) se justificó por su capacidad para manejar datos de alta dimensión y relaciones lineales de manera efectiva. Los resultados del análisis demostraron una precisión global del 77.6% en la validación, con tiempos de predicción y entrenamiento eficientes y un tamaño de modelo compacto. Los modelos alternativos de árbol de decisiones fino (97.2%), KNN (97.3%), y red neuronal estrecha (96.2%) fueron considerados, pero no se seleccionaron debido a las altas posibilidades de sobre ajustes reflejados en elevados porcentajes de precisión. En contraste, el SVML mostró un mejor manejo de datos y una mayor capacidad de generalización. Las curvas ROC y la matriz de confusión mostraron un rendimiento sólido del modelo, con áreas bajo la curva (AUC) altas para todas las clases, especialmente para la Clase 4, aunque identificaron áreas donde se podrían realizar mejoras adicionales, particularmente en las Clases 1, 2 y 3. L Estos resultados demuestran que el modelo SVML es efectivo, pero también resaltan la importancia de continuar optimizándolo para mejorar su precisión en todas las clases.
- Se validó el modelo utilizando un conjunto de datos independiente para asegurar que no solo funciona bien en el conjunto de entrenamiento, sino que también generaliza adecuadamente a datos nuevos. La precisión global del 77.6% y la alta precisión en la Clase 4 (89.3%) indican que el modelo es particularmente eficaz en la identificación de ciertas fallas críticas. Estos resultados confirman la hipótesis planteada, por la consistencia y aplicabilidad del modelo para la predicción de fallas en motores de combustión interna, proporcionando una herramienta confiable para el diagnóstico y

mantenimiento preventivo de estos motores.

11. Recomendaciones

- Se recomienda adquirir datos de una mayor variedad de modelos de vehículos que presenten distintas fallas. Este enfoque contribuirá a la generalización del modelo de predicción de fallas SVM, asegurando que el modelo sea capaz de identificar y predecir una amplia gama de fallas en diferentes tipos de vehículos. Al incorporar datos más diversos, se mejorará la robustez y precisión del modelo, facilitando su aplicación en un entorno real con múltiples variantes y condiciones operativas de motores de combustión interna.
- Así mismo se debe realizar el entrenamiento con distintos modelos de aprendizaje automático, este enfoque permitirá verificar la precisión de predicción de cada modelo y confirmar que no se produzca un sobreajuste. Al comparar los resultados obtenidos con cada modelo, se puede identificar cuál ofrece el mejor equilibrio entre precisión y capacidad de generalización, asegurando así un rendimiento robusto y confiable del modelo predictivo en diversas condiciones de operación de los motores de combustión interna.

Referencias

- Ahmed, I. (2020). Engine coolant temperature sensor in automotive applications. *Technische Universität Chemnitz*.
- Andrés Gustavo Loja Cajas, P. F. F. U., Edgar Jamil Fernández Sarmiento. (2012). *Diseño y construcción de un indicador electrónico para el cambio de velocidades en un vehículo volkswagen golf año 1995* (Tesis Doctoral no publicada). Universidad Politécnica Salesiana, Cuenca, Ecuador. (Director: MSc. Efrén Fernández)
- Arias Montaña, E. I., y Ludeña Ayala, J. A. (2018). *Estimación del consumo de combustible y niveles de emisiones contaminantes de un vehículo de categoría m1 en rutas con mayor grado de saturación en la ciudad de cuenca* (B.S. thesis).
- Basri, E., y otros. (2017). Preventive maintenance (pm) planning: a review. *Journal of Quality in Maintenance Engineering*. Descargado de <https://www.emerald.com/insight/content/doi/10.1108/JQME-04-2016-0014/full/html> (Consultado en julio de 2024)
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. New York: Springer.
- Boland, H., Burgett, M., Etienne, A., y III, R. (2021, 07). An overview of can-bus development, utilization, and future potential in serial network messaging for off-road mobile equipment.. doi: 10.5772/intechopen.98444
- Bosch. (2014). *Bosch automotive handbook* (9.^a ed.). Bentley Publishers.
- Breiman, L., Friedman, J. H., Olshen, R. A., y Stone, C. J. (1984). *Classification and regression trees*. Wadsworth International Group.
- Calle Jara, C. P., y Vicuña Pacheco, D. G. (2015). *Identificación y análisis de eventos transitorios en motores de combustión interna mediante la posición del cigüeñal y árbol de levas, utilizando procesamiento de señales* (B.S. thesis).
- CAM2. (2024). *Buscan - ¿qué es y cómo funciona el bus can?* Descargado de <https://www.cam2.com.pe/single-post/buscan>
- Campoverde, P. A. M., Campoverde, N. D. R., Espinoza, J. E. M., Fernandez, G. M. R., y Novillo, G. P. (2022). Influence of the road slope on nox emissions during start up. *Materials Today: Proceedings*, 49, 8–15.
- Car Truck. (2024). *What should long term and short term fuel trim be?* Descargado de <https://carandtruck.org/what-should-long-term-and-short-term-fuel-trim-be/> (Consultado en julio de 2024)
- Carlos, V. (2020). *Aprendizaje automático. introducción al aprendizaje profundo*. El Fondo Editorial de la Pontificia Universidad Católica del Perú. Des-

- cargado de <https://bibliotecas.ups.edu.ec:2681/login.aspx?direct=true&db=e000xww&AN=2600876&site=ehost-live>
- CarParts.com. (2024). *What are short-term and long-term fuel trims?* Descargado de <https://www.carparts.com/blog/what-are-short-term-and-long-term-fuel-trims/> (Consultado en julio de 2024)
- Carvalho, T. P., Soares, F. A. A. M. N., Vita, R., da P. Francisco, R., Basto, J. P., y Alcalá, S. G. S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers Industrial Engineering*, 137, 106024. Descargado de <https://www.sciencedirect.com/science/article/pii/S0360835219304838> doi: <https://doi.org/10.1016/j.cie.2019.106024>
- De Antonio, A. R., y Muñoz Domínguez, M. (2016). *Motores de combustión interna*.
- Freematics. (2024). *Freematics one+ model b*. Descargado de <https://freematics.com/products/freematics-one-plus-model-b/>
- General Technologies Corp. (2024). *Long-term & short-term fuel trim*. Descargado de <https://gtc.ca/blog/long-term-fuel-trim-and-short-trim-fuel-trim/> (Consultado en julio de 2024)
- GmbH, R. B. (2019). *Sensors* [Manual de software informático]. Descargado de <https://www.bosch-ibusiness.com/es/productos/sensores/>
- Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep learning*. Cambridge, MA: MIT Press.
- Guartazaca, S. (2024). *Gráfica de la temperatura del refrigerante del motor, ect.* (Imagen creada con MATLAB, archivo personal)
- Gutiérrez, A. M. (2009). *Mantenimiento planeación, ejecución y control* (M. Alfaomega Grupo Editor S.A. de C.V., Ed.). Pimera Edición.
- Hastie, T., Tibshirani, R., y Friedman, J. (2009). *The elements of statistical learning*. New York: Springer.
- Hella. (2023). *Thermo range brochure*. Descargado de https://www.hella.com/hella-za/assets/media_global/HASA_Thermo_Range_Borchure_LRes.pdf (Accessed: 2024-07-03)
- Heywood, J. B. (1988). *Internal combustion engine fundamentals*. McGraw-Hill Education.
- Hsu, C.-W., Chang, C.-C., y Lin, C.-J. (2002). A practical guide to support vector classification [Manual de software informático]. (Disponible en: <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>)
- Jachero Arízaga, G. A. (2016). *Levantamiento de una base de datos para el diagnóstico de fallas en motores de combustión interna ciclo otto con sistema mpfi mediante el análisis*

del sensor map (B.S. thesis).

- Jambor-Sadeghi, K., Ketabchi, M. A., Chue, J., y Ghiassi, M. (1994, 01). A Systematic Approach to Corrective Maintenance. *The Computer Journal*, 37(9), 764-778. Descargado de <https://doi.org/10.1093/comjnl/37.9.764> doi: 10.1093/comjnl/37.9.764
- James, G., Witten, D., Hastie, T., y Tibshirani, R. (2013). *An introduction to statistical learning*. New York: Springer.
- Johnson, R. A., y Wichern, D. W. (2007). *Applied multivariate statistical analysis*. Pearson Prentice Hall.
- Kotu, V., y Deshpande, B. (2019). Chapter 1 - introduction. En V. Kotu y B. Deshpande (Eds.), *Data science (second edition)* (Second Edition ed., p. 1-18). Morgan Kaufmann. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780128147610000010> doi: <https://doi.org/10.1016/B978-0-12-814761-0.00001-0>
- MathWorks. (2024). *Machine learning*. Descargado de <https://la.mathworks.com/discovery/machine-learning.html>
- MaxiSys MS906 - autel*. (s.f.). <https://www.autel.com/es/mk3/3217.jhtml>. (Accessed: 2023-6-2)
- Molina Campoverde, P. A., Rivera Campoverde, N. D., Novillo Quirola, G. P., y Bermeo Naula, A. K. (2020, octubre). Characterization of braking and clutching events of a vehicle through obd ii signals. En *Advances in intelligent systems and computing* (pp. 134-143). Springer International Publishing. doi: 10.1007/978-3-030-59194-6_12
- Montgomery, D. C., y Runger, G. C. (2014). *Applied statistics and probability for engineers* (6th ed.). Wiley.
- NAPA Know How. (2024). *What is a throttle position sensor?* Descargado de <https://knowhow.napaonline.com/what-is-a-throttle-position-sensor/> (Consultado en julio de 2024)
- Néstor Diego, R. C., Molina Campoverde, P. A., Quirola Novillo, G. P., y Naula Bermeo, A. K. (2020). Development of an algorithm capable of classifying the starting, gear change and engine brake variables of a vehicle by analyzing obd ii signals. En *International conference on systems and information sciences* (pp. 121-133).
- Nielsen, M. A. (2015). *Neural networks and deep learning*. (Disponible en: <http://neuralnetworksanddeeplearning.com/>)
- Pulkrabek, W. W. (2004). *Engineering fundamentals of the internal combustion engine*. Pearson Education.
- Rivera, N. D., Molina, P. A., Bermeo, A. K., Bermeo, O. E., y Figueroa, J. L. (2022). Driving style analysis by studying pid's signals for determination of its influence on

- pollutant emissions. En *Communication, smart technologies and innovation for society: Proceedings of citis 2021* (pp. 321–331).
- Rivera Campoverde, N., Chica, F., y Zambrano, I. (2015). *Estudio del comportamiento de un motor ciclo otto de inyección electrónica respecto de la estequiometría de la mezcla y del adelanto al encendido para la ciudad de cuenca*. Cuenca: Escuela Politécnica Nacional.
- Road to Reliability. (2024). *What are the 5 types of preventive maintenance?* Descargado de <https://reliabilityacademy.com> (Consultado en julio de 2024)
- Schölkopf, B., y Smola, A. J. (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. Cambridge, MA: MIT Press.
- Smola, A. J., y Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199-222. (Disponible en: <https://alex.smola.org/papers/2004/SmoSch04.pdf>) doi: 10.1023/B:STCO.0000035301.49549.88
- Stewart, J. (2015). *Calculus: Early transcendentals* (8th ed.). Cengage Learning.
- Stone, R. (2012). *Introduction to internal combustion engines*. Palgrave Macmillan.
- Sánchez, . D. S., C. (2012, enero). Implementación de un tablero didáctico del sistema de inyección electrónica multipunto multec iefi-6 para la escuela de ingeniería automotriz.
- The Drive. (2024). *What should long term and short term fuel trim be?* Descargado de <https://www.thedrive.com/cars-101/38138/what-should-long-term-and-short-term-fuel-trim-be> (Consultado en julio de 2024)
- The Motor Guy. (2024). *Throttle position sensor: Location and function*. Descargado de <https://themotorguy.com/throttle-position-sensor-location-and-function/> (Consultado en julio de 2024)
- The Tuning School. (2024). *Fuel trims & the tuning process*. Descargado de <https://thetuningschool.com/blogs/news/fuel-trims-the-tuning-process> (Consultado en julio de 2024)
- Tovar-Lopez, F. J. (2023, junio). Recent progress in micro- and nanotechnology-enabled sensors for biomedical and environmental challenges. *Sensors*, 23(12), 5406. doi: 10.3390/s23125406
- Trade Mechanic. (2024). *Understanding short term and long term fuel trims*. Descargado de <https://trade.mechanic.com.au/news/understanding-short-term-and-long-term-fuel-trims1> (Consultado en julio de 2024)
- Universidad politécnica salesiana del ecuador. (2023). Sitio web de la Universidad Politécnica Salesiana del Ecuador. Disponible en: <https://www.ups.edu.ec/>.
- Vacacela Romero, J. H., y Rivera Carrión, N. F. (2018). *Estudio de las señales pid's obtenidas a través de obd-ii en función de las maniobras de conducción, arranque, cambio de*

marcha y freno motor para el desarrollo de un algoritmo (B.S. thesis).

Vergara, M., Ramos, L., Rivera-Campoverde, N. D., y Rivas-Echeverría, F. (2023). Engine-faultdb: a novel dataset for automotive engine fault classification and baseline results. *IEEE Access*, *11*, 126155–126171.

Wikipedia. (2024). *Throttle position sensor*. Descargado de https://en.wikipedia.org/wiki/Throttle_position_sensor (Consultado en julio de 2024)

ANEXOS

Anexo 1: Entrenamiento del modelo de aprendizaje SVML en vehículos individuales

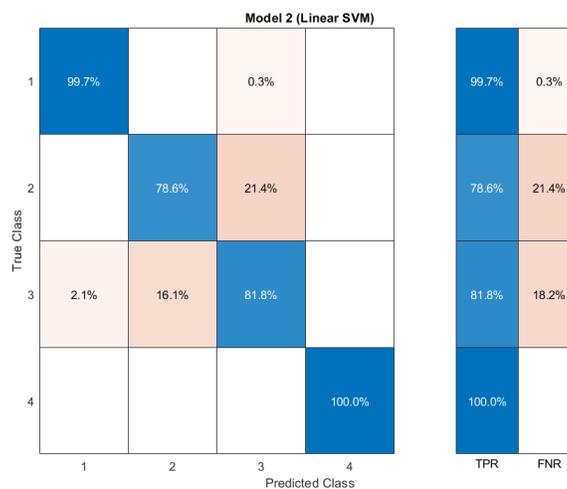
Tabla 29

Resultados del Modelo SVM

Parámetro	Modelo 1	Modelo 2	Modelo 3
Precisión (Validación)	90.0%	99.2%	88.0%
Costo total (Validación)	399	34	479
Velocidad de predicción (obs/sec)	36000	77000	79000
Tiempo de formación (sec)	4.577	2.3565	2.3449
Tamaño del modelo (Compact)	35 kB	35 kB	35 kB

Figura 41

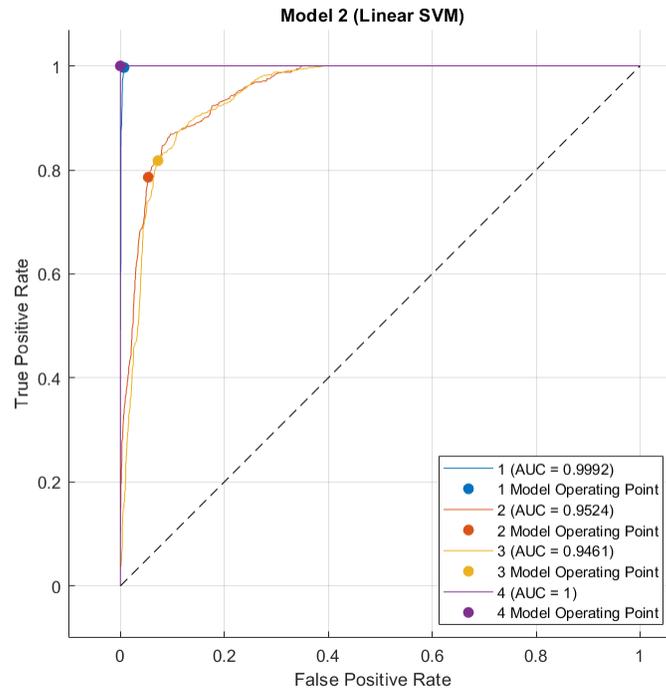
Matriz de confusión modelo SVML para vehículo 1



Nota: Se observa la matriz de confusión modelo SVML para vehículo vehículo 1 (Guartazaca, 2024).

Figura 42

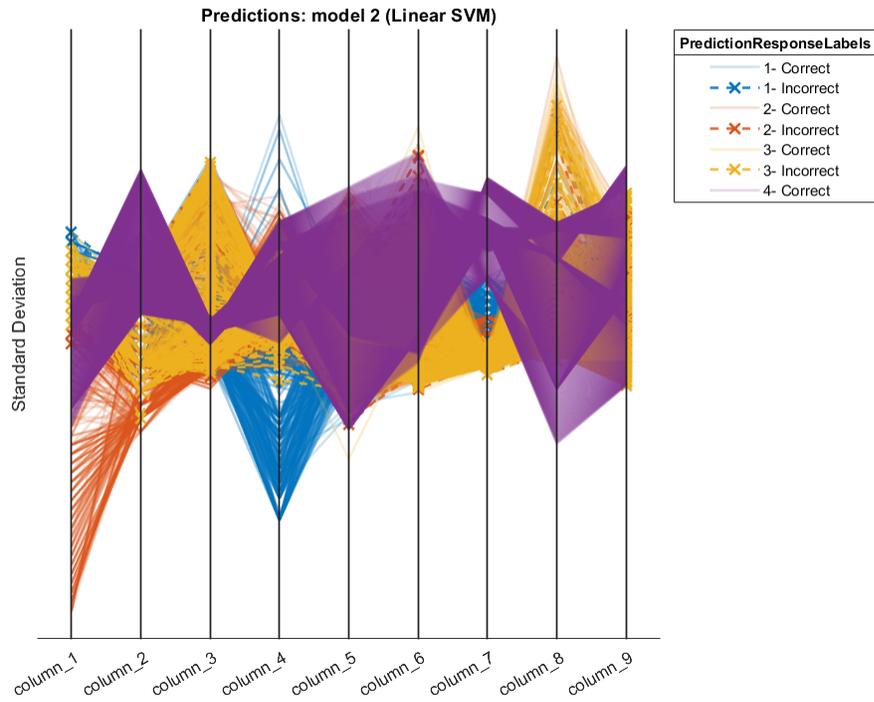
Curva ROC del desempeño del algoritmo SVML.



Nota: Se observa la curva ROC del desempeño del algoritmo SVML. (Guartazaca, 2024).

Figura 43

Coordenadas paralelas del algoritmo de predicción de fallas SVML.



Nota: Se observa las coordenadas paralelas obtenidas del algoritmo de predicción de fallas utilizando el modelo SVML en el vehículo 1. (Guartazaca, 2024).

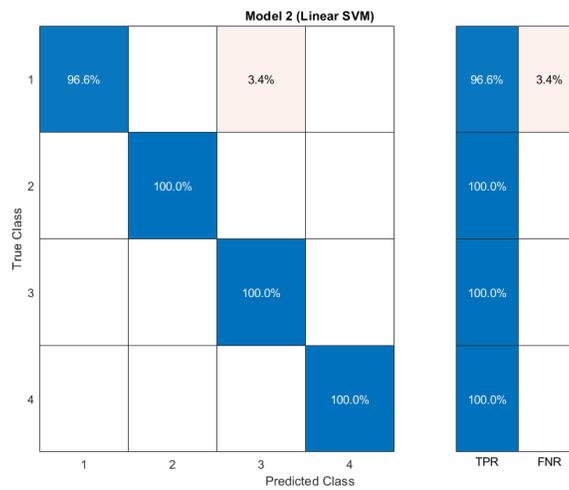
Tabla 30

Resultados del Modelo SVM

Parámetro	Valor
Precisión (Validación)	99.2 %
Costo Total (Validación)	34
Velocidad de predicción (obs/sec)	77000
Tiempo de formación (sec)	2.3565
Tamaño del modelo (Compact)	35 kB

Figura 44

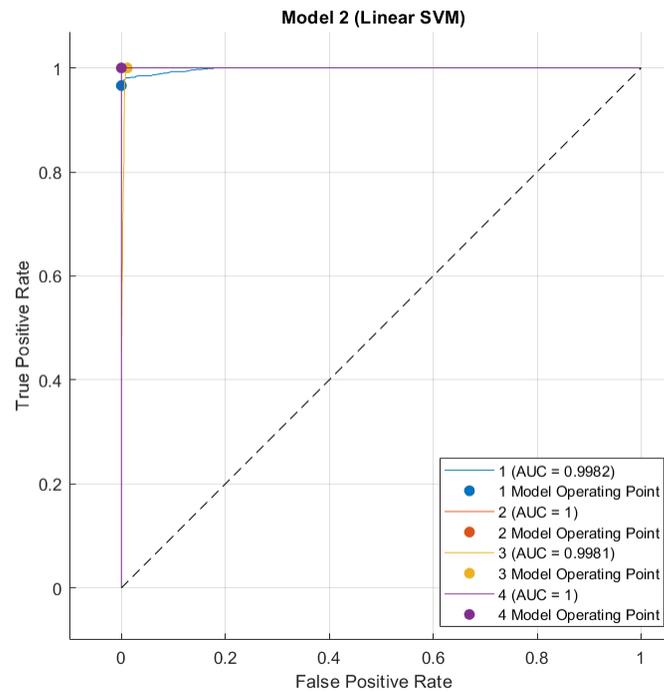
Matriz de confusión modelo SVML para vehículo 2



Nota: Se observa la matriz de confusión modelo SVML para vehículo 2 (Guartazaca, 2024).

Figura 45

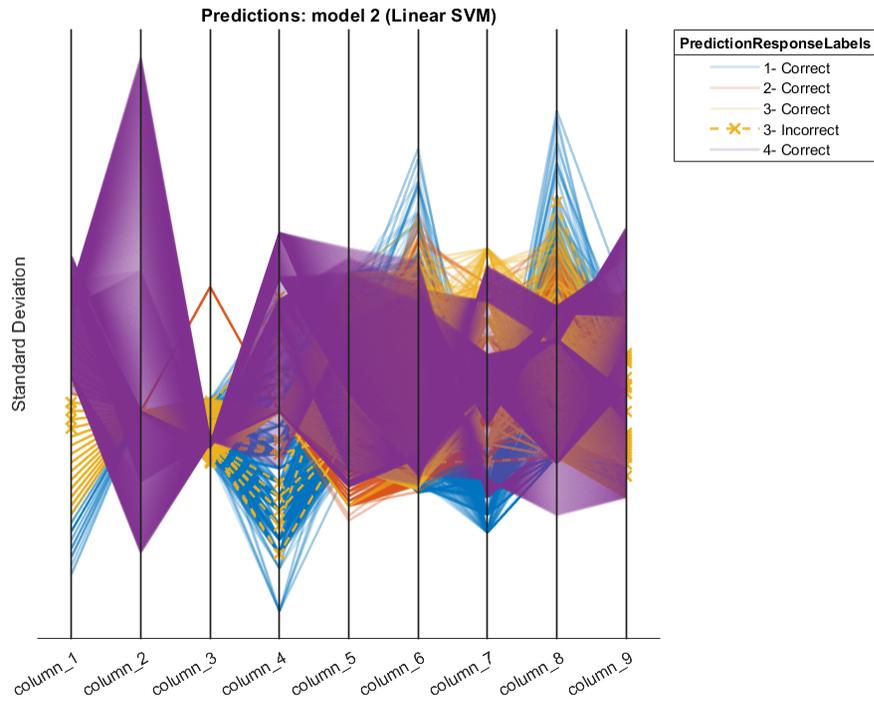
Curva ROC del desempeño del algoritmo SVML.



Nota: Se observa la curva ROC del desempeño del algoritmo SVML. (Guartazaca, 2024).

Figura 46

Coordenadas paralelas del algoritmo de predicción de fallas SVML.



Nota: Se observa las coordenadas paralelas obtenidas del algoritmo de predicción de fallas utilizando el modelo SVML en el vehículo 2. (Guartazaca, 2024).

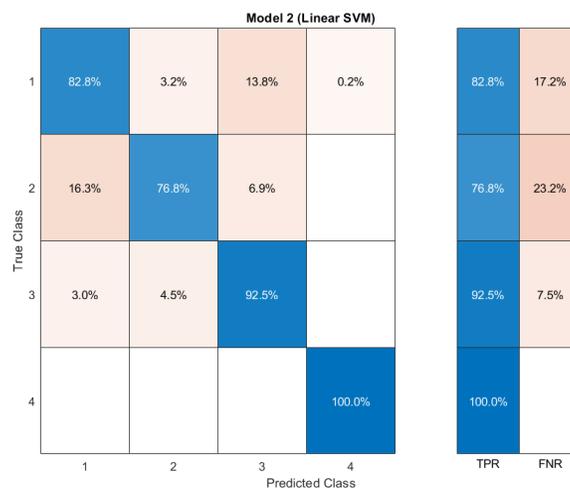
Tabla 31

Resultados del Modelo SVM

Parámetro	Valor
Precisión (Validación)	88.0 %
Costo total (Validación)	479
Velocidad de predicción (obs/sec)	79000
Tiempo de formación (sec)	2.3449
Tamaño del modelo (Compact)	35 kB

Figura 47

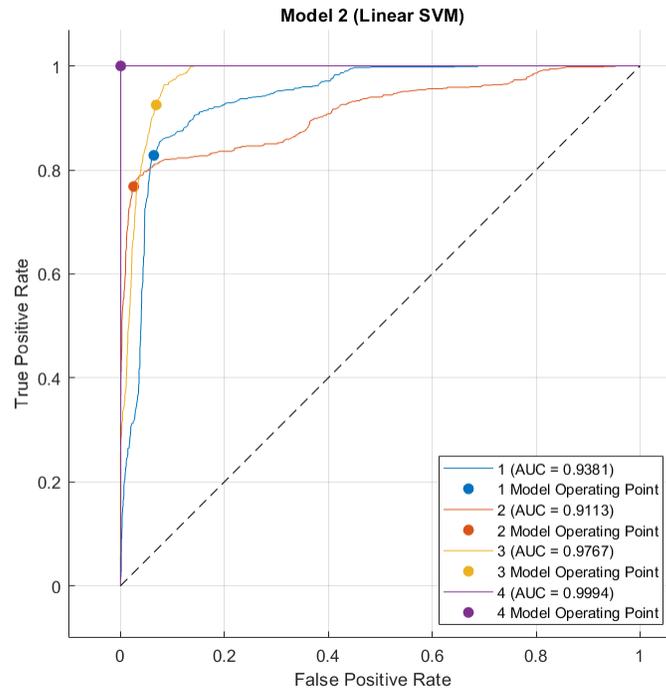
Matriz de confusión modelo SVML para vehículo 3



Nota: Se observa la matriz de confusión modelo SVML para vehículo 3 (Guartazaca, 2024).

Figura 48

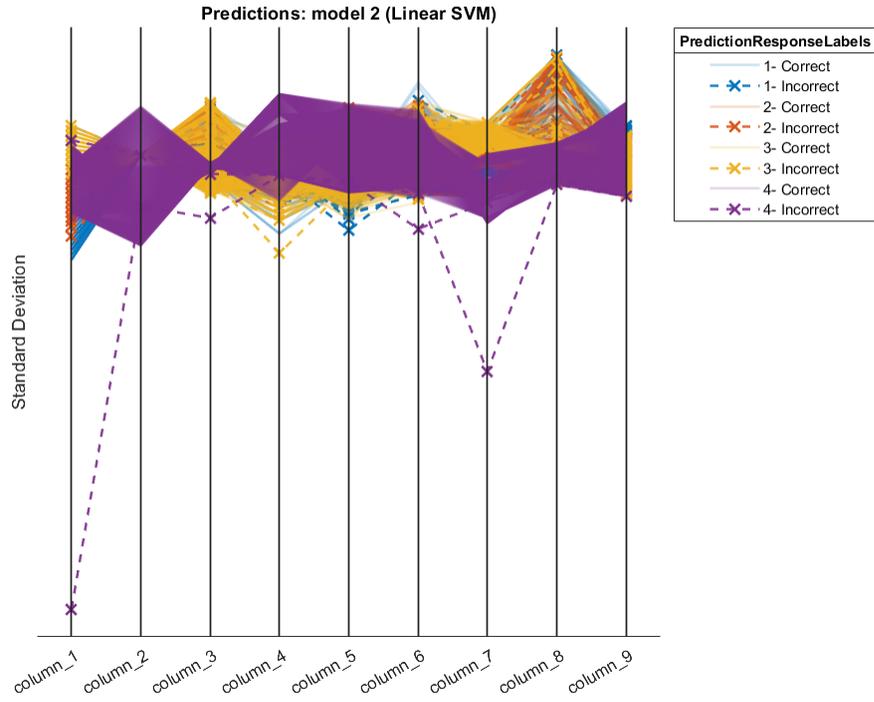
Curva ROC del desempeño del algoritmo SVML.



Nota: Se observa la curva ROC del desempeño del algoritmo SVML. (Guartazaca, 2024).

Figura 49

Coordenadas paralelas del algoritmo de predicción de fallas SVML.



Nota: Se observa las coordenadas paralelas obtenidas del algoritmo de predicción de fallas utilizando el modelo SVML en el vehículo 3. (Guartazaca, 2024).