



UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE CUENCA
CARRERA DE INGENIERÍA AUTOMOTRIZ

**IMPLEMENTACIÓN DE LA METODOLOGÍA AMFEC PARA LA DETECCIÓN
DE FALLOS INCIPIENTES DEL SISTEMA DE INYECCIÓN DEL MOTOR G4GC**

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

AUTORES: JONNATHAN ISRAEL SUQUI PADILLA

CARLOS SEBASTIÁN VÁSQUEZ SEGARRA

TUTOR: ING. NÉSTOR DIEGO RIVERA CAMPOVERDE, MSc.

Cuenca - Ecuador

2024


CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Nosotros, Jonnathan Israel Suqui Padilla con documento de identificación N° 0150232239 y Carlos Sebastián Vásquez Segarra con documento de identificación N° 0106488257; manifestamos que:

Somos los autores y responsables del presente trabajo; y, autorizamos 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, 04 de julio del 2024

Atentamente,



Jonnathan Israel Suqui Padilla

0150232239



Carlos Sebastián Vásquez Segarra

0106488257


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

Nosotros, Jonnathan Israel Suqui Padilla con documento de identificación N° 0150232239 y Carlos Sebastián Vásquez Segarra con documento de identificación N° 0106488257, expresamos nuestra voluntad y por medio del presente documento cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del Proyecto técnico: “Implementación de la metodología AMFEC para la detección de fallos incipientes del sistema de inyección del motor G4GC”, el cual ha sido desarrollado para optar por el título de: Ingeniero Automotriz, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

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


Cuenca, 04 de julio del 2024

Atentamente,



Jonnathan Israel Suqui Padilla

0150232239



Carlos Sebastián Vásquez Segarra

0106488257

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Néstor Diego Rivera Campoverde con documento de identificación N° 0103898995, docente de la Universidad Politécnica Salesiana, declaró que bajo mi tutoría fue desarrollado el trabajo de titulación: IMPLEMENTACIÓN DE LA METODOLOGÍA AMFEC PARA LA DETECCIÓN DE FALLOS INCIPIENTES DEL SISTEMA DE INYECCIÓN DEL MOTOR G4GC, realizado por Jonnathan Israel Suqui Padilla con documento de identificación N° 0150232239 y por Carlos Sebastián Vásquez Segarra con documento de identificación N° 0106488257, 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, 04 de julio del 2024

Atentamente,



Ing. Néstor Diego Rivera Campoverde, MSc.

0103898995

DEDICATORIA

Con total agradecimiento y aprecio dedico este proyecto a mi madre Diana Padilla quien ha sido fundamental a lo largo de mi vida. El esfuerzo y dedicación continuos han forjado la fortaleza necesaria para alcanzar mis metas propuestas.

A mi amado tío José Padilla en el cielo expreso mi total gratitud. Te extraño todos los días, especialmente este momento de culminación. Tu amor y apoyo han sido la mayor motivación para concluir mis metas.

Mi gratitud hacia ti trasciende las palabras. Te extraño y te honro.

A Germán Sucuzhañay quién asumió el rol de padre sin compartir vínculo sanguíneo volviéndose un ser querido en el círculo familiar. Le dedico especialmente un reconocimiento por su preocupación permanente por el bienestar de la familia.

Finalmente, a todos mis familiares y amigos por haber formado parte del proceso de aprendizaje desde diferentes circunstancias y perspectivas.

Jonnathan Israel Suqui Padilla

DEDICATORIA

Con extenso amor y aprecio, dedico a mis padres, Gladys Segarra, José Abel Segarra y con mucho más aprecio dedico este proyecto a mi abuela Blanca Figueroa que desde el cielo fue la que me dio fuerzas y la motivación para dar por finalizado mi etapa universitaria.

fueron primordiales en el transcurso de mi vida y formación como persona. Los esfuerzos continuos de mi familia son una fortaleza y fue mi pilar para mantenerme con mis metas propuestas.

A José Abel, quien fue el que asumió el rol de padre, convirtiéndose en un ser amado, dedicando este proyecto con mayor aprecio. En donde su constante interés por que acabe mi carrera como Ingeniero Automotriz fue un pilar indispensable y alentando a seguir con mis metas.

En última instancia quiero dedicar este proyecto a toda mi familia y amigos que formaron parte de mi proceso educativo

Carlos Sebastián Vásquez Segarra

AGRADECIMIENTO

En primer lugar, agradecer a Dios por permitirme completar esta etapa universitaria y alcanzar este objetivo.

A la Universidad Politécnica Salesiana por abrirme las puertas de la institución para realizar mis estudios superiores.

A mi mamá Diana, por su apoyo a lo largo de este camino y por creer en mis capacidades para finalizar esta carrera, siempre estando pendiente de mí.

A mi abuelita Aida, cuyos principios, junto con los de mis padres, me incentivaron a completar con éxito mi carrera universitaria y por sus palabras y consejos diarios que me motivaron a no rendirme.

A mis hermanos Sofía, y Stalin, por acompañarme en este largo recorrido universitario.

De manera especial, al Sensei, el Ing. Néstor Rivera, por su tiempo, su amistad, su confianza y los conocimientos compartidos

que me permitieron completar este proyecto técnico con éxito.

Y a los docentes de la Universidad, por los conocimientos proporcionados para mi formación profesional.

Jonnathan Israel Suqui Padilla

AGRADECIMIENTO

Me gustaría comenzar agradeciendo a Dios en primer lugar por guiarme y darme la fuerza necesaria a lo largo de mi etapa universitaria.

Me gustaría dedicar este proyecto a mi madre Gladys Segarra que siempre me apoyo desde un inicio y me brindo una educación de calidad. Que fue pieza fundamental para mi formación.

También a mi padre José Abel Segarra por siempre guiarme por el buen camino y agradecerle por haber influido de manera positiva en mi formación como persona.

A mi familia que me ayudaron en todo este camino de mi formación educativa y siempre

estuvieron pendientes de que me encuentre bien.

También quiero expresar mi más sincero agradecimiento a mi tutor de tesis el Ing. Néstor Rivera por su amistad, su gran apoyo y voluntad durante el transcurso de mi tesis. Su gran voluntad y ayuda fueron de suma importancia para poder desarrollar este proyecto con éxito.

Finalmente agradezco a la Universidad Politécnica Salesiana por abrirme sus puertas y por formar parte de mi formación profesional.

Carlos Sebastián Vásquez Segarra

RESUMEN

Este proyecto técnico presenta un método para la predicción de fallos en el sistema de inyección de vehículos utilizando técnicas de aprendizaje automático. El objetivo de este proyecto es mejorar la detección temprana de fallos, contribuyendo así a la optimización del mantenimiento automotriz, a la reducción de costos y al incremento de la confiabilidad vehicular.

El desarrollo del proyecto se divide en tres etapas principales para alcanzar los resultados deseados.

La primera etapa se enfoca en realizar una revisión bibliográfica a profundidad para adquirir conocimiento sobre los fallos en el sistema de inyección y las técnicas de predicción disponibles. Este análisis proporcionará una base teórica sólida asegurando la confiabilidad de los resultados.

En la segunda etapa se desarrolló la adquisición de datos necesarios para el estudio. Se utilizó diversas señales de sensores y dispositivos de diagnóstico móviles como el dispositivo Freemantics y un analizador de gases portátil conectados al flujo de datos del vehículo para recopilar valores operativos en tiempo real. Además, se realizó pruebas en condiciones controladas y reales para asegurar la precisión de los datos recopilados.

La tercera etapa se centra en el análisis de los datos adquiridos mediante técnicas estadísticas y de aprendizaje automático. El objetivo es identificar patrones y señales tempranas de posibles fallos en el sistema de inyección. Los resultados obtenidos proporcionan una base sólida para futuras tomas de decisiones y desarrollos tecnológicos en el sector automotriz.

Palabras Claves: *Aprendizaje automático, predicción, patrones de señales.*

ABSTRACT

This technical project presents a method for predicting failures in the vehicle injection system using machine learning techniques. The objective of this project is to improve the early detection of failures, thereby contributing to the optimization of automotive maintenance, cost reduction, and increased vehicle reliability.

The development of the project is divided into three main stages to achieve the desired results.

The first stage focuses on conducting an in-depth literature review to gain knowledge about failures in the injection system and the available prediction techniques. This analysis will provide a solid theoretical foundation ensuring the reliability of the results.

In the second stage, the necessary data for the study was acquired. Various sensor signals and mobile diagnostic devices such as the Freematics device and a portable gas analyzer connected to the vehicle's data flow were used to collect real-time operating values. Additionally, tests were conducted under controlled and real conditions to ensure the accuracy of the collected data.

The third stage centers on analyzing the acquired data using statistical and machine learning techniques. The goal is to identify patterns and early signs of potential failures in the injection system. The results obtained provide a solid foundation for future decision-making and technological developments in the automotive sector.

Keywords: Machine learning, prediction, signal patterns.

ÍNDICE GENERAL

INTRODUCCIÓN	20
PROBLEMA	21
Antecedentes	22
Importancia y alcances.....	24
Delimitación	24
Objetivos.....	25
Objetivo general.....	25
Objetivos específicos	25
CAPÍTULO 1: MARCO TEÓRICO REFERENCIAL Y ESTADO DEL ARTE ..	26
Marco teórico referencial	26
Metodología AMFEC	26
Árbol de fallas o anomalías	31
Definición de obtención de Datos	34
Análisis Cualitativo	34
Análisis Cuantitativo.....	34
Aprendizaje automático.....	34
Señales PID's	35
Prueba en ciclos reales de conducción (Real Driving Emissions, RDE).....	35
Registrador de datos	36
Analizador de gases (Portable measuring emissions System, PEMS)	36

	13
Emisiones de gases contaminantes.....	37
Sensores.....	38
Ajuste de combustible:.....	40
Long Term Fuel Trim (LTFT).....	41
Short Term Fuel Trim (STFT).....	41
Definición de fiabilidad.....	41
Modelos de fiabilidad.....	41
Estimación de Contaminantes.....	42
Herramientas de clasificación	44
Estado del arte.....	45
CAPÍTULO II: METODOLOGÍA UTILIZADA PARA LA OBTENCIÓN DE DATOS	52
Variables para la adquisición de datos:.....	53
Variables de Ruido.....	53
Variables de Bloqueo	54
Variables de Entrada	54
Variables de Salida.....	55
Rutas para obtención de datos.....	56
Proceso Experimental.....	58
Vehículo asignado a testeo	58
Adquisición de Datos	60
Vectores De Análisis	62

Filtrado de variables	62
Metodología de ajuste de mínimos cuadrados. - Savitzky-Golay	63
Extracción y visualización de datos.....	63
Correlación de variables	86
CAPÍTULO III: PROCESAMIENTO DE SEÑALES, ENTRENAMIENTO DE APRENDIZAJE AUTOMATICO Y ANÁLISIS DE PREDICCIÓN DE FALLOS	89
Análisis comparativo	89
Aplicación de la metodología AMFEC usando MATLAB.....	92
Entrenamiento de la inteligencia artificial	94
Árboles de decisión	94
SVM.....	95
KNN.....	95
Redes neuronales.....	96
Determinación de Emisiones.....	99
Conclusiones.....	101
Recomendaciones.....	102
Referencias	103
Anexos.....	106

ÍNDICE DE FIGURAS

Figura 1 Delimitación geográfica.....	25
Figura 2 METODOLOGÍA AMFEC.....	27
Figura 3 AMFEC.....	28
Figura 4 Diagrama del árbol de fallos.....	32
Figura 5 Simbología de las compuertas lógicas.	33
Figura 6 Freematics.	36
Figura 7 Software Kane Live.	37
Figura 8 Sensor de oxígeno.....	40
Figura 9 Modelos de fiabilidad.....	42
Figura 10 Clasificación de variables.	53
Figura 11 Ruta de adquisición de datos. Normativa RDE.....	57
Figura 12 Ruta de adquisición de datos. Conducción Aleatoria.....	58
Figura 13 Kia Sportage.	59
Figura 14 Dispositivos vinculados en la adquisición de datos.....	60
Figura 15 Protocolo para la adquisición de datos.	61
Figura 16 Extracción de datos adquiridos de Freematics.....	63
Figura 17 Visualización PID's.	64
Figura 18. Ajuste de combustible de largo plazo.....	65
Figura 19 Ajuste de combustible de largo plazo.	66
Figura 20 Ajuste de combustible de corto plazo.	66
Figura 21 Ajuste de combustible de corto plazo.	67
Figura 22 Comportamiento del sensor TPS.....	68
Figura 23 Comportamiento del sensor TPS.....	68
Figura 24 Comportamiento del sensor de oxígeno (O ₂).....	69
Figura 25 Comportamiento del sensor de oxígeno (O ₂).....	70

Figura 26 Ajuste de combustible de largo plazo.	70
Figura 27 Ajuste de combustible de largo plazo.	71
Figura 28 Ajuste de combustible de corto plazo.	72
Figura 29 Ajuste de combustible de corto plazo.	72
Figura 30 Funcionamiento del sensor TPS.	73
Figura 31 Funcionamiento del sensor TPS.	73
Figura 32 Funcionamiento del sensor de oxígeno (O ₂).	74
Figura 33 Funcionamiento del sensor de oxígeno (O ₂).	75
Figura 34 Ajuste de combustible a largo plazo.	76
Figura 35 Ajuste de combustible a largo plazo.	76
Figura 36 Ajuste de combustible a corto plazo.	77
Figura 37 Ajuste de combustible a corto plazo.	78
Figura 38 Funcionamiento del sensor TPS.	78
Figura 39 Funcionamiento del sensor TPS.	79
Figura 40 Funcionamiento del sensor de oxígeno (O ₂).	80
Figura 41 Funcionamiento del sensor de oxígeno (O ₂).	80
Figura 42 Ajuste de combustible a largo plazo.	81
Figura 43 Ajuste de combustible a largo plazo.	82
Figura 44 Ajuste de combustible a corto plazo.	82
Figura 45 Ajuste de combustible a corto plazo.	83
Figura 46 Comportamiento sensor TPS.	84
Figura 47 Comportamiento sensor TPS.	84
Figura 48 Comportamiento sensor Oxígeno (O ₂).	85
Figura 49 Comportamiento sensor Oxígeno (O ₂).	86
Figura 50 Matriz de correlación de variables.	86
Figura 51 Gráfica comparativa sensor O ₂	93

Figura 52 Gráfica comparativa Ajuste de combustible de corto plazo.....	991
Figura 53 Gráfica comparativa Ajuste de combustible de largo plazo.....	992
Figura 54 Prioridad de fallos.....	993
Figura 55 Predicción mediante Árboles de decisión.	994
Figura 56 Predicción mediante modelo SVM.	995
Figura 57 Predicción mediante modelo KNN.	996
Figura 58 Predicción mediante modelo de redes neuronales.	97
Figura 59 Estimación de factores de emisión.....	104
Figura 60 Proceso de adquisición de datos.....	110
Figura 61 Conexión del analizador de gases.	110
Figura 62 Sonda del analizador de gases.....	107

ÍNDICE DE TABLAS

Tabla 1 Severidad.	29
Tabla 2 Ocurrencia.	30
Tabla 3 Detección.	31
Tabla 4 Variables de Ruido.	54
Tabla 5 Variables de Bloqueo.....	54
Tabla 6 Variables de Entrada.....	55
Tabla 7 Variables de Salida.	56
Tabla 8 Especificaciones mecánicas y eléctricas del Kia Sportage.....	59
Tabla 9 Interpretación de la matriz de correlación.	88
Tabla 10 Variables más influyentes.....	88
Tabla 11 Tabla Resultados Metodología AMFEC.	93
Tabla 12 Tabla de Resultados del aprendizaje automático.....	98

ÍNDICE DE FÓRMULAS

Fórmula 1 Índice de prioridad de riesgo.	31
Fórmula 2 Fórmula de estimación de contaminantes.....	42
Fórmula 3 Fórmula de estimación de contaminantes.....	42
Fórmula 4 Fórmula de estimación de contaminantes.....	43
Fórmula 5 Fórmula de estimación de contaminantes.....	43
Fórmula 6 Fórmula de estimación de contaminantes.....	43
Fórmula 7 Fórmula de estimación de contaminantes.....	43

INTRODUCCIÓN

La fiabilidad y eficiencia de los sistemas de inyección de combustible en los automóviles son determinantes en el rendimiento del vehículo y en la reducción de emisiones contaminantes. En el sector automotriz contemporáneo con constante evolución, la capacidad de predecir fallos en los sistemas que conforman el vehículo se ha convertido en una prioridad para los fabricantes y propietarios de los vehículos. Los sistemas de inyección gestionan la cantidad y el momento exacto de la dosificación del combustible verificando los valores de los sensores que integran el vehículo.

El presente proyecto se centra en la implementación de técnicas avanzadas de predicción de fallos en sistemas de inyección de combustible mediante el uso de algoritmos de aprendizaje automático. A medida que los sistemas de inyección se vuelven más complejos, las metodologías tradicionales de diagnóstico y mantenimiento se muestran insuficientes para abordar de manera eficaz las fallas incipientes. Como consecuencia surge la adopción de técnicas de aprendizaje automático permitiendo un enfoque preciso y eficiente, capaz de identificar patrones de fallos antes de que estos se conviertan en problemas severos.

Este estudio explora el uso de modelos predictivos, como las redes neuronales y los algoritmos de Machine Learning para analizar datos obtenidos de sensores. La recopilación de datos incluye parámetros clave del sistema de inyección, tales como los ajustes de combustible, el flujo de inyección y las variaciones en las señales PID's. Mediante el análisis de estos datos se pretende desarrollar modelos capaces de predecir con alta precisión la ocurrencia de fallos.

Los beneficios de este enfoque son múltiples puesto que no solo se optimiza la confiabilidad y la vida útil del sistema de inyección, dado que también se optimiza el

consumo de combustible y se reducen las emisiones contaminantes. Además, la capacidad de predecir fallos y realizar mantenimientos preventivos puede traducirse en ahorros significativos en costos de reparación y tiempo de inactividad del vehículo.

La aplicación de técnicas de aprendizaje automático para la predicción de fallos en sistemas de inyección de combustible representa un avance significativo en la gestión del mantenimiento automotriz.

PROBLEMA

Actualmente la falta de familiarización con el manejo adecuado de las señales PID's (Parámetros Identificativos de Diagnóstico) y una base de datos sólida de los mismos dificulta el diagnóstico de fallos en etapa incipiente para los diferentes sistemas de los vehículos. Esta brecha limita la oportunidad de implementar diagnósticos tempranos efectivos en los sistemas de los vehículos.

Un agravante para la situación es la falta de una base de datos sólida de las señales PID's, restringiendo el desarrollo de métodos de detección temprana de anomalías.

Además, los técnicos a menudo dependen de herramientas tradicionales como escáneres y osciloscopios para identificar y solucionar problemas. Aunque estas herramientas son valiosas, su capacidad para prever desgastes futuros o detectar todas las posibles averías es limitada. La falta de capacitación adecuada en el uso de técnicas de aprendizaje automático impide que los técnicos aprovechen al máximo estas herramientas, resultando en diagnósticos incompletos y en elevados costos de mantenimiento.

(Hurtado et al., 2016), destacan en su publicación que "algunas anomalías en motores no son detectadas por herramientas de diagnóstico debido a la falta de

conocimientos especializados, y las fallas complejas aumentan el costo y tiempo de reparación, además de provocar un incremento en las emisiones contaminantes y el consumo de combustible."

Este problema no solo afecta la eficiencia operativa de los vehículos, sino que también tiene un impacto ambiental negativo. La incapacidad para anticipar y corregir fallos en sus etapas iniciales conduce a reparaciones más costosas y a un mayor tiempo de inactividad de los vehículos. Además, los fallos no detectados a tiempo provocan aumento en las emisiones de gases contaminantes y en el consumo de combustible, contrarrestando los esfuerzos por mejorar la sostenibilidad en el sector automotriz.

La integración de técnicas de aprendizaje automático en el diagnóstico de fallos automotrices ofrece una solución a estos desafíos. Sin embargo, para que esta integración sea efectiva es crucial que se desarrollen bases de datos de las señales PID's exhaustivas combinado con el correcto uso de algoritmos de aprendizaje automático. Solo a través de una combinación de conocimientos técnicos y herramientas avanzadas se podrá mejorar la precisión de los diagnósticos, reducir los costos de mantenimiento y minimizar el impacto ambiental de los vehículos.

Antecedentes

El desarrollo del presente proyecto tiene como propósito abordar la predicción de fallos en el sistema de inyección de automóviles mediante la implementación de técnicas de aprendizaje automático. Este enfoque innovador surge en respuesta a la creciente variante de los sistemas automotrices modernos y la necesidad de mejorar la precisión y eficiencia de los diagnósticos tempranos. La falta de implementación de los técnicos con el aprendizaje automático y la ausencia de una base de datos exhaustiva de señales PID's son obstáculos críticos que este proyecto pretende superar.

El análisis de antecedentes revela que, aunque las herramientas tradicionales como escáneres y osciloscopios son útiles su capacidad para prever desgastes futuros o detectar todas las posibles averías es limitada. Este proyecto se alinea con la necesidad de aplicar técnicas de aprendizaje automático y desarrollar bases de datos de señales PID's, lo que permitirá mejorar significativamente la precisión de los diagnósticos y reducir los costos de mantenimiento.

El plan de estudio se enfoca en la recopilación y análisis de datos obtenidos de sensores del sistema de inyección, tales como el ajuste de combustible, parámetros de inyección y las variaciones en el funcionamiento del motor. A través de arquitecturas de aprendizaje automático entrenadas, se busca desarrollar modelos predictivos capaces de identificar patrones de fallos en sus etapas iniciales. Esto permitirá anticipar problemas antes de que se conviertan en averías graves, optimizando así el rendimiento del vehículo y reduciendo su impacto ambiental.

En relación con los objetivos de desarrollo sostenible, este proyecto está vinculado directamente con el objetivo 12 del plan de creación de oportunidades del Ecuador (Secretaría Nacional de Planificación, 2024), que tiene como propósito principal incrementar el ahorro de combustibles fósiles a través de mejoras en la eficiencia. La capacidad de predecir y prevenir fallos en los sistemas de inyección contribuirá a la reducción de emisiones contaminantes y al consumo eficiente de combustible, alineándose con las metas ambientales y de sostenibilidad del país.

Diversos estudios en el ámbito automotriz han destacado la importancia de la eficiencia y la reducción de emisiones contaminantes. La incorporación de tecnologías innovadoras, como el aprendizaje automático en el diagnóstico y mantenimiento de vehículos representa un avance significativo hacia una industria más sostenible. La

literatura científica muestra un creciente interés en la convergencia entre la tecnología de aprendizaje automático y la industria automotriz, lo que ha llevado a desarrollos prometedores en la predicción y prevención de fallos.

Importancia y alcances

En la época contemporánea, se evidencia la incorporación de nuevas tecnologías en diversas áreas del sector automotriz. En el ámbito del mantenimiento, se han desarrollado avances significativos con la necesidad de optimización.

El objetivo de la predicción de fallos en etapas incipientes es aportar conocimientos al sector de mantenimiento automotriz, a los propietarios de vehículos y a la comunidad interesada en general.

Se busca implementar nuevas metodologías para la toma de decisiones desde la perspectiva de la inteligencia artificial combinada con la tecnología proporcionada por los fabricantes de vehículos. Esto contribuirá a una investigación e interpretación accesible para la sociedad fomentando así el estudio continuo del área.

Delimitación

El proyecto se realizó en la ciudad de Cuenca, misma que se encuentra situada en la provincia de Azuay. La localidad se ubica a una altitud de 2.550 metros sobre el nivel del mar y cuenta con una superficie de 70.59 kilómetros cuadrados.

De acuerdo con INEC, se estima que tiene una población de aproximadamente 596.101 habitantes en el cantón Cuenca (INEC, 2024).

Figura 1 Delimitación geográfica.



Nota: Adaptado de Google Maps. Fuente: (Google Maps, 2024)

Objetivos

Objetivo general

Implementar la metodología AMFEC para la detección de fallos incipientes del sistema de inyección del motor G4GC.

Objetivos específicos

- Revisar el estado del arte para determinar una forma eficiente de adquirir y procesar señales.
- Diseñar una base de datos mediante redes de aprendizaje automático.
- Evaluar la precisión de la predicción mediante la generación de un banco de información orientado a futuras investigaciones.

CAPÍTULO 1: MARCO TEÓRICO REFERENCIAL Y ESTADO DEL ARTE

Marco teórico referencial

Metodología AMFEC

La metodología AMFEC, también conocida como análisis de modos de falla, efectos y criticidad, se constituye como un procedimiento que ayuda a comprender cómo trabaja un sistema y cómo puede fallar el mismo. (J. Aguilar et al., 2010) explicó: “El AMFEC consiste en las siguientes etapas: Definición de la intención de diseño, análisis funcional, identificación de modos de falla, efectos de la falla, criticidad o jerarquización del riesgo y recomendaciones”. Entonces este procedimiento es decisivo para la planificación del mantenimiento, debido a que ofrece distinguir con exactitud los modos de falla, efectos de este y su criticidad en términos de peligro.


El principio de la metodología es brindar solución a incógnitas como: ¿Qué puede fallar? ¿Qué consecuencias tiene? ¿Cómo puede detectarse la falla? Analizando las soluciones a estas interrogantes se puede definir y entender los riesgos para diseñar acciones de mejora para la prevención y/o control. (Pacho et al., 2020)

AMFEC se desarrolló fundamentada en las normas SAE JA-1011/ 1012, gracias al cumplimiento de dichos parámetros se da lugar al modelo RCM. Es decir, la metodología está calificada para estudiar fallas, efectos de fallas y la probabilidad de que ocurran (SAE, 2024).

Como se muestra en la *figura 2*, el procedimiento para implementar la metodología dispone de diversas etapas, logrando la clasificación cuantitativa de la falla.

Con el análisis AMFEC se consigue garantizar que los modos de falla puedan ser entendidos. Además, proveerá criterios para priorizar acciones correctivas o preventivas.

Figura 2 METODOLOGÍA AMFEC.



Nota: Proceso de gestión de mantenimiento mediante la aplicación del análisis de modos de falla, efectos y criticidad. Fuente: (J. Aguilar et al., 2010).

Etapas de la metodología:

- Establecer el alcance del análisis

La literatura propone que para cumplir con este parámetro se debe tener en cuenta las fronteras que muestra el sistema estudiado. Además, la profundidad de análisis requerida.

- Recopilar la información necesaria

La etapa de recopilar información es indagar todo aquello que brinde información sobre el diseño como especificaciones, manuales de funcionamiento, datos y/o resultados experimentales.

- Preparar la lista de componentes

Esta etapa demanda el conocimiento total de cada uno de los componentes del sistema, se debe mostrar la función de cada uno y las condiciones en las que opera cada elemento.

Usos del AMFEC

La metodología AMFEC básicamente analiza los modos de fallo y su criticidad, pero además de eso se puede usar para:


- Elaboración de árboles de decisión.
- Elaboración de planes de mantención preventiva.
- Diseño de indicadores de falla.
- Beneficios AMFEC:

Logra identificar las posibles fallas en distintos componentes, de tal forma que, se conocen anomalías que se pueden evitar o mejorar.

Técnica de la metodología AMFEC

La *figura 3* ilustra el procedimiento que se debe de implementar con la técnica AMFEC en un sistema (A. Aguilar et al., 2017).

Figura 3 AMFEC.



Nota: Proceso para la aplicación de la metodología AMFEC.

Modo de falla

El concepto modo de falla hace referencia a las diversas formas en las que un componente puede mostrar anomalía, presentando uno o varios modos de falla.

El listado de los modos de falla abarca cualquier proceso que pueda provocar mal funcionamiento como lo son el deterioro, los defectos de diseño y los errores humanos (SAE, 2024).

Efecto de falla

El efecto de falla como tal, informa lo que pasaría si no se ejecuta una tarea con el objetivo de anticipar y prevenir la falla. Su función es la de describir las consecuencias indeseadas de la falla que se detectan y siempre deben expresarse en términos de rendimiento o eficiencia del producto, proceso o sistema.

Si un modo de falla tiene varios efectos, se comienza primero con la evaluación y posteriormente se escoge los más graves (Belloví et al., 2004).

Severidad

Indica el nivel de gravedad de una falla que ha sido previamente identificada, pero esto va a depender según la persona que evalúe el daño. En la *tabla 1* se presenta la clasificación del nivel de daño de los modos de falla.

Tabla 1 Severidad.

Severidad	Criterio	Valor
Repercusiones mínimas “No detectables”	Es poco probable que el fallo cause un defecto en el sistema.	1
Repercusiones leves “Apenas discernibles”	El fallo causó un ligero contratiempo en el sistema. Es fácilmente corregible.	2 - 3
Moderada defectos de importancia relativa	El fallo está generando problemas en el sistema.	4 - 6
Alta	El fallo podría ser crucial y dejar el sistema inoperativo.	7 - 8

Muy alta	Fallo extremadamente crítico que compromete la seguridad y el funcionamiento del sistema.	9 - 10
----------	---	--------

Nota: Tabla de clasificación de severidad. Fuente: (Rodríguez, 2013)

Ocurrencia

La función de la ocurrencia es de indicar con qué frecuencia aparece una falla en el sistema, entonces se entiende como una probabilidad en donde puede ocurrir o no una falla. Por lo tanto, la probabilidad de que una causa de falla se manifieste y posteriormente de paso al modo de falla.

En la *tabla 2* se ilustra la clasificación de la ocurrencia.

Tabla 2 Ocurrencia.

Ocurrencia	Criterio	Valor
Muy baja o improbable	La anomalía tiene una baja posibilidad de ocurrir	1
Baja	La anomalía presenta poca probabilidad de ocurrir.	2 - 3
Moderada	El fallo se muestra pocas ocasiones.	4 - 5
Alta	La anomalía se muestra constantemente.	6 - 8
Muy alta	El fallo tiene probabilidad casi segura de aparecer.	9 - 10

Nota: Tabla de clasificación de ocurrencia. Fuente: (Rodríguez, 2013)

Detección

La detección se entiende como la identificación de una falla que, al no ser identificada aumenta las probabilidades de que cause daños mayores a futuro.

En la *tabla 3* se ilustra la clasificación de la detección.

Tabla 3 Detección.

Detección	Criterio	Valor
Muy alta	Es probable que el defecto sea detectado mediante las medidas de prueba y control previstas	1
Alta	El defecto es claramente detectable.	2 - 3
Mediana	El defecto es perceptible.	4 - 6
Pequeña	Es complicado detectar el defecto utilizando las medidas de prueba y control previstas	7 - 8
Improbable	La imperfección es indetectable y es muy probable que el fallo cause problemas en el sistema	9 - 10

Nota: Tabla de clasificación de detección. Fuente: (Rodríguez, 2013)

Índice de prioridad de riesgo

El índice de prioridad de riesgo (IPR) es el resultado de la multiplicación de tres variables: los índices de severidad, ocurrencia y detección, según se indica en la *Fórmula 1*. Este valor determina la criticidad de una falla, orientando las intervenciones de mantenimiento, tanto correctivas como preventivas.

$$IPR = S \times O \times D$$

Fórmula 1 Índice de prioridad de riesgo.

Fuente: (Rodríguez, 2013)

Árbol de fallas o anomalías


Correspondiente a los diferentes análisis de confiabilidad el árbol de fallas es de vital importancia a razón de que establece diferentes combinaciones de anomalías de un componente que concluyen en un suceso indeseado. Por otro lado, abre la posibilidad de

calcular la probabilidad de que el fallo ocurra basado en el análisis de las ocurrencias de las fallas de los componentes.

Para la construcción del árbol de fallos se nombra el suceso principal. Los eventos de falla que van a contribuir a la ocurrencia del evento principal están ligados a través de funciones lógicas.

- El dispositivo no recibe señal necesaria para trabajar.
- El dispositivo tuvo fallo interno.
- Un error exterior. (Fallo Humano)
- Un evento externo que impide operar al dispositivo.

Figura 4 Diagrama del árbol de fallos.



Nota: Construcción del árbol de fallos. Fuente: (Fernández et al., 2017)

Construcción de un árbol de fallas:

Se debe identificar la avería, indagar su procedencia y sus consecuencias al sistema. Además, existen 2 tipos de anomalía que pueden surgir: Falla en el sistema y falla en un componente.

Para realizar la construcción del árbol es esencial identificar las funciones de cada una de los tipos de compuertas lógicas y su simbología.

En la figura 5, se muestra la simbología de las compuertas lógicas útiles para fabricar un árbol de fallas.

Figura 5 Simbología de las compuertas lógicas.

Símbolo	Nombre	Descripción
	Evento Principal	Evento de falla, generalmente es el resultado de otros eventos.
	Evento Básico	Evento base, se encuentra en la parte inferior del árbol. No hay puertas o eventos debajo de este evento.
	Evento no desarrollado	Evento de falla cuyas causas no han sido desarrolladas.
	Símbolo de Transferencia	Es una rama del árbol transferido a otro lugar del árbol.
	Evento Condición	Llega a ocurrir únicamente cuando se presentan ciertas condiciones.
	Puerta "And"	Evento de salida, el evento ocurre si y solo si todos los eventos de entrada ocurren.
	Puerta "Or"	Evento de salida, el evento ocurre si uno o más eventos de entrada ocurren.
	"Or" Exclusivo	El evento ocurre si ocurre exactamente una de las entradas.
	"And" Prioritario	El evento ocurre si todas las entradas se producen en una determinada secuencia.
	Puerta Inhibición	El evento ocurre si la única entrada ocurre en el caso en que se produzca una condición.

Nota: Simbología para la construcción del árbol de fallos. Fuente: (Fernández et al., 2017)

Definición de Falla

Se define falla el cambio de conducta de los componentes que conforman un sistema, es decir, éste ya no puede realizar su actividad designada a desempeñar.(Hurtado et al., 2016)

Definición de obtención de Datos

El proceso de adquirir parámetros físicos como corriente, presiones, temperaturas, entre otras es conocido como adquisición de datos. Posterior se realiza mejora en el procesamiento de datos en una investigación. (NATIONAL INSTRUMENTS, 2024)

Análisis Cualitativo

Para el sector de mantenimiento un método cualitativo obtiene las causas que generan fallas en el desarrollo del procedimiento, equipos o sistemas. Esto se logra con la ayuda de técnicas de recolección de información como lluvia de ideas, entrevistas y observación.

Análisis Cuantitativo

Al mencionar métodos cuantitativos estamos tratando de forma directa con estudios estadísticos e indicadores asociados a los procesos evaluados.

Los modelos aplicados son modelos matemáticos e ilustración de gráficas representativas para analizar los datos.

Aprendizaje automático

El aprendizaje automático o también citado en inglés como Machine Learning, forma parte de una de las ramas de la inteligencia artificial. (Sandoval, 2018) explica que: “El trabajo del Machine Learning es elaborar algoritmos que tienen la capacidad de aprender y no necesitan ser programados con un carácter riguroso”. Uno de los requisitos primordiales es que necesita un número grande de datos con el fin de que el algoritmo

pueda instruirse y eso mismo sirva para que esté al corriente como actuar en cada caso que se presente.

Señales PID's

Las señales PID's, también conocidas como parámetros de identificación de datos, señalan que son códigos que se utiliza en el sistema de diagnóstico de los vehículos de tal manera que sirva para estar al tanto de cómo se encuentra los componentes del motor a través de la recolección de datos, lo que permite formar un estudio íntegro de su funcionamiento para posteriormente poder revelar posibles fallos de forma eficaz.

Precisamente, el primer modo del diagnóstico a bordo (OBD) está enfocado en la recolección de datos en tiempo real, suministrando valores analógicos o digitales de las salidas y entradas conectadas a la unidad de control del motor. Es indispensable resaltar que las señales emitidas permiten gestionar el monitoreo real del vehículo lo cual complementa el diagnóstico de forma temprana ante posibles irregularidades en los diferentes sistemas. Esta actitud proactiva es primordial para realizar planes de mantenimiento preventivo del automotor. (Rivera et al., 2022)

Prueba en ciclos reales de conducción (Real Driving Emissions, RDE)

El denominado RDE es un tipo de prueba con finalidad investigativa donde se suministra con equipos de medición un vehículo durante un periodo de tiempo establecido. Se recorre un determinado valor de kilómetros variando las distintas condiciones para el automotor como la temperatura, flujo de tráfico, altitud, carga del vehículo, etc. (euro 6, 2017)

Registrador de datos

El Freematics One Plus es un dispositivo versátil que tiene varias funciones. Se utiliza para la obtención de datos, permite monitorear el estado del motor de un vehículo, también como dispositivo GPS.

Este dispositivo fue desarrollado por la compañía Freematics en Australia, además contiene un software de código abierto que implementa un kit de desarrollo de software. (Gárate, 2018)

Según (Freematics, 2024) explica que “Para la recopilación de información se introduce en la entrada OBD de un vehículo y trabaja de manera autónoma siendo capaz de interactuar con la ECU.”

Figura 6 Freematics.



Nota: Dispositivo para la adquisición de información. Fuente: (Freematics, 2024)

Analizador de gases (Portable measuring emissions System, PEMS)

El Kane Live es un software en donde su trabajo es la de facilitar la transferencia de los datos de un medidor de gases portátil Kane Autoplus a otro dispositivo, como pueden ser computadoras portátiles. El mismo software provee una lectura de los datos tanto de manera gráfica o digital. (Kane, 2024)

Según (Jiménez & Cárdenas, 2023) en su proyecto “Modelo paramétrico para la estimación de emisiones contaminantes en vehículos M1 ciclo otto con OBD-II” establece en su proyecto que también, a través de la interfaz de la aplicación Kane Live, es posible:

- Almacenar los datos recopilados por el software en formato .csv.
- Bajarse los registros en base a las pruebas hechas.
- Encender, apagar y purgar la bomba.

Figura 7 Software Kane Live.



Nota: Interfaz de la aplicación Kane Live. Fuente: (Kane, 2024)

Emisiones de gases contaminantes

Las emisiones de gases polutivos están cercanamente unida al proceso de oxidación de combustibles fósiles tales como el carbón y los componentes derivados del petróleo esenciales para generar energía.

La principal fuente de contaminación mediante dióxido de carbono proviene de la quema de carbón, petróleo y gas en centrales de producción eléctrica, vehículos automotores y las instituciones industriales (Romero, 2016)

Durante el desarrollo de la obtención de energía el motor libera grandes cantidades de dióxido de carbono (CO_2), mismo que se caracteriza por la influencia en el fenómeno ambiental denominado efecto invernadero.

En el enfoque de las emisiones generadas por los automóviles se conoce que estos surgen como consecuencia de distintos procesos, el más común y representativo es la oxidación del combustible con su respectiva liberación a través del sistema de escape.

Entre los gases polutivos destacan el monóxido de carbono (CO), los óxidos de nitrógeno (NO_x), los hidrocarburos (HC), los óxidos de azufre (SO_x), compuestos orgánicos volátiles (COV) y partículas de suspensión (PM). Adicionalmente el automotor emite gases contribuyentes al efecto invernadero (CO_2) el cual no afecta de forma directa al ser humano, pero impacta de manera representativa en el cambio climático. (Velepucha et al., 2021)

Sensores

Un sensor es un componente electrónico diseñado para convertir diferentes magnitudes físicas en señales eléctricas. Estas señales son luego procesadas por la unidad de control electrónica, la cual utiliza estos datos para optimizar el funcionamiento de los sistemas. (Rivera et al., 2022)

- **Sensor TPS:**

Es el sensor de posición del acelerador, su función es convertir el ángulo de la mariposa del cuerpo de aceleración en una señal eléctrica para finalmente enviar a la ECU. Su ubicación va dispuesta en el cuerpo de aceleración del vehículo.

Comprobación funcionamiento sensor TPS

- Verificar voltaje entre puerto de alimentación (5 Voltios) y masa.

- Verificar voltaje entre puerto de 5V y masa en el interior de la PCM.
- Verificar el valor de la resistencia interna del sensor.
- Sensor MAP:

Este sensor cumple la función de medir la presión total que existe dentro del colector de admisión en base a la presión atmosférica. Como todo sensor convierte la variable física en eléctrica para posterior interpretación de la ECU.

Una vez interpretado por la ECU se calcula directamente la carga del motor, movimiento en el punto de avance al encendido y tiempos de inyección.

Se ubica en el colector de admisión entre la válvula de mariposa y válvulas de entrada. En función del movimiento de las válvulas se crea aumento o disminución de la presión ocasionando que la unidad de control modifique constantemente la cantidad de combustible.


- Sensor O₂:

El sensor de oxígeno forma parte de los elementos más relevantes del sistema de control de las emisiones de un automóvil. El trabajo del O₂ es de controlar la cantidad de oxígeno presente en los gases del escape, posteriormente con esa información recolectada por el sensor esta viaja a la PCM (Powertrain Control Module) para que este ajuste de forma precisa la mezcla aire-combustible. (Booster, 2023)

La mezcla de aire-combustible puede ser tanto rica como pobre, si la mezcla de un vehículo es rica esta indicaría que se consume casi todo el oxígeno, obteniendo un rango de valores de 0.6 - 1.0 volt y si se tiene una mezcla pobre esto señalaría que posteriormente al proceso de combustión se tiene más oxígeno disponible teniendo así un rango de valores de 0.1 - 0.4 volt. (Booster, 2023)

Es esencial mencionar que la señal de voltaje del sensor de oxígeno proporcionado por un scanner automotriz, tanto para una mezcla rica será alta y para una pobre será baja como se observa en la siguiente figura 8.

Figura 8 Sensor de oxígeno.



Nota: Señal oscilante del sensor de oxígeno. Fuente: (Booster, 2023)

Ajuste de combustible:

El ajuste de combustible tanto de corto (STFT) y largo (LTFT) plazo, trata de la capacidad que tiene el sistema de inyección para regular la dosificación de la mezcla aire - combustible que va a ingresar a la cámara de combustión del motor de un vehículo. De este modo se garantiza el funcionamiento óptimo del motor en cuanto a su rendimiento y eficiencia. (Molina, 2023), en su artículo “Estimación del consumo de combustible a través de las señales PID’s mediante el uso del ciclo de emisiones reales en la ciudad de Quito-Ecuador” establece que “ El ajuste a corto plazo hace las correcciones de manera inmediata que son realizados por el sistema de gestión del motor en función de la respuesta a las condiciones de funcionamiento actuales y cuando se trata a largo plazo su trabajo va más centrado en la corrección de desviaciones en la mezcla aire-combustible durante un periodo prolongado”.

Long Term Fuel Trim (LTFT)

Es la corrección de largo plazo que se genera debido a la variación de valores en la señal del sensor de oxígeno. Indica la cantidad corregida sobre el ancho de pulso de inyección. A partir de un valor mayor al 25% el vehículo sufrirá código de averías.

Short Term Fuel Trim (STFT)

Esta corrección se genera en corto plazo, es decir, funciona con la variación de la señal del sensor Oxígeno en valores pequeños. Es el causante de la mezcla rica y pobre. (Calderón, 2012)


Definición de fiabilidad

Sinónimo de confianza es una medida estadística que determina qué tan probable es un evento de fallo en un elemento o sistema. Esto permite garantizar el óptimo funcionamiento conociendo el tiempo establecido. (Apolo et al., 2017)

Modelos de fiabilidad

En la figura 9 se presentan modelos de fiabilidad en análisis estadísticos. Se compone de exponencial, Weibull y Normal

Figura 9 Modelos de fiabilidad.



Nota: modelos de fiabilidad en análisis estadísticos. Fuente: (Torres, 2017)

Estimación de Contaminantes

Una vez adquirido los valores de concentración respecto al volumen de los gases polutivos se puede representar los caudales másicos de cada uno de los contaminantes.

El flujo de masa de gases en la salida del sistema de escape se representa de la siguiente forma:

$$\dot{m}_{ex} = \dot{m}_{in} + \dot{m}_f$$

Fórmula 2 Fórmula de estimación de contaminantes.

Fuente: (Comisión Europea, 2016)

La emisión de gases se debe medir en base seca por lo que la literatura propone la aplicación de una ecuación fundamentada en la base húmeda del contaminante relacionada con la base seca del mismo.

$$C_{wet,j} = k_{w,j} C_{dry,j}$$

Fórmula 3 Fórmula de estimación de contaminantes.

Fuente: (Comisión Europea, 2016)

$$k_w = \frac{1.008}{1 + 0.005 \propto (CO_2 + CO)}$$

Fórmula 4 Fórmula de estimación de contaminantes.

Fuente: (Comisión Europea, 2016)

En la ecuación mencionada se muestra el factor de corrección. Posterior se puede calcular en base a la ecuación de emisiones másicas de cada contaminante.

$$\dot{m}_{j,i} = c_{j,i} \mu_{j,i} \dot{m}_{ex,i} 10^{-3}$$

Fórmula 5 Fórmula de estimación de contaminantes.

Fuente: (Comisión Europea, 2016)

La emisión de gases en el periodo de manejo de las pruebas es igual a la sumatoria de la emisión instantánea respecto al tiempo.

$$m_j = \sum_{i=0}^n \dot{m}_{j,i} \Delta t$$

Fórmula 6 Fórmula de estimación de contaminantes.

Fuente: (Comisión Europea, 2016)

Los factores de emisión de cada contaminante en la sección del RDE queda determinada mediante la ecuación:

$$F_{j,k} = \frac{m_{j,k}}{s_k}$$

Fórmula 7 Fórmula de estimación de contaminantes.

Fuente: (Comisión Europea, 2016)

Donde:

$\dot{m}_{ex}$ [g/s]: Flujo masico de escape.

$\dot{m}_{in}$: Es el flujo másico de aire.

$\dot{m}_f$: El flujo de combustible.

$C_{wet,i}$: Es la concentración.

$C_{dry,j}$: Es la concentración en base seca del contaminante.

k_w : Es el factor de corrección de base seca a húmeda.

α : Es la relación molar del hidrógeno.

$C_{CO_2} + C_{CO}$: Son las concentraciones en base seca de CO_2 y CO .

$\dot{m}_{j,i} \left[\frac{g}{s} \right]$: Emisiones máscas instantáneas de cada contaminante.

i Es el número de medición.

c_j , Es la concentración instantánea.

μ_j Es la relación entre la densidad de cada componente y la densidad global del escape.

m_j (g): Emisión de cada contaminante.

$\dot{m}$: Es el flujo másico instantáneo del contaminante j .

n : Es el número de muestras del dataset.

Δt : Es el tiempo de muestreo.

$F_{j,k}$: Factores de emisión.

Herramientas de clasificación

Fine Tree:

Son árboles de decisión que se ocupan para la predicción de resultados mediante una serie de decisiones basadas en datos recopilados. (MathWorks, 2024a)

KNN:

K-Nearest Neighbors se ocupa en el aprendizaje automático con la finalidad de poder realizar actividades tanto de clasificación como de regresión. (MathWorks, 2024c)

SVM:

Máquinas de vectores soporte en Matlab forma parte del aprendizaje automático, en donde se usa para actividades de clasificación. (MathWorks, 2024b)

Narrow Neural Network:

Una red neuronal de este tipo permite elaborar modelos de Machine Learning más simples, debido a que cuentan con una estructura más sencilla siendo capaces de dar resultados efectivos sin requerir de una estructura compleja. (MathWorks, 2024d)

Estado del arte

Dongfang Zhao, y Shungen Xiao en su artículo científico desarrollan una metodología denominada ESAX, que toma el problema de aliasing en las señales y la operación de valor extremo absoluto garantizando la corrección de los datos mediante un proceso de cálculo. Esto es necesario al momento de analizar señales de sensores en vehículos para predecir fallos mecánicos. (Zhao et al., 2022)

La utilización del modelo BoW (Bag-of-Words) para convertir cadenas de símbolos en vectores de características digitales es aplicable al análisis de señales de sensores en automóviles. Al emplear el modelo BoW para realizar estadísticas de conteo de palabras relacionadas con fallas, se puede extraer información relevante de las señales de los sensores para predecir fallos en los vehículos.

La incorporación del algoritmo de puntuación de Laplaciano (LS) en el proceso de extracción de características contribuye significativamente a la identificación y clasificación de características relevantes para la predicción de fallos automotrices. Al

clasificar los resultados estadísticos obtenidos a través del modelo BoW, optimiza la precisión en la predicción de fallos basada en señales de sensores en vehículos.

Como resultado de esta investigación se obtiene que la combinación de la metodología ESAX, el modelo BoW y el algoritmo LS desarrollados es aplicada de manera efectiva en el procesamiento de cualquier tipo de señales. Por este motivo se implementa en la predicción de fallos automotrices basada en señales de sensores, permitiendo una extracción precisa de características y una mejor comprensión de posibles problemas mecánicos en los vehículos.

Mohammed Al-Zeyadi et al en su investigación menciona acerca del uso de técnicas de aprendizaje profundo como el Modelo Basado en Síntomas Profundos (Deep-SBM), mejora la eficiencia y efectividad del diagnóstico de fallas en vehículos. Esto se alinea con la idea de que el aprendizaje profundo es una herramienta poderosa para predecir y diagnosticar fallos en sistemas automotrices. (Al-Zeyadi et al., 2020)

El documento describe que se generó un conjunto de datos de diagnóstico convirtiendo sesiones de diagnóstico exitosas en vectores de características y síntomas de vehículos. En una investigación sobre predicción de fallos automotrices, este enfoque de generar conjuntos de datos estructurados a partir de datos de diagnóstico reales podría ser crucial para entrenar modelos de aprendizaje automático.

La investigación menciona que el modelo Deep-SBM fue validado a través de experimentos que verifican su rendimiento con otros modelos. En una investigación sobre predicción de fallos automotrices, la evaluación del rendimiento de los modelos de predicción es fundamental para determinar su eficacia y utilidad en la detección de fallos en vehículos.

Como resultado de la investigación se conoce que la información del documento con una investigación sobre predicción de fallos automotrices destaca la importancia de utilizar técnicas avanzadas como el aprendizaje profundo, la generación de conjuntos de datos estructurados y la evaluación rigurosa del rendimiento del modelo para mejorar la precisión y eficiencia en la predicción de fallos en vehículos. Esto es de vital aporte para el proyecto técnico de investigación presente.

Molina Campoverde en su estudio técnico titulado “Driving Mode Estimation Model Based in Machine learning Through PID’s Signals Analysis Obtained From OBD II” (J. Molina, 2020), menciona sobre el uso de técnicas de aprendizaje profundo, como el Modelo Basado en Síntomas Profundos (Deep-SBM), puede mejorar la eficiencia y efectividad del diagnóstico de fallas en vehículos. Esto se alinea con la idea de que el aprendizaje profundo puede ser una herramienta poderosa para predecir y diagnosticar fallos en sistemas automotrices.

El documento describe cómo se generó un conjunto de datos de diagnóstico convirtiendo sesiones de diagnóstico exitosas en vectores de características y síntomas de vehículos. En una investigación sobre predicción de fallos automotrices, este enfoque de generar conjuntos de datos estructurados a partir de datos de diagnóstico reales es determinante para entrenar modelos de aprendizaje automático.

La investigación menciona que el modelo Deep-SBM fue validado a través de experimentos que comparan su rendimiento con otros modelos. En una investigación sobre predicción de fallos automotrices, la evaluación del rendimiento de los modelos de predicción es fundamental para determinar su eficacia y utilidad en la detección de fallos en vehículos.

Manteniendo relación, se destaca la importancia de utilizar técnicas avanzadas como el aprendizaje profundo, la generación de conjuntos de datos estructurados y la evaluación rigurosa del rendimiento del modelo para mejorar la precisión y eficiencia en la predicción de fallos en vehículos.

Molina Campoverde en su proyecto de investigación titulado “Estimación de Consumo de Combustible a Través de las Señales PID’s Mediante la Utilización del Ciclo de Emisiones Reales en la Ciudad de Quito” (Molina, 2023), desarrolla una propuesta metodológica centrada en predecir el consumo másico de combustible en un vehículo. Para lograrlo aplican ciclos de emisiones reales RDE contrastado con el desarrollo de un algoritmo donde se aplican las fuerzas resistentes al movimiento.

Esta aproximación metodológica es crucial, ya que la predicción precisa del consumo de combustible está directamente relacionada con la eficiencia y el correcto funcionamiento del sistema de inyección de combustible. Si el sistema de inyección falla, el consumo de combustible se ve alterado directamente.

Por tales motivos la investigación es altamente relevante para interpretación de fallos de sistemas de inyección debido a la rigurosidad del enfoque metodológico, el uso de señales PID’s, uso de datos y condiciones reales.

Sandoval en su artículo titulado “Artículos de Aprendizaje Automático para Análisis y Predicción de Datos” (Sandoval, 2018), menciona que la evaluación y predicción de fallos en equipos tecnológicos son aspectos cruciales en diversos sectores industriales. Al detectar posibles fallas de manera anticipada, puedo evitar costosos periodos de inactividad y reparaciones. En este contexto, el uso de técnicas avanzadas como el

Machine Learning se ha vuelto esencial para mejorar la precisión y eficiencia en la predicción de fallos.

El documento revisado destaca cómo el Machine Learning puede aplicarse en la predicción de fallos, ya que este enfoque permite analizar grandes volúmenes de datos para identificar patrones y tendencias que sugieren posibles fallas en equipos tecnológicos. Al utilizar datos específicos y características definitorias de cada caso, puedo ofrecer análisis predictivos, lo que permite no solo evaluar eventos pasados, sino también realizar predicciones individualizadas basadas en comportamientos futuros.

Además, la capacidad del Machine Learning para aprender automáticamente de los datos y generar modelos predictivos que se puede integrar en aplicaciones ofrece un gran potencial para mejorar la eficacia de los sistemas de monitoreo y mantenimiento predictivo. Al anticipar fallos en equipos tecnológicos, permite adoptar estrategias proactivas para minimizar interrupciones operativas, optimizar la planificación del mantenimiento y reducir los costos asociados con reparaciones inesperadas.

Como resultado de la información se conoce que la relación entre la información proporcionada en el documento y nuestra investigación sobre predicción de fallos subraya la importancia del Machine Learning como una herramienta clave para mejorar la fiabilidad y eficiencia en la gestión de activos tecnológicos. Permitiendo anticipar posibles fallos y tomar medidas preventivas a tiempo.

Aguilar y Tandazo, en su investigación titulada "Análisis de Modos de Falla, Efectos y Criticidad (AMFEC) del Sistema de Inyección de un Motor de Encendido Provocado Corsa Evolution 1.4L Empleando Herramientas de Aprendizaje y Clasificación para la Programación del Mantenimiento"(A. Aguilar & Tandazo, 2017), se enfoca en analizar los modos de falla del sistema de inyección de un motor específico.

Para vincular este trabajo con nuestra investigación sobre predicción de fallos del sistema de inyección, se destaca la relevancia de utilizar herramientas de aprendizaje y clasificación para mejorar la programación del mantenimiento y la disponibilidad del motor, como se menciona en las recomendaciones del trabajo de titulación. Esta investigación podría explorar cómo la aplicación de metodologías como el AMFEC y el uso de sistemas inteligentes en línea pueden contribuir a una mejor predicción de fallos en el sistema de inyección de motores, permitiendo una planificación más efectiva del mantenimiento y aumentando la disponibilidad del vehículo.

Como resultado se obtuvo que, al integrar los hallazgos y recomendaciones del trabajo de titulación con investigaciones previas sobre predicción de fallos en sistemas de inyección de motores, se puede avanzar en el desarrollo de estrategias más eficientes para la gestión del mantenimiento y la operatividad de los vehículos.

El artículo académico presentado por Pacho y Tacuri se enfoca en el análisis de modos de fallo (AMFEC) de un motor Aveo 1.4L mediante la fragmentación de microciclos en función de las señales PID's. (Pacho & Tacuri, 2020)

Se empleó la metodología AMFEC para llevar a cabo el análisis de los modos de fallo en un motor Aveo 1.4L. La metodología AMFEC es una herramienta utilizada en ingeniería para identificar los posibles modos de fallo de un sistema, evaluar sus efectos y determinar su criticidad en función de la importancia de cada fallo en el funcionamiento global del sistema.

En este estudio, se fragmentaron los microciclos del motor en función de las señales PID's (Proporcional, Integral, Derivativo) para analizar cómo varían en estado estacionario y transitorio en dos etapas: una con el motor en buen funcionamiento y otra con fallos provocados, como la desconexión de una bujía, la anulación de un inyector y la saturación

del filtro de aire. La adquisición de datos se realizó mediante el dispositivo Freematics One +, y a partir de estos datos se generó una matriz de resultados mediante la fragmentación de microciclos.

El análisis de la matriz de resultados permitió identificar los cambios en el motor con fallos provocados en comparación con un motor en perfecto estado, utilizando histogramas y aplicando el análisis de varianza (ANOVA) para corroborar dichos cambios. Además, se aplicó la metodología AMFEC para determinar cuál era el fallo más crítico y los efectos que causaba en el funcionamiento del motor. Los resultados principales del estudio destacaron la importancia de la toma de decisiones basada en un modelo AMFEC para optimizar las tareas de mantenimiento en un vehículo Aveo 1.4L.

Ambos estudios comparten el enfoque en la aplicación de la metodología AMFEC para analizar los modos de fallo en sistemas de inyección de motores, lo que subraya la importancia de esta metodología en el ámbito de la ingeniería automotriz para identificar y prevenir posibles fallos en los sistemas de los vehículos. La utilización de AMFEC en estos contextos demuestra su eficacia para el análisis y la predicción de fallos en sistemas automotrices críticos como el sistema de inyección.

CAPÍTULO II: METODOLOGÍA UTILIZADA PARA LA OBTENCIÓN DE DATOS

Este capítulo se describe en detalle el método empleado para la adquisición de datos previo al análisis mediante técnicas de aprendizaje automático. Se utilizaron equipos automotrices móviles o portátiles con el objetivo de captar datos en condiciones reales de conducción garantizando así un alto nivel de confiabilidad y precisión en los datos recopilados.

Las técnicas de recolección y evaluación de datos incluyeron una aplicación móvil diseñada para capturar parámetros operativos a través del puerto DLC, en conexión con el dispositivo OBDLink MX. Este dispositivo automotriz se utilizó para medir varios gases contaminantes mediante una sonda y un analizador conectado al software KANE LIVE. Adicionalmente, se empleó el dispositivo FREEMATICS ONE+ para obtener información en tiempo real sobre la ubicación geográfica durante diversas rutas. El objetivo es interpretar estadísticamente el comportamiento de las diversas señales PID's capturadas del vehículo, con el fin de comprender el funcionamiento del sistema de inyección.

La adquisición de valores de las diferentes señales PID's se realizó durante la conducción de un vehículo Kia Sportage que porta la codificación G4GC para el motor en una ruta dentro de la ciudad de Cuenca, Ecuador. El procedimiento se llevó a cabo siguiendo los principios técnicos establecidos en la Normativa Euro 6 RDE 1154, la cual define estándares en términos de velocidad, tiempo y tipos de recorrido.

Variables para la adquisición de datos:


Para desarrollar la adquisición de datos debemos tener establecido los tipos de variables que encontraremos durante el proceso.

En el transcurso del proceso existen indicadores de inferencia, por lo general se conocen como:

- Variables de entrada
- Variables de ruido
- Variables de bloqueo
- Variables de salida

Como se muestra cada una de las variables inciden de manera directa en el análisis de las señales PID's y en las señales contaminantes. (Rivera-Campoverde et al., 2021)

Figura 10 Clasificación de variables.



Nota: Tipos de variables para la adquisición de datos. Fuente: (Autores, 2024)

Variables de Ruido

Aplicado el proceso de adquisición de datos durante el periodo de conducción dentro de la ciudad de Cuenca existen factores que intervienen de manera directa, pero son intrincados de controlar. Dicho de esta forma estos factores ejercen alta variación en los datos finales del experimento.

Tabla 4 Variables de Ruido.

Variables de ruido	Símbolo	Rango de valores	Unidad
Humedad relativa del aire	H_{rel}	65-75	[%]
Presión atmosférica	P_{atm}	70-80	[KPa]
Temperatura del aire	T_{aire}	15-25	[°C]

Nota: Variables de ruido para la adquisición. Fuente: (Autores, 2024)

Variables de Bloqueo

Los factores son controlados de manera directa por el técnico durante el desarrollo experimental. Como resultado, estos factores no influyen en los parámetros de salida, asegurando la integridad y precisión de los datos obtenidos. Estos factores controlados permiten aislar y estudiar los efectos de las variables independientes sobre las variables dependientes, facilitando un análisis riguroso y fiable de los resultados experimentales.

Tabla 5 Variables de Bloqueo.

Variables de bloqueo	Símbolo	Rango de valores	Unidad
Temperatura del refrigerante	T_{ref}	80-95	[°C]
Masa del vehículo	m_{veh}	1533	[Kg]
Temperatura del lubricante	T_{lub}	90-105	[°C]

Nota: Variables de bloqueo para la adquisición. Fuente: (Autores, 2024)

Variables de Entrada

Las variables de estudio conocidas influyen directamente en los valores resultantes emitidos por las variables de salida después del proceso experimental.

Entre las variables de entrada, la relación debe ser independiente entre sí; de tal forma, si se modifica el valor de un parámetro, no afectará a otro, a pesar de pertenecer al mismo grupo de variables o parámetros.

Tabla 6 Variables de Entrada.

Variables de entrada	Símbolo	Unidad
Régimen de giro del motor	n	[RPM]
Flujo másico del aire	MAF	[g/s]
Velocidad del vehículo	VSS	[km/h]
Tipo de vehículo	SUV	[-]
Ruta	d	[Km]

Nota: Variables de entrada para la adquisición. Fuente: (Autores, 2024)

Variables de Salida

Los factores conocidos como variables de respuesta son los resultados emitidos por el proceso experimental. Estas variables varían en función de los tres grupos de parámetros previamente mencionados, debido a su dependencia directa de dichos parámetros. La variabilidad de las variables de respuesta es un reflejo de cómo los diferentes parámetros controlados y no controlados influyen en los resultados finales, permitiendo así una comprensión profunda del comportamiento analizado.

Tabla 7 Variables de Salida.

Variables de salida	Símbolo	Unidad
Consumo de combustible	Consumo	L/100 km
Monóxido de carbono	CO	[%]
Dióxido de carbono	CO ₂	[%]
Hidrocarburos no combustionados	HC	[ppm]
Óxidos de nitrógeno	NO _x	[ppm]

Nota: Variables de salida para la adquisición. Fuente: (Autores, 2024)

Rutas para obtención de datos

En consecuencia, de la necesidad de datos de las señales PID's del vehículo Kia Sportage equipado con una transmisión manual de 6 velocidades y un motor 2.0 (G4GC) en condiciones de funcionamiento real se fundamenta la planificación de un ciclo de conducción.

Es imprescindible establecer un recorrido que disponga de variedad de condiciones para el vehículo tipo M1 (SUV) conforme a la normativa técnica INEN 2656.

La primera ruta establecida obedece lineamientos de la normativa EURO 6 correspondiente al RDE 1154.

El Reglamento (UE) 2017/1154 de la Comisión se enfoca en abordar las emisiones de vehículos de motor, específicamente las de turismos y vehículos comerciales ligeros (Euro 5 y Euro 6). Su objetivo principal es mejorar la calidad del aire y proteger la salud humana mediante la reducción de las emisiones contaminantes.


Este reglamento establece medidas para asegurar que los vehículos cumplan con los límites de emisiones estipulados. Prohíbe el uso de dispositivos de desactivación que disminuyan el control de emisiones y fija requisitos estrictos para la homologación de

tipo de los vehículos. Asimismo, implementa procedimientos de ensayo de emisiones en condiciones reales de conducción (RDE) para reflejar de manera precisa las emisiones en carretera.

El Reglamento (UE) 2017/1154 tiene como finalidad corregir las deficiencias en las emisiones de los vehículos de motor, especialmente en lo referente a las emisiones de NOx con el objetivo de mejorar la calidad del aire y proteger la salud pública.

Para la adquisición de datos se emplea un sistema portátil de medición de emisiones. Los segmentos de la ruta comprenden 21,63 km en áreas urbanas, 21,24 km en áreas rurales y 19,61 km en autopistas, respetando el requisito mínimo de 16 km

Figura 11 Ruta de adquisición de datos. Normativa RDE.



Nota: Ruta normalizada RDE. Fuente: (Autores, 2024)

En complemento, se muestra la segunda ruta realizada se hizo de manera aleatoria dentro de la ciudad de Cuenca. El objetivo es realizar una toma muestral de la conducción normal dentro de la ciudad. Se inicia desde la ubicación de la Universidad Politécnica Salesiana

tomando pendientes, sectores de congestión vehicular, sectores de alta velocidad de recorrido.

Como se aprecia en la *figura 12* se evidencia el recorrido realizado para obtención de los distintos parámetros necesarios de análisis.

Figura 12 Ruta de adquisición de datos. Conducción Aleatoria.



Nota: Ruta aleatoria para la adquisición de datos. Fuente: (Autores, 2024)

Proceso Experimental

Engloba todo el desarrollo de la experimentación exponiendo el equipo técnico utilizado para adquisición de parámetros de funcionamiento. El conocimiento de dichos valores se torna imprescindible para interpretar factores de entrada preparativos a la predicción de fallos en etapas incipientes del vehículo seleccionado mediante asistencia por software de ingeniería.

Vehículo asignado a testeo

El vehículo destinado al desarrollo experimental catalogado como tipo SUV (Sport Utility Vehicle) es un Sportage de la marca Kia. Es un SUV compacto de diseño moderno y sofisticado, equipado con tecnología avanzada y sistemas de seguridad de última

generación. Ofrece un rendimiento eficiente y una experiencia de conducción cómoda frente a exigencias de conducción.

A continuación, se presenta la imagen referencial del vehículo seleccionado:

Figura 13 *Kia Sportage.*



Nota: Vehículo asignado para la toma de datos. Fuente: (Autores, 2024)

En la tabla siguiente se respalda el vehículo seleccionado con sus datos técnicos y especificaciones de fábrica.

Tabla 8 *Especificaciones mecánicas y eléctricas del Kia Sportage.*

<i>Especificación</i>	<i>Valor</i>
Motor	4 cilindros en línea
Cilindrada	1995 cc
Relación de compresión	16,5:1
Tipo de combustible	Gasolina
Transmisión	Manual
Número de velocidades	6 velocidades
Potencia máxima	134,15 HP
Torque máximo	320 Nm

Nota: Ficha técnica del Kia Sportage. Fuente: (Autores, 2024)

Adquisición de Datos

Una vez concluida la presentación sobre la información del vehículo y las rutas seleccionadas para la obtención de parámetros, procedemos a equipar el vehículo con dispositivos móviles especializados. Estos incluyen: un analizador y medidor de gases, la aplicación funcional Kane Live y la antena GPS Freematics.

El analizador de gases portátil Kane tiene la capacidad de establecer conexión con la unidad de control del vehículo, lo que permite el enlace de datos en tiempo real mediante el software Kane Live. El dispositivo que brinda las coordenadas geográficas del vehículo durante todo el ciclo de conducción es el Freematics ONE+ cual va enlazado en la conexión OBD II.

Figura 14 Dispositivos vinculados en la adquisición de datos.




Nota: Diagrama de los dispositivos vinculados al vehículo para la adquisición de datos.

Fuentes: (Autores, 2024)

El objetivo de mantener el orden del protocolo es garantizar la adquisición de datos de manera precisa y confiable, disminuyendo el margen de error al mínimo. Este protocolo

brinda una descripción concisa de las actividades llevadas a cabo desde la fase inicial del procedimiento. A continuación, se presenta el flujograma del desarrollo:

Figura 15 Protocolo para la adquisición de datos.



Nota: Flujograma del proceso a seguir para la adquisición de datos. Fuente: (Autores, 2024)

Con fundamentos teóricos el flujograma expuesto brinda la capacidad de optimizar el procedimiento en la etapa de predicción de fallos debido a que brinda datos estadísticos con mínimos márgenes de error.

Vectores De Análisis

Una vez completada la fase de recopilación de datos, estos se cargan en el software de ingeniería (MATLAB) en forma de matrices y vectores. Se utilizan matrices generales para inicializar los valores de cada una de las variables; posteriormente, estas se etiquetan y se organizan en vectores.

En el desarrollo de la investigación se han adquirido valores de parámetros mediante los distintos equipos usados, esto significa que el número de datos entre equipos no sean iguales o parecidos.

En consecuencia, de esto para interpretación de datos en el software MatLab requiere que los tamaños de los vectores sean iguales con referencia al de mayor extensión.

Cuando el programa de ingeniería realiza lectura de los datos presenta inconvenientes con formatos de texto, caracteres que no son numéricos denominándose NaN. Por tal motivo se debe generar el reemplazo de dichos datos erróneos por el valor 0, logrando el avance de funcionalidad del código.

Filtrado de variables


Al realizar la adquisición de datos se toma en cuenta que la calidad de las variables recibidas no tiene 100% de fiabilidad. Por esta razón se deben filtrar cada una de ellas debido a que sufren distintas alteraciones:

- Ruido: Al ser datos que provienen de sensores de un motor de combustión interna en funcionamiento real, existen varias vibraciones, movimientos, etc. Estas causas generan errores en la medición por lo que deben ser filtrados para mantener la calidad de las variables.
- Datos Anómalos: Se trata de valores extraños que mantienen riesgo de alterar negativamente la precisión del modelo.

A continuación, se presentan las gráficas características de los sensores que componen el automóvil, mostrando su comportamiento real durante la conducción, para ello se han asignado 4 pruebas de conducción en 2 rutas distintas.

La primera prueba se realizó tomando datos en condiciones de funcionamiento normal del vehículo al tener alrededor de 140 mil Km de recorrido.

Figura 17 Visualización PID's.




Nota: Visualización de los diferentes sensores. Fuente: (Autores, 2024)

Los datos adquiridos son los que se muestran a continuación:

La *figura 18* evidencia el comportamiento del vehículo durante las condiciones de funcionamiento normal, los valores que muestra el ajuste de largo plazo varían en valores de un máximo de 16% indicativo de funcionamiento aceptable del vehículo.


Figura 18. Ajuste de combustible de largo plazo.



Nota: LTFT en condiciones normales. Fuente: (Autores, 2024)

En la *figura 19* se muestra la forma en la que se comportó el vehículo en el transcurso de las condiciones normales, los valores que muestra el LTFT varían, pero en el valor de 14% es un indicativo de que el vehículo debe de realizar un ajuste y esto puede deberse a fugas.


Figura 19 Ajuste de combustible de largo plazo.



Nota: Histograma del LTFT en condiciones normales. Fuente: (Autores, 2024)

La *figura 20* muestra el comportamiento del ajuste de combustible de corto plazo, los valores que muestra van hasta un máximo que supera el 20% y van valores cercanos a 0.

Figura 20 Ajuste de combustible de corto plazo.




Nota: STFT en condiciones normales. Fuente: (Autores, 2024)

La *figura 21* muestra el comportamiento del STFT, señalando que hay valores cercanos a 0 lo que sugiere que el vehículo está ajustando el combustible de manera correcta, como consecuencia el vehículo tiene un buen rendimiento.

Evidenciando que durante este ciclo de conducción la mezcla de aire - combustible está cerca de la ideal.

Figura 21 Ajuste de combustible de corto plazo.




Nota: Histograma del STFT en condiciones normales. Fuente: (Autores, 2024)

A continuación, se presentan las gráficas de funcionamiento del sensor TPS y del sensor de oxígeno (O_2), los cuales son indispensables al momento de interpretar el rendimiento del sistema de inyección electrónica de combustible del vehículo.

En referencia al comportamiento del sensor TPS, se muestra la *figura 22* misma que contrasta el funcionamiento normal del vehículo. El vehículo realiza pocas aceleraciones mismas que son progresivas.


Figura 22 Comportamiento del sensor TPS.



Nota: Sensor TPS en condiciones normales. Fuente: (Autores, 2024)

Se observa en la *figura 23* un funcionamiento normal del vehículo durante el ciclo de conducción en condiciones normales. El vehículo realiza aceleraciones bajas en la mayor parte del recorrido.


Figura 23 Comportamiento del sensor TPS.



Nota: Histograma del sensor TPS en condiciones normales. Fuente: (Autores, 2024)

La *figura 24* representa el comportamiento alterado del sensor de oxígeno (O_2). Al ser un sensor que proporciona directrices para la corrección de tiempos de inyección se muestra que tiene oscilaciones normales por el número de muestras también está dentro de los rangos.

Figura 24 Comportamiento del sensor de oxígeno (O_2).




Nota: Sensor O_2 en condiciones normales. Fuente: (Autores, 2024)

En la *figura 25* se muestra cómo se comportó el sensor de oxígeno (O_2). Evidenciando que tiene oscilaciones normales que se encuentran dentro de los rangos de 0 - 1 v, lo que indica que en el transcurso del recorrido no hubo anomalías.

De la misma forma la prueba número dos se denomina al recorrido realizado en el vehículo durante la conducción aleatoria simulando fallo del vehículo con obstrucción en el ingreso de aire al sistema de admisión.

Figura 25 Comportamiento del sensor de oxígeno (O_2).




Nota: Histograma del sensor O_2 en condiciones normales. Fuente: (Autores, 2024)

Una vez provocada la falla a continuación se muestra el comportamiento de los sensores:

La *figura 26* plasma el comportamiento del ajuste de combustible de largo plazo. Al impedir el ingreso de aire el sistema debe modificar los valores de dosificación de combustible a la mezcla con el aire. Se puede ver que los valores máximos sobrepasan el 40% a comparación que con normalidad alcanza solamente 16%.


Figura 26 Ajuste de combustible de largo plazo.



Nota: LTFT con la condición del filtro de aire tapado. Fuente: (Autores, 2024)

La *figura 27* plasma el comportamiento del LTFT. Al momento que se tapa el filtro por consecuencia comenzará a reducirse el flujo de aire que ingresa al motor. Como se observa se tuvo valores altos lo que señala que hubo un aumento de los gases contaminantes.

Figura 27 Ajuste de combustible de largo plazo.




Nota: Histograma del LTFT con la condición del filtro de aire tapado. Fuente: (Autores, 2024)

La *figura 28* responde al comportamiento que tuvo el ajuste de combustible en el sistema de inyección al provocar la obstrucción de ingreso de aire. Como se muestra los valores parten desde valores negativos en el eje vertical hasta alcanzar el 20% como valor máximo.

Los valores presentados evidencian la presencia de la falla en el vehículo, comparando con un funcionamiento normal. En el eje horizontal se muestra el número total de muestras realizadas.


Figura 28 Ajuste de combustible de corto plazo.



Nota: STFT con la condición del filtro de aire tapado. Fuente: (Autores, 2024)

La figura 29 plasma el comportamiento que se obtuvo del STFT al obstruir el ingreso de aire. Como se observa durante el ciclo de conducción, parte desde valores negativos lo que es un indicio de que se produjo alguna anomalía haciendo fallar el vehículo.


Figura 29 Ajuste de combustible de corto plazo.



Nota: Histograma del STFT con la condición del filtro de aire tapado. Fuente: (Autores, 2024)

En respuesta al comportamiento del sensor TPS, se muestra la *figura 30* misma que contrasta anomalía en el funcionamiento. Para el vehículo alcanzar la misma aceleración durante el recorrido se tiene que llegar mayor número de veces a una apertura de la mariposa de aceleración que sobrepase el 75%.


Figura 30 Funcionamiento del sensor TPS.



Nota: Sensor TPS con la condición del filtro de aire tapado. Fuente: (Autores, 2024)

Como se puede evidenciar en la *figura 31* se representa el número de muestras en barras proporcionales a la cantidad de ocasiones en las que se mantuvo el porcentaje de apertura de la mariposa del TPS a lo largo del número total de muestras.


Figura 31 Funcionamiento del sensor TPS.



Nota: Histograma del sensor TPS con la condición del filtro de aire tapado. Fuente: (Autores, 2024)

La *figura 32* representa el comportamiento alterado del sensor de oxígeno (O_2), debido a la falla provocada. Al ser un sensor que brinda información de la calidad de la combustión interna para la corrección tiene oscilaciones exageradas por lo que aumenta el número de muestras del eje horizontal.


Figura 32 Funcionamiento del sensor de oxígeno (O_2).



Nota: Sensor O_2 con la condición del filtro de aire tapado. Fuente: (Autores, 2024)

La *figura 33* plasma el modo de actuar del O_2 al obstruir el flujo de aire que ingresa al motor, se muestra que tiene un sobredimensionamiento en las barras lo que señala que hay un desempeño ineficiente del motor.

Figura 33 Funcionamiento del sensor de oxígeno (O_2).




Nota: Histograma del sensor O_2 con la condición del filtro de aire tapado. Fuente: (Autores, 2024)

A continuación, se muestra el tercer recorrido realizado en la misma ruta. El recorrido evidencia la presencia de anomalía en el sistema de alimentación, en específico las bujías.

Se presentan los datos adquiridos.

La *figura 34* representa el funcionamiento del vehículo en una ruta realizada bajo la presencia de fallo en el sistema de alimentación del vehículo. La bujía presenta una calibración exagerada para el funcionamiento llegando a 1,3 mm de apertura. Los valores del ajuste llegan a superar el 25% lo cual puede generar un código de avería.


Figura 34 Ajuste de combustible a largo plazo.



Nota: LTFT con la condición de las bujías a 1.3 mm. Fuente: (Autores, 2024)

Como se muestra en la *figura 35* con respecto al LTFT al realizar la segunda anomalía se observa en las barras que se produjo una mezcla ineficiente, como consecuencia se llega a superar el 25 % y se da una reducción notable en la eficiencia del motor generando así un código de avería.


Figura 35 Ajuste de combustible a largo plazo.



Nota: Histograma del LTFT con la condición de las bujías a 1.3 mm. Fuente: (Autores, 2024)

La *figura 36* plasma la corrección que se realizó en corto plazo con la falla de la calibración de las bujías de encendido. Se confirma la presencia de falla al tener valores distantes a 0.


Figura 36 Ajuste de combustible a corto plazo.



Nota: STFT con la condición de las bujías a 1.3 mm. Fuente: (Autores, 2024)

La *figura 37* contrasta la distribución de datos tomados durante el proceso experimental el ajuste de combustible de corto plazo. Cuando se simuló la falla en las bujías evidencia notable variación en comparación al comportamiento en funcionamiento normal. Se muestra que el vehículo mayormente se encontraba en 0% de ajuste de combustible.


Figura 37 Ajuste de combustible a corto plazo.



Nota: Histograma del STFT con la condición de las bujías a 1.3 mm. Fuente: (Autores, 2024)

Como se muestra en la *figura 38* el comportamiento del TPS evidencia la pérdida de potencia notoria por lo que el vehículo debe ser forzado a tener apertura del TPS mayor al 80% para conseguir aceleración.


Figura 38 Funcionamiento del sensor TPS.



Nota: Sensor TPS con la condición de las bujías a 1.3 mm. Fuente: (Autores, 2024)

La *figura 39* acerca del histograma del sensor de la mariposa de aceleración contrasta el número de veces que se exigió aumentar el porcentaje de apertura de la mariposa. En presencia de la anomalía el vehículo mayormente se encontró mayor número de veces en porcentajes de apertura entre el 20% y 30%, relativamente bajas.


Figura 39 Funcionamiento del sensor TPS.



Nota: Histograma del sensor TPS con la condición de las bujías a 1.3 mm. Fuente: (Autores, 2024)

La *figura 40* muestra el comportamiento del sensor de oxígeno (O_2) al tener presente la falla de funcionamiento de las bujías. El sensor tiene la presencia de una mezcla incompleta en la salida de los gases lo que provoca la oscilación constante y distorsionada.


Figura 40 Funcionamiento del sensor de oxígeno (O_2).



Nota: Sensor O_2 con la condición de las bujías a 1.3 mm. Fuente: (Autores, 2024)

La *figura 41* expone los valores de voltaje que midió el sensor de oxígeno durante la presencia de falla en la calibración de las bujías de encendido. Como se puede ver el valor del sensor de oxígeno tiene oscilación entre valores de 0,1 a 0,9 voltios. Como se mira el pico de la gráfica está entre valores de 0,8 y 0,9 voltios que se repitió aproximadamente 5000 veces durante la medición indicando mezcla relativamente pobre.


Figura 41 Funcionamiento del sensor de oxígeno (O_2).



Nota: Histograma del sensor O₂ con la condición de las bujías a 1.3 mm. Fuente: (Autores, 2024)

La *figura 42* responde al comportamiento que tuvo el ajuste de combustible en el sistema de inyección durante la conducción reglamentada bajo normativa RDE. Cabe recalcar que la ruta fue tomada cuando el vehículo disponía del 87,14% menos del kilometraje actual. Como se muestra los valores parten desde valores negativos, pero en poco rango debido a que llega a -2% hasta un valor máximo de 10% lo cual indica el correcto estado de funcionamiento del vehículo.


Figura 42 Ajuste de combustible a largo plazo.



Nota: LTFT con la ruta RDE. Fuente: (Autores, 2024)

La *figura 43* plasma el desempeño que tuvo el LTFT durante la conducción reglamentada cuando el vehículo se encontraba con un registro de 18.000 km recorridos. Como se muestra en la gráfica parten desde valores negativos, pero con un rango bajo lo que señala un adecuado funcionamiento del vehículo.


Figura 43 Ajuste de combustible a largo plazo.



Nota: Histograma del LTFT con la ruta RDE. Fuente: (Autores, 2024)

La *figura 44* plasma la corrección que se realizó en corto plazo con valores demasiado cercanos a 0 y oscilando constantemente lo que muestra que el funcionamiento del automóvil no presenta ninguna falla ya que la corrección es constante.


Figura 44 Ajuste de combustible a corto plazo.



Nota: STFT con la ruta RDE. Fuente: (Autores, 2024)

En la *figura 45* se plasma el comportamiento de ajuste de combustible de corto plazo, mismo que muestra su estado de funcionamiento correcto gracias a que el mayor número de muestras se encuentra en el valor 0, esto significa que existe poca necesidad de modificación en la dosificación de la inyección; lo cual da como resultado un correcto funcionamiento.


Figura 45 Ajuste de combustible a corto plazo.



Nota: Histograma del STFT con la ruta RDE. Fuente: (Autores, 2024)

Como se muestra en la *figura 46* el comportamiento del TPS responde a la normativa del ciclo de conducción RDE. Como se conoce la normativa demanda que existe 3 diferentes escenarios de conducción lo que se demuestra en la gráfica debido a que las aceleraciones son constantes en 3 secciones distintas.


Figura 46 Comportamiento sensor TPS.



Nota: Sensor TPS con la ruta RDE. Fuente: (Autores, 2024)

En la *figura 47* se demuestra que el mayor número de apertura de la mariposa de aceleración está entre el 10 al 30% debido a las condiciones de la ruta. El histograma representa que se cumplió con la normativa RDE debido a que evidencia patrones de comportamiento en diferentes secciones.


Figura 47 Comportamiento sensor TPS.



Nota: Histograma del sensor TPS con la ruta RDE. Fuente: (Autores, 2024)

La *figura 48* muestra el comportamiento del sensor de oxígeno al tener el funcionamiento ideal del vehículo el número de oscilaciones se denota correcto entre los rangos de funcionamiento.

Figura 48 Comportamiento sensor Oxígeno (O_2).




Nota: Sensor O_2 con la ruta RDE. Fuente: (Autores, 2024)

La *figura 49* pone a consideración los valores de voltaje que brindados por el sensor de oxígeno durante el funcionamiento normal del sistema de inyección. Como se puede ver el valor del sensor de oxígeno tiene oscilación entre valores de 0,1 a 0,9 voltios.

Se puede notar 2 secciones donde existen los puntos altos de la figura cuando se muestran valores de 0 a 0,1 voltios y de 0,7 a 0,9 voltios, lo que determina que el sensor mostraba funcionalidad total al presentar oscilación constante. Esta conclusión se respalda en el comportamiento de la *figura 45* que evidencia la corrección de ajuste de combustible de corto plazo.

Figura 49 Comportamiento sensor Oxígeno (O_2).




Nota: Histograma del sensor O_2 con la ruta RDE. Fuente: (Autores, 2024)

Correlación de variables

Entendido el comportamiento de los distintos sensores en cada uno de los ciclos de conducción realizados en la toma muestral, el proceso continúa al detallar una matriz de correlación de las distintas variables obtenidas.

La matriz que se muestra en la *figura 50* evidencia el alto número de variables influyentes al caso analizado, lo que desencadena la necesidad de generar la matriz de correlación con la finalidad de interpretar los factores influyentes.

Figura 50 Matriz de correlación de variables.



Nota: Matriz de correlación entre las 2 rutas. Fuente: (Autores, 2024)

Con la determinación de los valores que afectan directamente en alta proporción al caso analizado se genera como respuesta un análisis de resultados con mayor confiabilidad.

Al llevar a cabo el análisis en el Software Matlab se adquieren valores aleatorios que reflejan la importancia de cada variable en el análisis, tal como se muestra en la *tabla 9*, el significado de dichos valores es:

Tabla 9 Interpretación de la matriz de correlación.

Valores	Explicación
Cercanos a 1	Se interpretan como una correlación correcta de manera positiva. Las variables aumentan proporcionalmente.
Cercanos a -1	Se entiende como una correlación correcta de manera negativa. Una variable suma mientras la otra disminuye de forma lineal.
Cercanos a 0	Indica ausencia de correlación.

Nota: Matriz de correlación. Fuente: (Autores, 2024)

En función a lo expuesto en la *tabla 10* se determina los siguientes valores como los más influyentes para el caso analizado.

Tabla 10 Variables más influyentes.

Variables	Valor “R”
MAP	[0,10]
STFT	[0.66]
LTFT	[-0.33]

Nota: En la tabla se visualiza las variables con su respectivo valor. Fuente: (Autores, 2024)

CAPÍTULO III: PROCESAMIENTO DE SEÑALES, ENTRENAMIENTO DE APRENDIZAJE AUTOMÁTICO Y ANÁLISIS DE PREDICCIÓN DE FALLOS

Previamente finalizada la validación de los datos de cada una de las distintas rutas, se llevó a cabo un minucioso procedimiento de análisis comparativo de las variables y factores para ser analizadas mediante inteligencia artificial.

Una vez finalizado el ordenamiento e interpretación de datos; este capítulo expone el desarrollo del análisis basado en la información adquirida de la matriz de correlación ejecutando procesos de entrenamiento del aprendizaje automático. Las variables más influyentes son los ajustes de combustibles que reaccionan en base a la lectura del sensor de oxígeno como se presenta a continuación.


Análisis comparativo

La *figura 51* evidencia la densidad muestral en función de la concentración de oxígeno (O_2) para cuatro condiciones distintas: Condición 1 (Funcionamiento Normal), Condición 2 (Obstrucción del ingreso de aire en la admisión), Condición 3 (Calibración defectuosa de la bujía) y Condición 4 (Ruta RDE). Como se observa los patrones generales permanecen consistentes con picos significativos alrededor de 0.05 V y 0.75 V, indicando fases de alta concentración de oxígeno (mezcla pobre). Sin embargo, se observa que la Condición 3 línea amarilla tiene un pico más alto alrededor de 0,9 V, superando significativamente a las demás condiciones en este punto. Este aumento sugiere que bajo la Condición 3, el sistema experimenta una mayor variación en la concentración de oxígeno, indicando una mayor criticidad.

Cabe recalcar que, al analizar el valle entre 0.1 V y 0.6 V, se observa una disminución similar en todas las condiciones, pero la Condición 3 mantiene valores ligeramente

superiores en comparación con las otras condiciones, esto refleja tendencia hacia una mezcla rica en esta región.


Figura 51 Gráfica comparativa sensor O_2 .



Nota: Gráfica O_2 entre las diferentes condiciones. Fuente: (Autores, 2024)

En la *figura 52* muestra la distribución del STFT (%) bajo las cuatro condiciones establecidas. Todas las condiciones presentan un pico principal alrededor del 0% de STFT, indicando que la mayoría de los valores de ajuste de corto plazo están concentrados cerca de cero. Las condiciones normales y filtro tapado tienen distribuciones similares, con una leve desviación hacia valores negativos, mientras que las bujías de 1.3 mm muestran dispersión elevada.


Figura 52 Gráfica comparativa Ajuste de combustible de corto plazo.



Nota: Ajuste de combustible del STFT entre las diferentes condiciones. Fuente: (Autores, 2024)

El gráfico de la *figura 53* de densidad muestra la distribución del LTFT (%) bajo las cuatro condiciones operativas. Todas las condiciones presentan un pico principal alrededor del 0% de LTFT, con la condición RDE mostrando el pico más alto y concentrado. Las condiciones normales y filtro tapado tienen una mayor dispersión de los valores de LTFT, extendiéndose hasta cerca del 30% y 25% respectivamente, mientras que las bujías 1.3 mm tienen una distribución más concentrada alrededor del 0%. Se debe resaltar que al sí se supera el 25% el vehículo indicará mediante la ECU un código de avería.

Figura 53 Gráfica comparativa Ajuste de combustible de largo plazo.



Nota: Ajuste de combustible del LTFT entre las diferentes condiciones. Fuente: (Autores, 2024)

Aplicación de la metodología AMFEC usando MATLAB


Desarrollando los parámetros de AMFEC se debe generar un árbol de fallas para determinar la criticidad e influencia de distintos factores en el desarrollo de una anomalía.

Tabla 11 Tabla Resultados Metodología AMFEC.

Formas de fallo	Efecto de fallo	Severidad	Ocurrencia	Detección	IPR
Bujía a 1.3 mm	Rendimiento de la combustión subóptimo	15	4	6	360 – 0.89874
Filtro de aire con obstrucción.	Reducción en el rendimiento del motor	10	6	4	240 – 0.59916

Nota: Resultados de la metodología AMFEC. Fuente: (Autores, 2024)

En la tabla 11 se muestra el resultado del índice IPR calculado anteriormente para los parámetros de ajuste de combustible.

Figura 54 Prioridad de fallos

Nota: Resultados del proyecto con la aplicación de AMFEC. Fuente: (Autores, 2024)

Entrenamiento de la inteligencia artificial


Posterior al procedimiento de datos se necesita realizar entrenamiento de la inteligencia artificial dentro de las funciones del Software Matlab.

Para ello se realiza el entrenamiento de 4 ramas de la inteligencia artificial como lo son: árboles de decisión, SVM, KNN y redes neuronales. Cada una de ellas muestran difieren en tiempos de entrenamiento lo que da lugar a tener diferentes valores en el porcentaje de confiabilidad.

Árboles de decisión

En la *figura 55* se obtiene la matriz de confusión que genera el modelo de árboles de decisión para realizar la predicción de fallos del sistema de inyección propuesto.

Figura 55 Predicción mediante Árboles de decisión.




Nota: Resultados del proyecto con árboles de decisión. Fuente: (Autores, 2024)

SVM

En la *figura 56* el modelo SVM muestra en el eje Y la información verdadera y en el eje X la información que el modelo es capaz de predecir. Es decir, de todas las muestras el modelo SVM fue capaz de predecir con el 97% de precisión.

Figura 56 Predicción mediante modelo SVM.




Nota: Resultados del proyecto con el modelo SVM. Fuente: (Autores, 2024)

KNN

De la misma forma el modelo KNN realiza la matriz indicando el 100% de confiabilidad lo que llega a resultar un error, como se muestra en la *figura 57*. Esto se genera debido a que el modelo funciona con corrección en solamente en los datos adquiridos para este experimento, pero al añadir datos distintos el modelo se inhabilita.

Figura 57 Predicción mediante modelo KNN.




Nota: Resultados del proyecto con el modelo KNN. Fuente: (Autores, 2024)

Redes neuronales

En la *figura 58* se muestra que el modelo de predicción basado en redes neuronales presenta el 99% de confiabilidad. Es decir, de toda la toma muestral el modelo fue capaz de interpretar el 99% de los resultados.

Figura 58 Predicción mediante modelo de redes neuronales.



Nota: Resultados del proyecto con el modelo de redes neuronales. Fuente: (Autores, 2024)

A continuación, se tabularon los resultados de los modelos de predicción con aprendizaje automático como se muestra en la *tabla 12*:

Tabla 12 *Tabla de Resultados del aprendizaje automático.*

Parámetros	Tiempo de entrenamiento	Porcentaje de confiabilidad
Árboles de decisión	2.2756 segundos	99.3%
SVM (Support Vector Machine)	104.82 segundos	97.8%
KNN (k-nearest neighbor classification)	239.6 segundos	100%
Neural Network	162.7 segundos	99.8%

Nota: Resultados del machine learning. Fuente: (Autores, 2024)

Como se evidencia el modelo KNN tuvo un porcentaje de confiabilidad del 100 % pero no se eligió este modelo ya que señala que hubo un sobreajuste, indicando que con los datos de entrenamiento se adaptaron muy bien provocando que con datos actualizados no pueda predecir correctamente y por ello sea menos confiable y por ello se ajusta el modelo SVM de mejor manera debido a su eficiencia del 97,8% de confiabilidad indicando que brinda una predicción más equilibrada entre precisión y su habilidad para generalizar nuevos datos. Además, si se realizan alteraciones al conjunto de datos no afecta en el rendimiento del modelo lo que representa una cualidad irrelevante para predicción de fallas.

Determinación de Emisiones

Con los datos adquiridos se ha realizado la estimación de emisiones contaminantes en los distintos periodos de conducción. A continuación, se muestra la gráfica de las emisiones contaminantes.

Se evidencia en la gráfica 59 que las emisiones se pueden estimar en función de los parámetros adquiridos durante del ciclo de conducción del vehículo Kia Sportage, como se muestra la influencia y afectación de cada uno de los fallos provocados en comparación con la representación gráfica del funcionamiento normal.


Se muestra en la estimación del CO₂ en la gráfica superior derecha como la contaminación en g/km tiene 13% de superioridad con la falla 2 en comparación con el funcionamiento normal. Además, la falla 1 muestra mayor emisión superando alrededor del 21% al funcionamiento normal esto debido a la influencia de la obstrucción de oxígeno a la cámara de combustión afectando la dosificación de la mezcla aire-combustible.

La emisión de la figura superior derecha presenta la contaminación emitida por el vehículo respecto a los óxidos nitrosos, los cuales al mostrarse en presencia de la falla 1 aumentan significativamente el 10% respecto a la emisión en condiciones de operación normal. Del mismo modo la falla 2 aumenta levemente respecto a las condiciones normales.

La figura inferior izquierda detalla la emisión de monóxido de carbono demostrando ventaja en la contaminación en presencia de la falla 1 ya que el vehículo emite 60% más que la operación normal.

Finalmente, la imagen inferior evidencia como la emisión de hidrocarburos no combustionados es modificado directamente gracias a la falla 1 siendo esta la que más afecta al comportamiento del vehículo.

Figura 59 Estimación de factores de emisión.



Nota: Factores de emisiones. Fuente: (Autores, 2024)

Conclusiones

Durante el desarrollo del proyecto se lograron las siguientes conclusiones en correlación a los lineamientos definidos anteriormente:

- Al establecer un plan sobre mantenimiento predictivo en un vehículo Kia Sportage clasificado como tipo M1, se aborda la deficiencia de los métodos de reparación actual. Aplicando la metodología AMFEC, se determina los modos de falla del sistema de inyección. El índice de ocurrencia de fallos en el vehículo se determinó mediante los parámetros del IPR, basados en la severidad y la probabilidad de ocurrencia. La falla de la bujía tiene un índice de prioridad de riesgo (IPR) de 360 que supera en un 50% al de la obstrucción en el filtro de aire ya que presenta IPR de 240 indicando que se debe priorizar la predicción de esta falla.
- Mediante la matriz de correlación se muestra las variables que inciden directamente en el rendimiento del vehículo las cuales son MAP, STFT y LTFT para posteriormente realizar el análisis predictivo mediante herramientas de aprendizaje automático.
- En cuanto a los modelos predictivos basados en la lectura de las señales PID's y en la emisión de gases contaminantes tomadas en g/ km mediante algoritmos de aprendizaje automático se realizó modelos predictivos de fallos SVM, Árboles de decisión, KNN y redes neuronales siendo efectivo el modelo entrenado SVM con un porcentaje del 97,8% de confiabilidad.
- En definitiva, al ocupar la metodología AMFEC nos ofrece la posibilidad de desarrollar estrategias de mantenimiento predictivo más efectivas, con el fin de evitar anomalías en el sistema ya que conducen a pérdidas de potencia y elevación de gases contaminantes.

Recomendaciones

- Para la realización del presente proyecto, se ocupó dispositivos de recolección de datos como es el Freematics que son indispensables para el desarrollo del estudio y análisis, se recomienda configurar los dispositivos para que en cualquier vehículo se pueda tomar datos y así proporcionar la adquisición y procesamiento de datos.
- Con base en las predicciones de fallos, se aconseja establecer un plan de mantenimiento predictivo personalizado para el vehículo, considerando las tendencias identificadas y las recomendaciones de intervención preventiva.
- Dada la confiabilidad de los modelos de inteligencia artificial utilizados en la predicción de fallos, se recomienda explorar la integración de otras técnicas avanzadas de aprendizaje automático, para mejorar la precisión en la detección de fallos incipientes.
- A partir de los resultados de la predicción, se propone realizar análisis del modelo predictivo en diferentes ciclos de conducción, considerando diversas fallas en los sistemas del vehículo y la variabilidad de las condiciones del automóvil.

Referencias

- Aguilar, A., & Tandazo, L. (2017). *ANÁLISIS DE MODOS DE FALLA, EFECTOS Y CRITICIDAD (AMFEC) DEL SISTEMA DE INYECCIÓN DE UN MOTOR DE ENCENDIDO PROVOCADO CORSA EVOLUTION 1.4L EMPLEANDO HERRAMIENTAS DE APRENDIZAJE Y CLASIFICACIÓN PARA LA PROGRAMACIÓN DEL MANTENIMIENTO*.
<http://dspace.ups.edu.ec/handle/123456789/14606>
- Aguilar, J., Torres, R., & Magaña, D. (2010). Análisis de modos de falla, efectos y criticidad (AMFEC) para la planeación del mantenimiento empleando criterios de riesgo y confiabilidad. In *Ciencia Ed. (IMIQ)* (Vol. 25, Issue 1).
<https://www.redalyc.org/pdf/482/48215094003.pdf>.
- Al-Zeyadi, M., Perez, J., Hagra, H., Royce, C., Smith, D., Rzonowski, P., & Malik, A. (2020). *Deep Learning Towards Intelligent Vehicle Fault Diagnosis*.
<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9206972&isnumber=9206590>
- Apolo, V., & Gordillo, D. (2017). *DETERMINACIÓN DE LA FIABILIDAD DE UN MOTOR CORSA EVOLUTION 1.4L A PARTIR DEL ANÁLISIS DE MODOS DE FALLAS EN LÍNEA BASADO EN LA DISTRIBUCIÓN DE WEIBULL*.
<http://dspace.ups.edu.ec/handle/123456789/14926>
- Belloví, M., Ramos, R., & París, C. (2004). *Análisis modal de fallos y efectos. AMFE*.
https://www.insst.es/documents/94886/326775/ntp_679.pdf/3f2a81e3-531c-4daa-bfc2-2abd3aaba4ba
- Booster, B. (2023). *Sensores de Oxígeno*.
<https://www.bing.com/ck/a?!&&p=b4c8e2d0817a8a8eJmltdHM9MTcxOTk2NDgwMCMZpZ3VpZD0wYWQyZGFINC05ZjEyLTZiMzctMGQ3Mi1jOTkxOWVhNTZhZTImaW5zaWQ9NTIzOQ&ptn=3&ver=2&hsh=3&fclid=0ad2dae4-9f12-6b37-0d72-c9919ea56ae2&psq=Sensores+de+Ox%c3%adgeno+Beto+Booster&u=a1aHR0cHM6Ly9hdXRvbWVjYW5pY28uY29tL2F1dG8yMDI3L2Jib29zdGVyMTIucGRm&ntb=1>
- Calderón, A. (2012). *OPTIMIZACIÓN DE LA POTENCIA EN UN MOTOR DE COMBUSTIÓN INTERNA GASOLINA MEDIANTE EL CONTROL DE AJUSTES DE COMBUSTIBLE Y EL MONITOREO DEL SENSOR DE OXÍGENO*.
<http://repositorio.espe.edu.ec/handle/21000/5483>
- Comisión Europea. (2016). *Euro 6*.
- Fernández, I., & Inga, H. (2017). *ANÁLISIS DE MODOS DE FALLA DEL SISTEMA DE INYECCIÓN ELECTRÓNICA DE COMBUSTIBLE MULTEC DELPHI*.
<http://dspace.ups.edu.ec/handle/123456789/13468>

- Freematics. (2024, July 4). *Freematics ONE+ Modelo B*.
<https://freematics.com/products/freematics-one-plus-model-b/>
- Gárate, D. (2018). *DESARROLLO DE UN ALGORITMO PARA LA ADQUISICIÓN Y ALMACENAMIENTO DE DATOS PROVENIENTES DEL SISTEMA DE DIAGNÓSTICO A BORDO OBD II*.
<http://dspace.ups.edu.ec/handle/123456789/16587>
- Google Maps. (2024, July 4). *Google Maps*. <https://www.google.com/maps/@-2.9132098,-79.0079942,15z?entry=ttu>
- Hurtado, L., Villarreal, E., & Villarreal, L. (2016). Detección y diagnóstico de fallas mediante técnicas de inteligencia artificial, un estado del arte. *DYNA (Colombia)*, 83(199), 19–28. <https://doi.org/10.15446/dyna.v83n199.55612>
- INEC. (2024, July 4). *Población y Demografía*.
<https://www.ecuadorencifras.gob.ec/censo-de-poblacion-y-vivienda/>
- Jiménez, E., & Cárdenas, J. (2023). *MODELO PARAMÉTRICO PARA LA ESTIMACIÓN DE EMISIONES CONTAMINANTES EN VEHÍCULOS M1 CICLO OTTO CON OBD-II*. <http://dspace.ups.edu.ec/handle/123456789/25589>
- Kane. (2024, July 4). *KANE EN VIVO*. <https://www.kane.co.uk/products/software/kane-live>
- MathWorks. (2024a, July 4). *Árboles de decisión*.
<https://la.mathworks.com/help/stats/decision-trees.html>
- MathWorks. (2024b, July 4). *Clasificación de máquinas de vectores de apoyo*.
<https://la.mathworks.com/help/stats/support-vector-machine-classification.html>
- MathWorks. (2024c, July 4). *ClassificationKNN*.
<https://la.mathworks.com/help/stats/classificationknn.html>
- MathWorks. (2024d, July 4). *Redes neuronales*.
<https://la.mathworks.com/help/stats/neural-networks-for-classification.html>
- Molina, J. (2020). *Driving Mode Estimation Model Based in Machine Learning Through PID's Signals Analysis Obtained From OBD II* (M. Botto-Tobar, M. Zambrano Vizuite, P. Torres-Carrión, S. Montes León, G. Pizarro Vásquez, & B. Durakovic, Eds.; Vol. 1194). Springer International Publishing.
<https://doi.org/10.1007/978-3-030-42520-3>
- Molina, P. (2023). *ESTIMACIÓN DEL CONSUMO DE COMBUSTIBLE A TRAVÉS DE LAS SEÑALES PID'S MEDIANTE LA UTILIZACIÓN DEL CICLO DE EMISIONES REALES EN LA CIUDAD DE QUITO-ECUADOR*.
<http://dspace.ups.edu.ec/handle/123456789/25028>
- NATIONAL INSTRUMENTS. (2024, July 4). *Adquisición de datos (DAQ)*.
- Pacho, G., & Tacuri, E. (2020). *ANÁLISIS DE MODOS DE FALLO AMFEC DE UN MOTOR AVEO 1.4L, MEDIANTE FRAGMENTACIÓN DE MICROCICLOS EN*

FUNCIÓN DE LAS SEÑALES PID'S.

<http://dspace.ups.edu.ec/handle/123456789/19548>

- Rivera, N., Molina, P., Bermeo, A., Bermeo, O., & Figueroa, J. (2022). Driving Style Analysis by Studying PID's Signals for Determination of Its Influence on Pollutant Emissions. *Smart Innovation, Systems and Technologies*, 252, 321–331. https://doi.org/10.1007/978-981-16-4126-8_30
- Rivera-Campoverde, N. D., Muñoz-Sanz, J. L., & Arenas-Ramirez, B. D. V. (2021). Estimation of pollutant emissions in real driving conditions based on data from OBD and machine learning. *Sensors*, 21(19). <https://doi.org/10.3390/s21196344>
- Rodríguez, J. (2013). *Mantenimiento de sistemas auxiliares del motor de ciclo Otto* (IC Editorial).
- Romero, L. (2016). *GAS NATURAL COMO ALTERNATIVA ENERGÉTICA DEL TRANSPORTE TERRESTRE PARA REDUCIR LA EMISIÓN DEL DIÓXIDO DE CARBONO EN HUÁNUCO*. <https://hdl.handle.net/20.500.13080/1921>
- SAE. (2024, July 4). *Norma SAE JA 1011 - Criterios Para Evaluar Procesos RCM (002)*. <https://studylib.es/doc/9110815/norma-sae-ja-1011---criterios-para-evaluar-procesos-rcm---...>
- Sandoval, L. (2018). *ALGORITMOS DE APRENDIZAJE AUTOMÁTICO PARA ANÁLISIS Y PREDICCIÓN DE DATOS* (Vol. 11). <http://redicces.org.sv/jspui/handle/10972/3626>
- Secretaría Nacional de Planificación. (2024, July 4). *Metodologías*. <https://www.planificacion.gob.ec/metodologias/>
- Torres, E. (2017). *SISTEMA DE DIAGNÓSTICO AUTOMOTRIZ MEDIANTE EL ANÁLISIS DE EMISIONES CONTAMINANTES CON LA APLICACIÓN DE REDES NEURONALES PARA LA DETECCIÓN DE FALLAS*. <http://dspace.ups.edu.ec/handle/123456789/14914>
- Velepucha, J., & Sabando, L. (2021). Emisiones de gases contaminantes en vehículos livianos a gasolina. *Revista Científica INGENIAR: Ingeniería, Tecnología e Investigación*, 4(8), 78–95. <https://doi.org/10.46296/ig.v4i8.0024>
- Zhao, D., Liu, S., Miao, Z., Zhang, H., Wei, Y., & Xiao, S. (2022). A Novel Feature Extraction Approach for Mechanical Fault Diagnosis Based on ESAX and BoW Model. *IEEE Transactions on Instrumentation and Measurement*, 71. <https://doi.org/10.1109/TIM.2022.3185658>

Anexos

Figura 60 Proceso de adquisición de datos.



Nota: Proceso tanto para la adquisición y monitoreo de datos desde el vehículo. Fuente: (Autores, 2024)

Figura 61 Conexión del analizador de gases.



Nota: Conexión de la manguera del analizador de gases contaminantes. Fuente: (Autores, 2024)

Figura 62 Sonda del analizador de gases.



Nota: Sonda del analizador de gases contaminantes que se introduce en el escape para la adquisición de datos. Fuente: (Autores, 2024)