

ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE INGENIERÍA MECÁNICA

**“ESTUDIO DE LA SEÑAL DEL SENSOR DE OXÍGENO Y DE LOS
AJUSTES DE COMBUSTIBLE DE CORTO Y LARGO PLAZO
DEBIDO A LA INFLUENCIA DE LAS OPERACIONES DE
CONDUCCIÓN BASADOS EN ARQUITECTURAS DE
APRENDIZAJE AUTÓNOMO”**

**TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE
MAGISTER EN SISTEMAS AUTOMOTRICES**

LUIS ALFREDO GONZALEZ CASTRO

luis.gonzalez@epn.edu.ec

DIRECTOR:

ING. IVAN ZAMBRANO MSc.

CODIRECTOR:

ING. JORGE MARTINEZ MSc.

FECHA: ABRIL DE 2023

CERTIFICACIÓN

Certifico que el presente trabajo fue desarrollado por **Luis Alfredo González Castro**, bajo mi supervisión.

ING. IVAN ZAMBRANO

DIRECTOR DE PROYECTO

DECLARACIÓN

Yo, **Luis Alfredo González Castro**, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración cedo mis derechos de propiedad intelectual correspondiente a este trabajo, a la Escuela Politécnica Nacional, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normativa institucional vigente.

Luis Alfredo González Castro

DEDICATORIA

Dedico todo el esfuerzo de este tiempo a mi familia por su paciencia, amor y apoyo para el cumplimiento de este trabajo.

AGRADECIMIENTO

Agradezco a todos mis profesores y directivos de la maestría en especial al Ing. Iván Zambrano e Ing. Jorge Martínez por su acertada dirección y consejos brindados a lo largo de todo este tiempo.

ÍNDICE DE CONTENIDO

INTRODUCCIÓN	1
Objetivo general	2
Objetivos específicos	2
1. MARCO TEÓRICO	3
1.1. Sistema de inyección electrónica	3
1.1.1. Sensores	4
1.1.1.1 VSS	4
1.1.1.2 CKP	5
1.1.1.3 TPS	5
1.1.1.4 ECT	6
1.1.1.5 MAP	6
1.1.1.6 IAT	7
1.1.1.7 O2	7
1.1.1.8 STFT	8
1.1.1.9 LTFT	8
1.2. Sistema de diagnóstico a bordo OBDII	9
1.2.1. Enlace con la ECU	9
1.3. Parámetros de identificación	10
1.4. Aprendizaje automático.	13
Aprendizaje supervisado	14

1.4.1. Máquinas de soporte vectorial	15
Kernel en SVM	16
1.4.2. Árboles de decisión	16
1.4.3. Lógica difusa	17
1.4.4. Redes neuronales	19
Aprendizaje no supervisado	20
1.4.5. K-means	20
2. ADQUISICIÓN DE DATOS.	22
2.1. Planeación de la corrida experimental	22
2.1.1. Variables de entrada	23
2.1.2. Variables de bloqueo	24
2.1.3. Variables de ruido	24
2.1.4. Variables de respuesta	25
2.2. Tarjeta adquisidora de datos	25
2.2.1. Obtención de datos mediante L102 Ulbotech configurador	25
2.2.2. Vehículo de pruebas	27
2.2.3. Selección de rutas de pruebas	28
2.2.4. Protocolo para obtención de datos con dispositivo Ulbotech L102	30
2.3. Representación gráfica de variables obtenidas a través de L102 Configurator y Matlab®.	32
2.3.1. Velocidad del vehículo	32

2.3.2. Régimen de giro del motor	33
2.3.3 Posición del acelerador	34
2.3.4. Temperatura del refrigerante	35
2.3.5. Temperatura del aire de admisión	36
2.3.6. Presión absoluta del colector	37
2.3.7. Sensor de oxígeno	38
2.3.8. Ajuste de combustible a corto plazo	39
2.3.9. Ajuste de combustible a largo plazo	40
3. APLICACIÓN DE ALGORITMOS DE APRENDIZAJE AUTÓNOMO PARA LA DETECCIÓN DE OPERACIONES DE CONDUCCIÓN Y SU INFLUENCIA EN LOS AJUSTES DE COMBUSTIBLE.	42
3.1. Validación de los datos adquiridos	42
3.2. Representación de las señales en microciclos de conducción.	43
3.3. Extracción de características de las señales	43
3.3.1 Sensor de Oxígeno	44
3.3.2 Ajuste de combustible de corto plazo STFT	45
3.3.3 Ajuste de combustible de Largo plazo LTFT	47
3.3.4. MAP	48
3.3.5. TPS	49
3.3.6. Derivada del TPS	50
3.3.7 IAT	52

3.3.8 ECT	53
3.3.9 Velocidad	54
3.3.10 Aceleración	55
3.4 Aplicación de arquitecturas de aprendizaje automático	56
3.4.1 Estimación del umbral de control del Sensor de Oxígeno	56
3.4.2. Estimación del estado de funcionamiento	58
4. GENERACIÓN DE MODELOS MATEMÁTICOS	80
4.1. Modelación del algoritmo obtenido.	80
4.1.1 Sensor de oxígeno	80
4.1.2 Ajuste de Combustible de Corto Plazo STFT	85
4.1.3 Ajuste de Combustible de Largo Plazo LTFT	86
4.2. Aplicación del algoritmo obtenido	87
4.2.1. Generación de fallas	89
4.2.2. Análisis del comportamiento de la señal del sensor de oxígeno, STFT, LTFT	90
CONCLUSIONES	99
RECOMENDACIONES	100
BIBLIOGRAFÍA	101

INDICE DE FIGURAS

Figura 1. Procesamiento de señales en la unidad de control.	3
Figura 2. Señal del sensor VSS tipo hall.	4
Figura 3. Sensor CKP.	5
Figura 4. Sensor TPS.	6
Figura 5. Señal del sensor IAT.	7
Figura 6. (a) Sensor de oxígeno, (b) Ajuste de combustible a largo plazo, (c) Ajuste de combustible a corto plazo.	8
Figura 7. Pines del conector OBD II.	10
Figura 8. Vector de n dimensiones.	15
Figura 9. El truco de Kernel.	16
Figura 10. Árboles de decisión.	17
Figura 11. Lógica difusa.	17
Figura 12. Estructura general de un controlador difuso.	18
Figura 13. Red neuronal totalmente conectada.	19
Figura 14. Iteraciones de k-means.	21
Figura 15. Proceso de adquisición de datos.	21
Figura 16. Variables involucradas en el experimento.	22
Figura 17. Dispositivo Ulbotech L102.	24
Figura 18. Vehículo utilizado para los recorridos.	26
Figura 19. Monitoreo de rutas.	28
Figura 20. L102 Configurator V1.007.	30
Figura 21. Datos obtenidos del sensor de velocidad.	32
Figura 22. Datos obtenidos del sensor CKP.	33
Figura 23. Datos obtenidos del sensor TPS.	34
Figura 24. Datos del sensor de temperatura del refrigerante.	35
Figura 25. Datos del sensor de temperatura del aire.	36
Figura 26. Datos obtenidos por el sensor MAP.	37
Figura 27. Datos obtenidos por el sensor de oxígeno.	38
Figura 28. Datos obtenidos del ajuste de combustible a corto plazo.	39
Figura 29. Datos obtenidos del ajuste de combustible a corto plazo.	40
Figura 30. Ciclo y microciclos de conducción.	42
Figura 31. Histograma de la señal del sensor de oxígeno.	43

Figura 32. Histograma de la señal del ajuste de combustible STFT.	44
Figura 33. Comportamiento del sensor de oxígeno.	46
Figura 34. Comportamiento de la señal LTFT.	47
Figura 35. Histograma de la señal del sensor MAP.	48
Figura 36. Histograma de la señal del sensor TPS.	49
Figura 37. Histograma de la derivada del TPS.	50
Figura 38. Histograma del sensor IAT.	51
Figura 39. Histograma del sensor ECT.	52
Figura 40. Histograma de la velocidad.	53
Figura 41. Histograma de la aceleración.	55
Figura 42. Señal del sensor de oxígeno durante la experimentación.	56
Figura 43. Diferenciación de grupos de mezcla.	57
Figura 44. Mezcla rica vs mezcla pobre.	58
Figura 45. Matriz de confusión del número de observaciones para la estimación de ralentí.	60
Figura 46. Curva ROC para la estimación de ralentí.	61
Figura 47. Algoritmo para ralentí.	62
Figura 48. Diagrama de velocidades.	63
Figura 49. Matriz de confusión.	64
Figura 50. Curva ROC.	65
Figura 51. Método de inferencia del conjunto difuso.	66
Figura 52. Función de membresía para aceleración, desaceleración y cruce.	67
Figura 53. Expresión gráfica de las reglas.	68
Figura 54. Validación del modelo difuso.	69
Figura 55. Función de membresía salida.	70
Figura 56. Calibración del estimador difuso.	70
Figura 57. Calibración del estimador difuso.	71
Figura 58. Histograma en función del TPS y velocidad de apertura del TPS.	72
Figura 59. Estimación del arranque en frío.	73
Figura 60. Estimación de la fase de calentamiento según Euro 6.	74
Figura 61. Estimación de la fase de calentamiento por K-means.	74
Figura 62. Red neuronal.	75
Figura 63. Resultados del entrenamiento de la red neuronal.	75
Figura 64. Validación de la red neuronal.	76
Figura 65. Matriz de validación.	77
Figura 66. Estimación de la fase de calentamiento por redes neuronales	78

Figura 67. Histograma de fase de calentamiento vs fase de funcionamiento en caliente.	78
Figura 68. Histograma del comportamiento del sensor de oxígeno.	79
Figura 69. Histograma de área unitaria de la tasa de variación del sensor de oxígeno en ralentí y todos los regímenes	80
Figura 70. Histograma de área unitaria del sensor de oxígeno en todos los regímenes, aceleración, desaceleración y cruce.	81
Figura 71. Histograma de área unitaria de la señal del sensor de oxígeno en todas las marchas y 1°, 2°, 3°, 4° Y 5° marcha.	82
Figura 72. Histograma de área unitaria del sensor de oxígeno en la fase de calentamiento.	83
Figura 73. Histograma de área unitaria de la señal del sensor de oxígeno en todas las marchas y en tercera.	84
Figura 74. LTFT en la fase de calentamiento y funcionamiento en caliente.	84
Figura 75. Histograma de área unitaria del ajuste de combustible a corto plazo en todos los regímenes, aceleración, desaceleración y cruce.	85
Figura 76. Histograma de área unitaria del ajuste de combustible a largo plazo en todos los regímenes, aceleración, desaceleración y cruce.	86
Figura 77. Esquema de generación de fallas.	87
Figura 78. Falla 1 Obstrucción del filtro de aire.	88
Figura 79. Calibración de las bujías.	89
Figura 80. Extracto de la señal del sensor de oxígeno con motor OK	89
Figura 81. Extracto de la señal del sensor de oxígeno con el filtro de aire obstruido	90
Figura 82. Sensor de oxígeno durante operación normal y mezcla rica.	91
Figura 83. STFT en operación normal y mezcla rica	92
Figura 84. LTFT en operación normal y falla mezcla rica.	93
Figura 85. Extracto de la señal del sensor de oxígeno con bujías abiertas	94
Figura 86. Señal del Sensor de oxígeno durante su operación normal y cuando falla la bujía	95
Figura 87. Señal del STFT durante operación normal y con falla en la bujía	96
Figura 88. Señal LTFT Operación normal y falla en la bujía	97

LISTA DE FIGURAS

Tabla 1. Modos de operación OBD II.	11
Tabla 2. PIDs para modo 01 de operación.	12
Tabla 3. Variables de entrada.	22
Tabla 4. Variables de bloqueo.	23
Tabla 5. Variables de ruido.	23
Tabla 6. Variables de salida.	24
Tabla 7. Especificaciones del dispositivo Ulbotech L102.	25
Tabla 8. Ficha técnica del vehículo	26
Tabla 9. Valores máximos y mínimos de los parámetros.	30
Tabla 10. Resultados de la corrida experimental.	41
Tabla 11. Estadísticos descriptivos de la señal del sensor de oxígeno	43
Tabla 12. Estadísticos descriptivos del ajuste de combustible de corto plazo.	46
Tabla 13. Estadísticos descriptivos del ajuste de combustible de corto plazo	47
Tabla 14. Estadísticos descriptivos del sensor MAP.	48
Tabla 15. Estadísticos descriptivos del TPS.	49
Tabla 16. Estadísticos descriptivos del ajuste de combustible de corto plazo.	51
Tabla 17. Estadísticos descriptivos del sensor IAT.	52
Tabla 18. Estadísticos descriptivos del ECT.	53
Tabla 19. Estadísticos descriptivos de la velocidad.	54
Tabla 20. Estadísticos descriptivos del ajuste de aceleración.	55
Tabla 21. Relaciones de transmisión	62

RESUMEN

La presente investigación versa de la adaptación de arquitecturas de aprendizaje automático para la identificación de diferentes operaciones de conducción y de sus efectos sobre los PIDs debido a la influencia que estas tienen sobre el comportamiento del motor. A través de una revisión bibliográfica se justifica que dentro de los PIDs más utilizados para el diagnóstico de sistemas de inyección se encuentran la señal del Sensor de Oxígeno y los ajustes de combustible de corto y largo plazo. Estas variables se ven alteradas por las características ambientales de ciudades de altura como Cuenca por lo que los datos patrón y los comportamientos dinámicos de las señales no son los mismos que a nivel del mar, por lo que se busca determinar el normal comportamiento de los mencionados PIDs durante distintas operaciones de conducción como el arranque, aceleración, desaceleración y velocidad de crucero. Para tal efecto se demuestra que la aplicación de diferentes arquitecturas de aprendizaje automático como son la lógica difusa, redes neuronales, máquinas de soporte vectorial, K-means y árboles de clasificación sirven para la detección y clasificación de diferentes maniobras de conducción.

En el capítulo 2 se desarrolla la metodología para la adquisición de datos, basada en una data Logger de uso genérico Ulbotech L102, que adquiere y almacena los Parámetros de Identificación durante los ciclos de conducción mantenidos. Para el desarrollo de la corrida experimental se determinan las variables de estudio, entrada, bloqueo y ruido aplicadas a un ciclo normalizado de conducción RDE (Real Driving Emissions) basada en la normativa Euro 6. La corrida experimental se realizó en el vehículo sedán más vendido en la última década en Ecuador.

El capítulo 3 indica la verificación de los datos mediante la comparación de los valores medidos y los límites impuestos en la norma SAE J1979, para luego extraer las propiedades de las señales en el dominio del tiempo y determinar los estadísticos descriptivos de tendencia central y dispersión en todo el ciclo de conducción. Se continúa con la aplicación de arquitecturas de aprendizaje automático para la estimación del umbral de control del sensor de oxígeno y a posteriori de las maniobras de conducción a partir de la aplicación de árboles de clasificación para estimación del ralentí, máquinas de soporte vectorial para la determinación de la marcha seleccionada por el conductor, lógica difusa

para evaluar el estado de circulación, k-means y redes neuronales para determinar el funcionamiento en caliente o en fase de calentamiento.

Finalmente se generan los modelos matemáticos a ser aplicados para la extracción de características de las señales del sensor de oxígeno y de los ajustes de corto y largo plazo, durante diferentes condiciones de funcionamiento. Se genera una base de datos que servirá como fundamento para la detección y el diagnóstico de posibles comportamientos anómalos del sistema de inyección de combustible. Para verificar la validez del algoritmo obtenido se generan dos fallas comunes en el motor como son el enriquecimiento de la mezcla por el uso de un filtro de aire contaminado y el uso de bujías en mal estado. Tras el análisis de los resultados se determinó que el algoritmo obtenido es sensible a la detección de fallas que no generan código de avería, por lo cual se recomienda continuar con la generación de conocimiento para establecer un algoritmo sensible a muchos otros fallos.

ABSTRACT

The present research deals with the application of machine learning architectures for the identification of different driving operations and their effects on PIDs due to the influence they have on engine behavior.

Through a bibliographic review it is justified that among the most used PIDs for the diagnosis of injection systems are the signal of the Oxygen Sensor and the short and long term fuel adjustments. These variables are altered by the environmental characteristics of high-altitude cities such as Cuenca, so the standard data and the dynamic behavior of the signals are not the same as at sea level, which is why we seek to determine the normal behavior of those mentioned. PIDs during different driving operations such as starting, acceleration, deceleration and cruising speed. For this purpose, it is shown that the application of different machine learning architectures such as fuzzy logic, neural networks, vector support machines, K-means and classification trees serve for the detection and classification of different driving maneuvers.

In chapter 2 the methodology for data acquisition is developed, based on a generic Ulbotech L102 data Logger, which acquires and stores the Identification Parameters during the maintained driving cycles. For the development of the experimental run, the study variables, input, blocking and noise applied to a normalized driving cycle RDE (Real Driving Emissions) based on the Euro 6 standard are determined. The experimental run was carried out in the best-selling sedan vehicle in the last decade in Ecuador.

Chapter 3 shows the validation of the data obtained by comparing the measured values and the limits imposed in the SAE J1979 standard, to then extract characteristics of the signals in the time domain and determine the descriptive statistics of central tendency and dispersion in the entire driving cycle. It continues with the application of machine learning architectures for the estimation of the oxygen sensor control threshold and subsequent to the driving maneuvers from the application of classification trees to estimate the idle speed, vector support machines for the determination of the gear selected by the driver, fuzzy logic to evaluate the state of movement, k-means and neural networks to determine the hot operation or in the warm-up phase.

Finally, the mathematical models are generated to be applied for the extraction of characteristics of the oxygen sensor signals and of the short and long-term adjustments, during different operating conditions. A database is generated that will serve as a basis for the detection and diagnosis of possible abnormal behavior of the fuel injection system.

To verify the validity of the algorithm obtained, two common failures are generated in the engine, such as the enrichment of the mixture due to the use of a contaminated air filter and the use of spark plugs in poor condition. After analyzing the results, it was determined that the algorithm obtained is sensitive to the detection of faults that do not generate a fault code, therefore it is recommended to continue with the generation of knowledge to establish an algorithm that is sensitive to many other faults.

INTRODUCCIÓN

Los sistemas de gestión electrónica para la verificación de la relación aire combustible conocidos de forma general como sistemas de inyección electrónica, utilizan sensores para determinar el estado del motor en tiempo real; basada en este estado la Unidad de Control Electrónico establece el combustible necesario que debe aportar a cada cilindro acorde a los requerimientos que el motor demande en ese instante.

La mayoría de estos sistemas utilizan sensores de oxígeno de banda estrecha para la retroalimentación del lazo de control, mismo que para ser robusto frente a perturbaciones se basa en ajustes de corto y largo plazo.

Las perturbaciones que contribuyen en el funcionamiento de la ECU pueden ser provocadas por factores internos o externos, generalmente asociados al funcionamiento y desempeño del motor y por ende del vehículo. Cualquier evento o circunstancia que altere el normal desempeño del motor provocará que el sensor de oxígeno detecte dichas anomalías por la cual ECU buscará un nuevo punto de funcionamiento modificando el valor de los ajustes de combustible acorde a las necesidades del motor.

No todas las averías que se pueden presentar en el sistema producen un código de avería que permita su detección y el posterior diagnóstico, existen un sin número de fallas que no pueden ser detectadas aún más en etapa incipiente, por lo que el consumo, las prestaciones y gases contaminantes generados pueden verse afectados sin que el conductor reciba advertencia alguna. Por ello es importante conocer el comportamiento normal de la señal del sensor de oxígeno y de los ajustes de combustible de corto y largo plazo durante todas las etapas de funcionamiento del motor, esta información permitirá detectar y diagnosticar fallas en etapa incipiente disminuyendo los tiempos y costos de mantenimiento de las unidades vehiculares.

Al tratarse de una gran cantidad de datos resulta poco práctico segregarse dichas señales de manera manual, por lo que se busca generar herramientas basadas en aprendizaje autónomo para la segregación de dichas señales de forma, conllevando esto a generar conocimiento del comportamiento del vehículo bajo las condiciones especiales que presenta nuestro entorno.

Objetivo general

Estudiar la influencia que tienen las operaciones de conducción en la señal del sensor de oxígeno y los ajustes de combustible de corto y largo plazo en un motor ciclo Otto de inyección electrónica mediante la aplicación de arquitecturas de aprendizaje autónomo.

Objetivos específicos

- Establecer una metodología para la realización de la adquisición de datos
- Aplicar algoritmos de aprendizaje autónomo para determinar operaciones de conducción como arranque, aceleración, velocidad de crucero y desaceleración.
- Realizar el procesamiento de los datos obtenidos para establecer la influencia de las variables de estudio en los ajustes de combustible de corto y largo plazo.
- Generar un Modelo Matemático basado en matrices de comparación.
- Establecer conclusiones, recomendaciones y proponer futuros trabajos.

1. MARCO TEÓRICO

1.1. Sistema de inyección electrónica

Los vehículos modernos presentan exigencias a nivel mundial sobre gases de escape, economía de combustible, aumento potencia, etc, las cuales el antiguo carburador ya no suple, debido a que no puede brindar una mezcla ideal de aire- combustible. Se corrobora y se desarrollan sistemas de inyección electrónica para mezclar 14.7 gr de aire por cada gr de combustible, buscando mayor rendimiento y ahorro en distintos regímenes del motor. (Sánchez & Delgado, 2012).

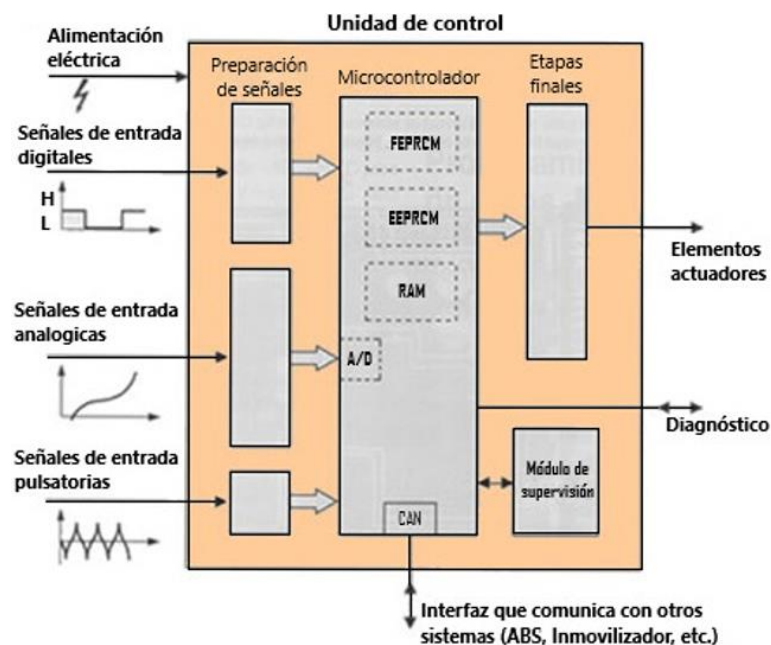


Figura 1. Entrada y salida de señales en la unidad de control.

Fuente: (Booster, 2016).

- **Unidad de control electrónico**

La ECU es un elemento que actúa como centro de control, toma las señales de los sensores instalados en las diferentes partes del motor, analiza, procesa y compara las señales de entrada de los sensores con la información ya programada de fábrica y

determina con exactitud la mezcla combustible-aire, óptima, adicionalmente envía una respuesta en forma de señal eléctrica a los actuadores como se indica en la figura 1.

Para extraer señales con comportamiento variable en tensión se utiliza un osciloscopio, mientras que al utilizar un escáner se establece comunicación a través del conector de diagnóstico OBDII para recoger parámetros de sensores y actuadores, códigos de avería, etc.

1.1.1. Sensores

1.1.1.1. VSS

El sensor de velocidad es un detector magnético que actualmente puede ser de efecto Hall o inductivo, su función es informar mediante la generación de una onda senoidal de corriente alterna al módulo de control, midiendo la velocidad de salida del transeje y la velocidad de la rueda, de esta manera controla el velocímetro, el sistema de control de tracción–estabilidad o la transmisión automática, etc. La señal obtenida por el sensor VSS se muestra en la figura 2.

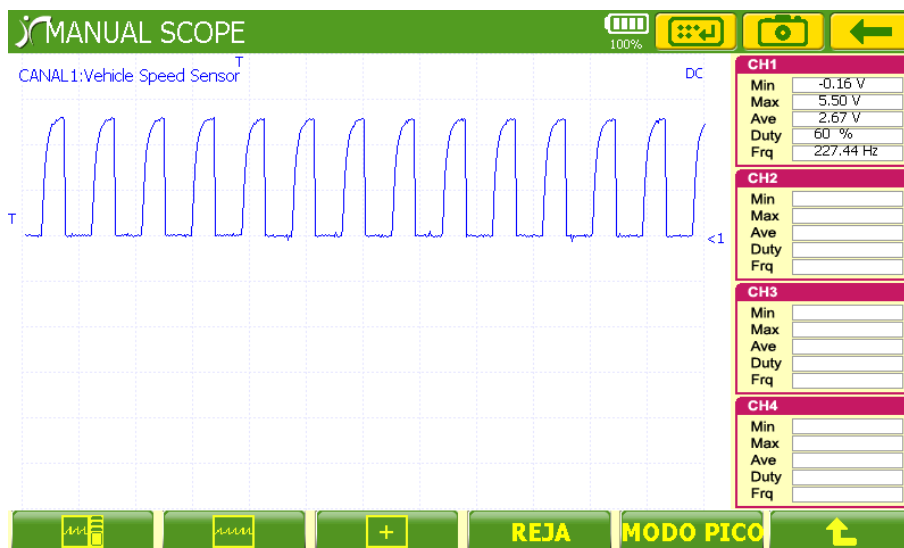


Figura 2. Tipo hall.

Fuente: Propia.

1.1.1.2. CKP

El sensor de posición del cigüeñal, ya sea magnético o de tipo Hall, genera un voltaje al girar frente al engranaje faltante del cigüeñal, transmitiendo información a la ECU y al módulo de encendido sobre la posición de los pistones. Con esta información, la ECU calcula las RPM del motor y determina el momento preciso de la inyección y su duración (Booster, 2016). Dicha señal se muestra en la Fig.3.




Figura 3. Sensor CKP.

(Fuente: Propia).

1.1.1.3. TPS

El Sensor de Posición del Acelerador monitorea la posición del acelerador en la válvula de mariposa de admisión del motor, enviando señales eléctricas a la ECU. La ECU utiliza esta información para ajustar la inyección de combustible en la cámara de combustión, en función de la aceleración o desaceleración del vehículo. El rango de apertura del acelerador puede variar de 0 a 100%, dependiendo del porcentaje de apertura, la señal se muestra en la Figura 4, panel a.




Figura 4. Sensor TPS.

Fuente: Propia.

1.1.1.4. ECT

El sensor de temperatura del refrigerante del motor envía información a la ECU sobre su temperatura para ajustar la inyección de combustible y el tiempo de encendido. La ECU evalúa los niveles de voltaje del sensor, que están relacionados con la temperatura del refrigerante, generando una señal de voltaje en un rango de 0 a 5V como se muestra en la Figura 4 imagen b.

1.1.1.5. MAP

Un elemento piezoeléctrico conocido como Sensor de Presión del Múltiple, también se deforma cuando hay una variación de presión (positiva o negativa) en él, cambiando la resistencia y resultando en una variación de voltaje en la entrada. Dependiendo de la lectura de presión en el colector, el valor devuelto a la ECU variará de 0 a 5 V. Mientras que el ralentí corresponde a un voltaje entre 0 y 1 puntos 5 voltios, la aceleración ocurre entre 1 y 4 puntos 8 voltios, y la aceleración completa ocurre en alrededor de 5 puntos 0 voltios. La imagen c de la figura 4 demuestra la señal.

1.1.1.6. IAT

El sensor de temperatura del aire de admisión mide la temperatura del colector de admisión. La señal se muestra en la figura 5 después de que la unidad de control evalúa los valores de voltaje (valores altos de voltaje indican temperaturas bajas y viceversa).

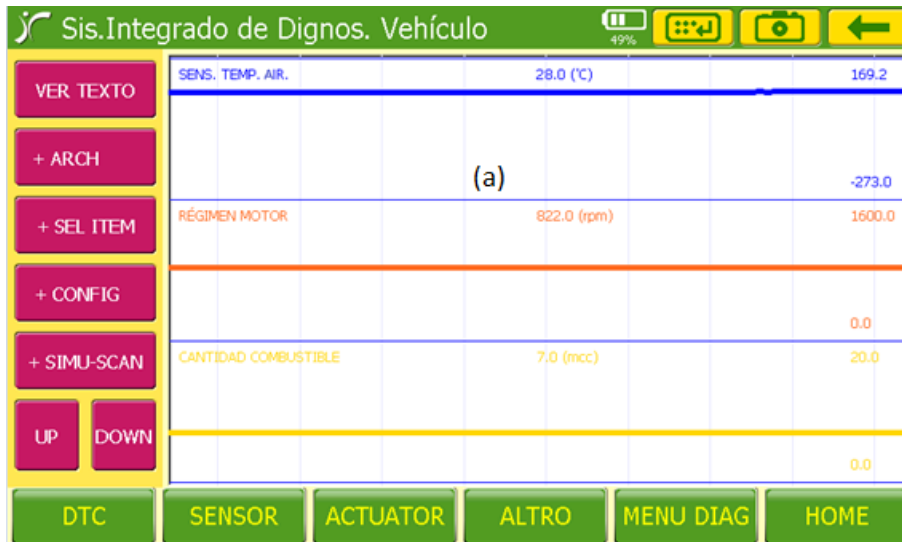


Figura 5. Señal del sensor IAT.

Fuente: Propia.

1.1.1.7. O2

El sensor de oxígeno es un miembro del sistema de escape de un vehículo que se coloca antes y después del catalizador para medir la cantidad de oxígeno en los gases que se emiten. Está compuesto por dos electrodos, uno en contacto con el aire y otro en contacto con los gases, separados por un electrolito cerámico. Los electrodos capturan iones de oxígeno, lo que genera una diferencia de voltaje entre ellos (conocida como diferencia cero) que varía de 0 a 1 voltio. Esta diferencia de voltaje es informada a la (ECU), que regula la cantidad de combustible a inyectar en el motor. La sonda brinda una señal eléctrica que se envía a la ECU, indicando la diferencia de oxígeno entre las dos secciones del sensor. Con esta información, la ECU ajusta la mezcla de aire y combustible para mantener una combustión eficiente (Concepción, 2011).

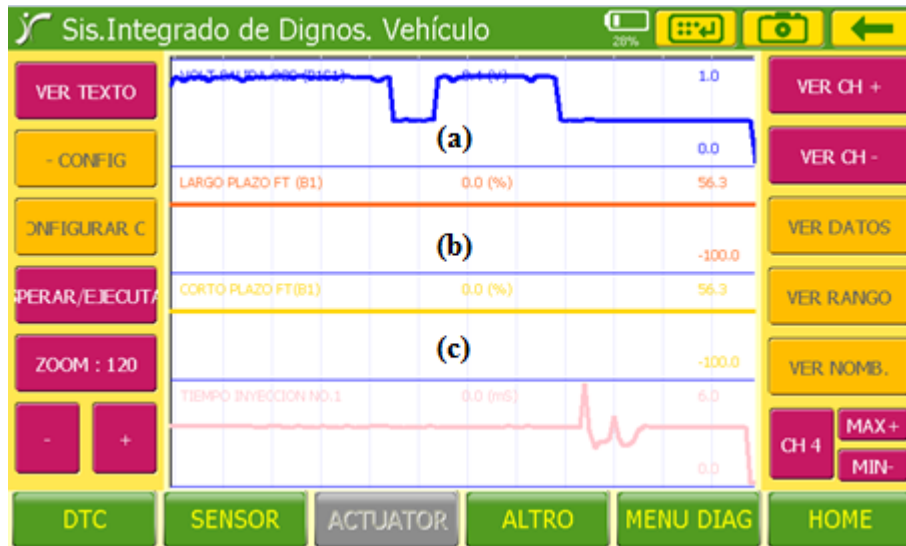


Figura 6. (a) Sensor de oxígeno, (b) Ajuste de combustible a largo plazo, (c) Ajuste de combustible a corto plazo.

Fuente: Propia.

1.1.1.8. STFT

Al ajustar el ancho de pulso de los inyectores para nivelar la mezcla estequiométrica de acuerdo con el promedio de cambios en el voltaje del sensor de oxígeno, la señal de STFT de la ECU, que se muestra en la figura 6, imagen c, señala la compensación. La STFT, que solo puede corregir en un corto período de tiempo, comienza con un valor 0 que representa la mezcla estequiométrica y luego ajusta el sistema para enriquecerla o empobrecerla. Sin embargo, existen valores límite superior e inferior para las correcciones que puede lograr el programa STFT (Calderón F, 2012).

1.1.1.9. LTFT

Genera una base de datos referente a las correcciones realizadas por el sensor de oxígeno, los ajustes LTFT varían dependiendo las RPM, la carga, la calidad del combustible, la temperatura ambiente y son almacenados memoria (KAM), estos valores son agregados al STFT (Díaz, 2012). Cuando la ECU determina que un motor está en mal estado, se basa en su tabla de búsqueda interna para analizar si existe almacenado un LTFT para esa situación. Si es así, entrega de forma automática un ajuste LTFT almacenado. La señal obtenida se indica en la figura 6 imagen b.

1.2. Sistema de diagnóstico a bordo OBDII

Es el responsable de monitorear todos los sistemas funcionales del vehículo, controlando de manera correcta el funcionamiento de todos los sensores que intervienen en la emisión contaminante, se encarga también de almacenar códigos de errores referentes a fallas en el sistema para avisar al conductor cuando el nivel de gases esté por encima de los límites establecidos (Arévalo & Ortega, 2016). A continuación, se mencionan sus características:

- Lleva un registro de los problemas que tiene el automóvil.
- Todos los vehículos, ya sea que funcionen con gasolina, diésel u otro combustible alternativo, cumplirán con las normas OBD2.
- Para cada vehículo dispone de un conector y protocolo estandarizados.

1.2.1. Enlace con la ECU

A pesar de que existen diferentes protocolos que permiten que el OBD II y la ECU se conecten entre sí, cada fabricante utiliza solamente un protocolo, se presentan los 5 protocolos a continuación.

- ISO9141-2: vehículos europeos y asiáticos
- ISO14230: Renault
- SAE J1850 PWM: Mazda y Ford Motor Company
- SAE J1850 VPW: General Motors
- KWP 1281 y KWP 2000: Grupo VGA

El conector OBD II tiene 16 pines estandarizados que se representan en la figura 7.




Figura 7. Pines del conector OBD II.

Fuente: (Arévalo & Ortega, 2016).

1. Opción para el elaborador
2. SAE-J1850 (BUS negativo)
3. Opción para el elaborador
4. Masa del vehículo
5. Masa de la señal
6. (J2284) CAN, línea alta
7. ISO 9141-2 (Línea K)
8. Opción para el elaborador
9. Opción para el elaborador
10. SAE-J1850 (BUS negativo)
11. Opción para el elaborador
12. Opción para el elaborador
13. Opción para el elaborador
14. (J2284) CAN, línea baja
15. ISO 9141-2 Línea L
16. Batería +

1.3. Parámetros de identificación

Los PIDs son datos proporcionados por los sensores en operación, existen 10 modos que permiten comunicarse con el sistema de diagnóstico, el primer byte de la cadena es el número del modo, indica el número de dato que se solicita, el segundo byte indica la información real necesaria conocidos también como identificación de parámetros PID, los cuales están en formato hexadecimal; la conversión a decimal se realiza mediante fórmulas establecidas.

Tabla 1. Modos operativos OBD II.

Modo(hex)	Descripción
01	Datos fácilmente disponibles
02	Información del cuadro de bloqueo
03	Códigos de diagnóstico que se han guardado
04	Elimina los códigos de diagnóstico almacenados

05	Información obtenida del seguimiento de los niveles de oxígeno en un proceso o sistema (no CAN).
06	Causado de otros componentes (solo CAN)
07	Durante el ciclo de manejo más reciente o anterior, se encontraron códigos de diagnóstico.
08	Compruebe las funciones de control del sistema de a bordo.
09	Solicitud de datos del automovil.
0A	Borrado del código de diagnóstico.

1.3.1. Modo 0x01 – Indicar información actual

Hay PID estandarizados para cada modo en OBD II, y cada respuesta se interpreta de manera diferente. Cuando se contacta a un PID para obtener información en tiempo real, enviará un valor hexadecimal que se convierte a decimal y luego se utiliza una fórmula para obtener el resultado en las dimensiones predeterminadas del PID. Los PID para el modo 01 de operación se muestran en la Tabla 2.

Tabla 2. PIDs para modo 01 de operación.

Modo (hex)	PID (hex)	Bytes	Descripción	Valor mínimo	Valor Máximo	Unidad	Fórmula
1	0	4	PID implementados				PID implementados [A7..D0] == [PID 0x01..PID 0x20]
1	1	4	Estado de pantalla después de borrar los códigos de fallas				Bits implementados
1	2	8	Códigos de falla de diagnóstico				
1	3	2	Estado del sistema de combustible				Bits implementados
1	4	1	Valor de carga del motor	0	100	%	$A*100 / 255$
1	5	1	Temperatura del refrigerante del motor	-40	215	°C	$A-40$
1	6	1	Ajuste de combustible a corto plazo – Banco 1	-100	99.2	%	$(A-128)*100/128$
1	7	1	Ajuste de combustible a largo plazo – Banco 1				
1	0A	1	Presión de combustible	0	765	Kpa	$A*3$
1	0B	1	Presión del colector de admisión	0	255	kPa	A
1	0C	1	Rpm del motor	0	16,383.7	Rpm	$((A*256) + B) / 4$
B	0D	2	Velocidad del vehículo	0	255	Km/h	A
1	0F	1	Temperatura de entrada de aire	-40	215	°C	$A-40$
1	10	1	Rango de flujo de aire MAF	0	655.35	g/s	$((256*A)+B)/100$
1	11	1	Posición del acelerador	0	100	%	

1.4. Aprendizaje automático.

El aprendizaje automático (ML) es una disciplina de la ciencia computacional que se centra en el reconocimiento de patrones y la capacidad de aprender de forma continua para hacer predicciones basadas en datos, razonamiento y toma de decisiones sin intervención humana. Consta de tres componentes principales: el algoritmo computacional, las variables y funciones que conforman la decisión, y la base de conocimientos que informa la respuesta y permite que el sistema se altere.

Se ingresan los datos de los parámetros con respuestas conocidas en el modelo. Luego se ejecuta el algoritmo y se realizan los ajustes hasta que el resultado concuerda con la solución previamente conocida.

Algoritmo de aprendizaje automático

Los algoritmos de aprendizaje automático son fragmentos de código que permiten explorar, analizar y dar significado a grandes conjuntos de datos complejos. En un modelo de aprendizaje automático, el objetivo es encontrar patrones que los usuarios pueden utilizar para categorizar datos o hacer predicciones basadas en parámetros derivados de los datos de entrenamiento, que son un subconjunto representativo del conjunto de datos completo. Los resultados generados por el algoritmo son más precisos a medida que se amplía el conjunto de datos de entrenamiento para que refleje mejor el mundo real. La aplicación de principios estadísticos es fundamental para el uso efectivo de los algoritmos en el aprendizaje automático.

Media, Media recortada, Mediana, Moda

Las medidas de tendencia central más utilizadas para poblaciones con pocos datos, es decir, aquellas que no requieren agrupación, son la media, la media recortada, la mediana y la moda. Estas medidas estadísticas buscan condensar un rango de valores en un solo valor, y al igual que los datos originales, se expresan en la misma unidad de medida.

Varianza y desviación estándar

La varianza y la desviación estándar son medidas estadísticas que indican en qué medida los valores se desvían de las medidas de posición. La variación es una técnica utilizada para examinar las diferencias entre las medias de dos o más poblaciones, y se expresa en las unidades de los datos elevados al cuadrado. Por otro lado, la desviación estándar es la raíz cuadrada positiva de la varianza y nos proporciona la probabilidad promedio de los datos en relación a su medio. La desviación estándar tiene las mismas unidades que los datos.

Máximo, mínimo, rango

El rango es una medida numérica que representa la diferencia entre los valores máximo y mínimo de una población o muestra estadística. Es una forma de medir la escasez de los datos y se utiliza con frecuencia para calcular la dispersión total de un conjunto de datos. El rango describe el tamaño de los datos utilizando los valores extremos de un conjunto de datos, es decir, el valor más alto y el valor más bajo observado en la población o muestra.

Representación de un histograma

El histograma es una representación gráfica utilizada para datos numéricos que revela la acumulación, tendencia, preferencia y patrón de distribución de una muestra o población estadística. La frecuencia de los datos se muestra en el eje Y, determinando la altura de las barras, mientras que la variable de estudio se representa en el eje X.

Representación de un histograma de área unitaria

El histograma de área unitaria toma una muestra de datos grande y hace que el área bajo la curva sea 1, compara el área de un mayor número de muestras con otro de menor número de muestras quedando ambas del mismo tamaño y de esta manera facilita la comparación entre ambas muestras.

Aprendizaje supervisado

Encontrar la correlación entre una variable de entrada o una de salida es la base del tipo de aprendizaje en el que todos los datos de entrenamiento están disponibles. Los algoritmos pueden aprender si se les enseña cuál es el resultado esperado para un valor

dato. Para ello, es necesario proporcionar suficientes datos de entrada y salida, y si existe una relación, el algoritmo será capaz de reconocerla. A continuación, se mencionan los algoritmos de aprendizaje supervisado:

- MSV
- Árboles de decisión
- Redes neuronales
- Lógica difusa
- Regresión lineal

1.4.1. Máquinas de soporte vectorial

Se pensaba que las máquinas de vectores de soporte (SVM) eran adecuadas para problemas de clasificación binaria. El algoritmo utiliza datos de entrenamiento etiquetados para generar un hiperplano óptimo que maximiza el margen entre las clases, como se muestra en la figura 8. Los vectores de soporte son puntos que definen el margen máximo de separación del hiperplano en una máquina de vectores de soporte (SVM). Buscan una separación eficiente, es decir, una línea que divide los dos grupos a la misma distancia. Estos "puntos" se llaman vectores en lugar de puntos, ya que tienen tantos elementos como dimensiones que hay en el espacio de entrada. Esto significa que estos puntos multidimensionales están representados por un vector n-dimensional (Monroy y Pérez, 2005).




Figura 8. Vector de n dimensiones.

Fuente: (Amat, 2017).

Kernel en SVM

En ocasiones, resulta imposible encontrar un hiperplano que divida dos clases en un problema de clasificación. En tales situaciones, se dice que los grupos no pueden separarse linealmente. La Figura 9 demuestra cómo una superficie de decisión con una nueva dimensión nos permite distinguir rápidamente entre las dos clases.




Figura 9. El truco de Kernel.

Fuente: (Amat, 2017).

1.4.2. Árboles de decisión

Se compone de múltiples nodos cuadrados que sirven como puntos de decisión y de los cuales emergen ramas para mostrar las diversas alternativas, como se presenta en la figura 10. Las probabilidades de cada rama deben sumar 1.0 y la posibilidad de cada evento, $P(E)$, se muestra encima de cada uno.

Esta herramienta se utiliza cuando se analiza la gestión de riesgos de cualquier tipo de proyecto porque se basa en datos estadísticos y de rendimiento anteriores para equilibrar el riesgo y la recompensa en las acciones o planes propuestos. participar en un proyecto o pensar en soluciones creativas a una necesidad o un problema. Esta estructura permite la estimación de costos, riesgos, resultados, probabilidades y otros factores del proyecto,

lo que ayuda a crear un caso de negocios completo para determinar dónde se obtendrán las ganancias (Guzmán y Castao, 2006).




Figura 10. Árboles de decisión.
Fuente: (Guzmán & Castaño, 2006)

1.4.3. Lógica difusa

Mediante el uso de una función que define la transición, a cada valor se le asigna un grado de pertenencia al conjunto, lo que resuelve el problema de tratar de usar la lógica binaria para simplificar problemas complejos. Con la lógica difusa, un valor puede estar en el conjunto o no, lo que significa que no tiene un borde claro que lo separe de él, por lo tanto, es dar una gama de probabilidad de veracidad, los valores de veracidad pueden ser parciales entre 0 a 1 (Guzmán & Castaño, 2006).




Figura 11. Lógica difusa.
Fuente: (Académica, 2015).

Cuando una variable en un conjunto pasa gradualmente de ser miembro a ser no miembro, las matemáticas de los conjuntos borrosos se pueden aplicar a conjuntos cuyos límites no están perfectamente definidos. Las características de estos conjuntos incluyen las funciones de pertenencia, que permiten la flexibilidad de modelado mediante expresiones lingüísticas.

La función característica conectada al conjunto borroso determina el grado de pertenencia de cada valor posible que puede tomar una entrada variable.

El sistema de controlador difuso posee cuatro partes principales: la base de conocimiento, los sistemas de codificación y decodificación, los sistemas de inferencia y los sistemas de decodificación.

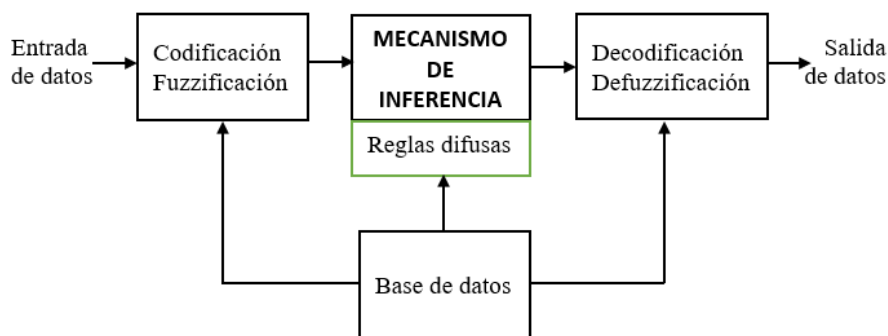


Figura 12. Estructura general de un controlador difuso.

Fuente: (Académica, 2015).

Sistemas de inferencia

Para derivar las conclusiones de las variables de salida en base a los valores de las variables de entrada, la inferencia difusa realiza la interpretación de las reglas de tipo SI-ENTONCES y mapea los conjuntos difusos de entrada a los conjuntos difusos de salida (Sanahuja, 2017). Los sistemas de inferencia borrosa se clasifican en las siguientes categorías:

Inferencia Mamdani

Se ejecuta en los siguientes pasos:

1. Fuzzificación de las variables de entrada.
2. Valoración de las reglas.

3. Designación de las salidas de las reglas.

4. Defuzzificación.

Este método enumera todas las reglas sobre cómo obtener la salida del sistema y emplea un conjunto de reglas "SI-ENTONCES" redactadas de forma confusa.

Inferencia de Takagi-Sugeno-Kang (TSK)

La principal distinción entre el método TSK y el de Mamdani es que el método TSK se basa en reglas difusas, pero a diferencia del de Mamdani, no realiza un proceso de defuzzificación porque se obtiene un conjunto de funciones lineales en lugar de un conjunto difuso. Este modelo es útil para sistemas más complicados con más dimensiones que las que se pueden resolver con el método Mamdani

1.4.4. Redes neuronales

Se basa en el funcionamiento del cerebro, existen tareas como el reconocer y clasificar patrones que son muy difíciles de realizar por computadoras, sin embargo, el cerebro es capaz de realizarlo sin muchos esfuerzos (Caparrini, 2019).

Un valor de peso se multiplica por el valor de salida de la neurona anterior o la transmisión de información. Las señales de entrada, la información y los pesos son elementos variables independientes que pueden tener un efecto en el estado de activación de las neuronas subsiguientes, ya sea aumentando o inhibiendo dicha activación. En un sistema neuronal artificial, el proceso de combinación de las señales de entrada con los pesos correspondientes se realiza mediante una operación de multiplicación. Cada valor de entrada, representado como un vector de entrada, se multiplica por su peso correspondiente, representado como un vector de peso. Esta multiplicación de vectores produce una combinación lineal de las entradas y los pesos, que se conoce como la función de ponderación. El comportamiento de una neurona artificial se muestra en la Figura 13.




Figura 13. Red neuronal totalmente conectada.
Fuente: (Matich, 2001).

Aprendizaje no supervisado

Al tener un conjunto de datos no etiquetados, es decir sin categoría o definidos se aplica dicho tipo de aprendizaje no supervisado.

Las tareas de clustering, buscan detectar conjuntos en los datos según la similitud de características, pero nada garantiza que éstas tengan algún significado o utilidad. (Blanco & Sanz, 2016).

1.4.5. K-means

Para encontrar patrones subyacentes, este algoritmo agrupa puntos de datos relacionados y busca un número fijo (k), que denota la cantidad de centroides necesarios en el conjunto de datos. El algoritmo de K-medias es un método de agrupamiento ampliamente utilizado que busca encontrar k centroides, que representan la ubicación central de cada grupo en un espacio de datos, ya sea en el dominio real o imaginario. Una vez que se encuentran los centroides, el algoritmo destina cada punto de datos al grupo más cercano en función de la distancia euclidiana o alguna otra métrica de distancia, y luego ajusta iterativamente las posiciones de los centroides para minimizar el tamaño de los centroides.

Es NP-Hard para este algoritmo. Es mejor hacer varias pruebas con varios valores porque depende de la asignación inicial del centro y puede dar un resultado u otro. Al seleccionar mejores centros, la variante K-means busca abordar este problema (Rivera, Muñoz y Arenas, 2021).

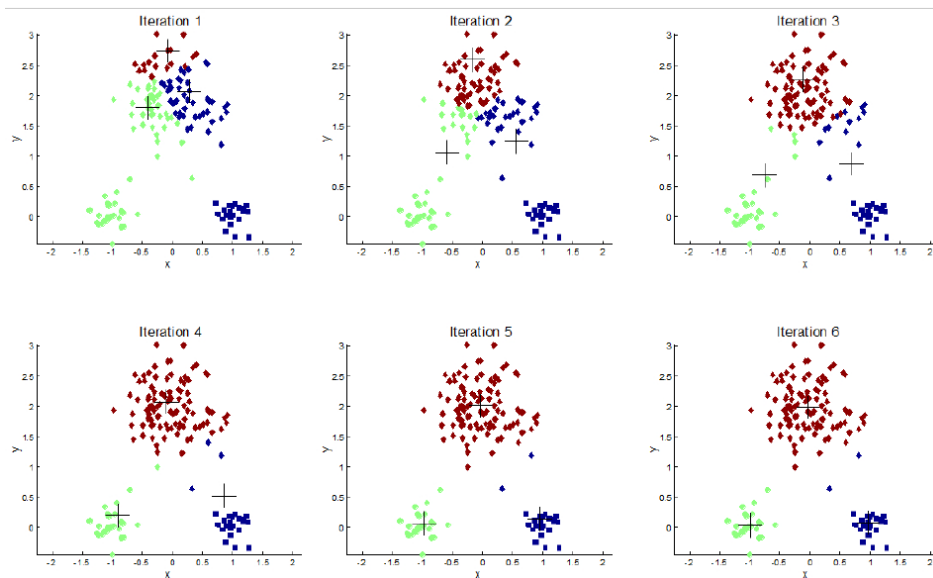


Figura 14. Iteraciones de k-means.

Fuente: (Blanco & Sanz, 2016).

Tres cruces están presentes en la primera iteración, cada una correspondiente a uno de los tres centros iniciales. Al centro más cercano se le han asignado puntos y se puede identificar por su color. El centroide se actualiza con la media de los puntos que se asignaron al conglomerado después de su asignación, que se calcula. Los centroides se han reubicado y los puntos se han asignado al centro más cercano en esta iteración. Cuando los centroides se estabilizan, la formación y optimización de grupos llega a su fin. Esto se debe a que el proceso de agrupación fue exitoso y se alcanzó el número deseado de iteraciones. (Arenas, Muñoz y Rivera, 2021).

2. ADQUISICIÓN DE DATOS.

Se basa en adquirir información en tiempo real de los fenómenos del entorno que nos rodea sean estos físicos o eléctricos, tales como temperatura, sonido, intensidad lumínica, voltajes corrientes, frecuencia que son captados por sensores, y poder manipularlos para generar controles, realizar análisis y emitir acciones según la información obtenida de lo que sucede en nuestro medio. La adquisición de datos utiliza tres etapas establecidas por la que permiten transformar la información obtenida y procesarla de manera eficiente.

Los equipos que procesan información y que además de ello pueden realizar otras operaciones, son los que obtiene la información ya convertida de un valor en magnitudes y que puede almacenarlas, visualizarlas y manipularlas para poder tener un conocimiento.




Figura 15. Proceso de obtención de información.

Fuente: Propia

2.1. Planeación de la corrida experimental

Para abordar el problema planteado, se hace necesario emplear la aplicación del diseño experimental, que implica la utilización de estrategias para analizar cómo se comporta una variable de respuesta en función de las diversas combinaciones de variables de entrada en un sistema durante la fase experimental. Este enfoque permite examinar cómo la manipulación de las variables independientes afecta la variable dependiente, es decir, la respuesta del sistema en estudio (Chica & Rivera, 2015).

Los factores que se encuentran involucrados son las variables que se describen en la figura 16.

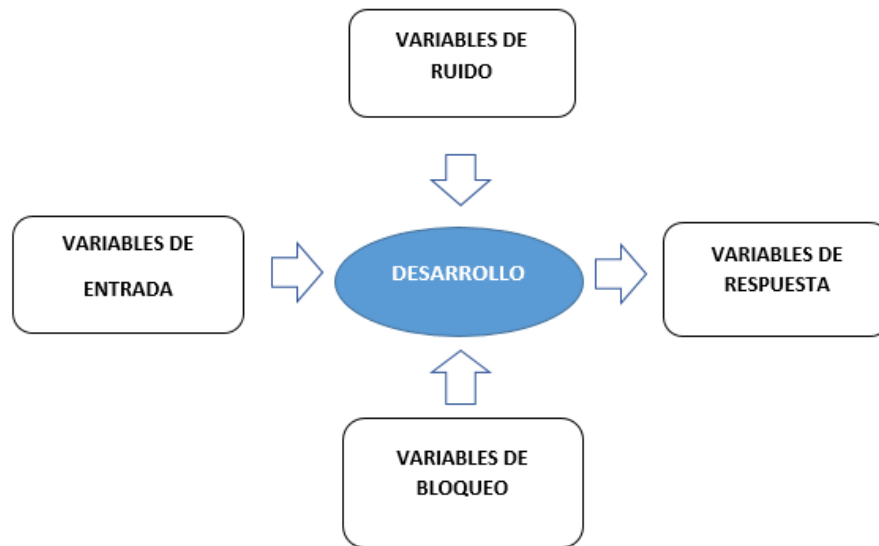


Figura 16. Variables involucradas en el experimento.

Fuente: (Chica & Rivera, 2015).

2.1.1. Variables de entrada

Es importante que la salida o la conducta de una variable no influya en la variación de ninguna otra variable, es decir, que sean independientes entre sí, las variables establecidas para el experimento se presentan en la tabla 3.

Tabla 3. Variables de entrada.

Variables de entrada	Nomenclatura	Unidad
Régimen de giro del motor	RPM	Rpm
Posición del acelerador	TPS	%
Temperatura del refrigerante del motor	ECT	°C
Temperatura del aire de admisión	IAT	°C
Presión absoluta del colector	MAP	kPa

2.1.2. Variables de bloqueo

Las variables que están en un punto de operación y no afectan directamente las variables de salida en un sistema o proceso se conocen como variables de control. La Tabla 4 enumera las variables para el experimento actual.

Tabla 4. Variables de bloqueo.

Variables de bloqueo	Nomenclatura	Unidad
Temperatura del refrigerante	ECT	[°C]
Temperatura de la rodadura	T Rolling	[°C]
Temperatura del lubricante	T lubri	[°C]
Tipo de combustible	RON	NO
Presión Atmosférica	P atm	[Pa]

2.1.3. Variables de ruido

Muestran ciertos inconvenientes mientras se desarrolla el experimento, al estar directamente afectadas por las condiciones climáticas son complicadas de controlar, sin embargo, se intenta obtener sus valores más bajos de las mismas debido a que intervienen en los valores de salida, las variables se indican en la tabla 5.

Tabla 5. Variables de ruido.

Variables de ruido	Símbolo	Unidad
Temperatura del aire	T air	[%]
Temperatura del combustible	T fuel	[°C]
Humedad relativa del aire	H rel	[%]

2.1.4. Variables de respuesta

El experimento propuesto tiene como objetivo demostrar cómo las variables de entrada influyen en la salida de un sistema en particular. Se ha seleccionado cuidadosamente el valor a analizar, debido a su especial interés en el contexto del estudio.

El modelo matemático permitirá analizar de manera cuantitativa cómo los valores de los parámetros PID influyen en el comportamiento del sistema de ajuste de combustible, tanto a corto plazo como a largo. Se utilizarán técnicas y métodos matemáticos apropiados para realizar el análisis de los datos obtenidos de las rutas vehiculares y determinar las relaciones matemáticas que existen entre los parámetros PID y el ajuste de combustible indicados en la tabla 6.

Tabla 6. Variables de salida.

Variables de salida	Símbolo	Unidad
Sensor de Oxígeno	O2	V
Ajuste de combustible a corto plazo	STFT	%
Ajuste de combustible a largo plazo	LTFT	%

2.2. Tarjeta adquisidora de datos

2.2.1. Obtención de datos mediante L102 Ulbotech configurador

Ulbotech L102 OBD *Logger* es un dispositivo de diagnóstico que presenta un lector OBDII encargado de registrar y analizar en tiempo real todos los datos de los parámetros de identificación (PID, Process Identificación) provenientes de la ECU, además permite conocer el comportamiento de conducción y los datos de estado del equipo mostrados en la figura 17. Los datos recopilados pueden almacenarse en la tarjeta de memoria SD con extensión "CSV" para después analizar mediante Matlab® (Gárate, 2018).



Figura 17. Ulbotech L102.

Fuente: (Ulbotech, 2014).

Tabla 7. Descripción del dispositivo Ulbotech L102.

Descripciones del dispositivo Ulbotech L102	
Sensivity GPS	Autónomo: -147 dbm Arranque en caliente: -160 dbm Seguimiento: -162 dbm
Almacenamiento	Tarjeta micro SD
Consumo de energía	30 mA (activo), 10 mA (suspensión), Máx. <250 Ma
Tensión de funcionamiento	8V a 32V DC
Sensor	Acelerómetro de 3 ejes $\pm 2g / \pm 4g / \pm 8g / \pm 16g$ Voltaje de la batería Sensor de temperatura

Las ventajas del dispositivo L102 se presentan a continuación.

- Soporta todos los protocolos OBDII.
- Almacenamiento de hasta 4Gb de información.
- Inmovilizador interno (corte del motor) para antirrobo.
- Acelerómetro interno de 3 ejes.
- Detección del comportamiento del controlador de 8 tipos.
- Registro por tiempo, distancia, curso y estado.

Protocolos soportados por el dispositivo:

- J1850 PWM
- J1850 VPW
- ISO 9141-2
- ISO14230(KWP2000)
- ISO15765-4(CAN)

2.2.2. Vehículo de pruebas

Los recorridos planteados se efectúan en el vehículo Chevrolet Aveo activo 1.6, pues al ser el vehículo tipo sedán más vendido en el Ecuador en los últimos años según el anuario de la Asociación de Empresas Automotrices del Ecuador (AEADE, 2020), y al existir gran cantidad de vehículos con características técnicas semejantes al vehículo seleccionado tanto en la parte mecánica como en la parte electrónica, los datos obtenidos posteriormente presentarán un alto nivel de aplicabilidad.



Figura 18. Vehículo para pruebas.

Fuente: Propia.

Tabla 8. Descripción técnica del vehículo

Ficha técnica Chevrolet Aveo	
Especificación	Detalle
Marca	Chevrolet
Modelo	Aveo
Año de fabricación	2016
Potencia máxima	103HP 6000 RPM
Torque	147Nm 6000RPM
Relación de compresión	9,5 :1
Relación final	4,176
Cilindrada	1598cc
Sistema de inyección	Multipunto
Distribución	DOHC 16V
Neumáticos	185 / 60R14
Tipo de combustible	Súper (92 Octanos)

El recorrido actual del vehículo es de 36000km hasta los cuales se encuentran realizados todos los mantenimientos y sin ninguna modificación en el motor, previo a realizar los recorridos se verifica que el motor esté funcionando de manera correcta.

2.2.3. Selección de rutas de pruebas

Se realizan recorridos aleatorios dentro y fuera de la Ciudad de Cuenca sin realizar una clasificación de zonas urbanas, rurales o autopista, de esta manera se recorren 124 Km.

Clasificación de rutas según la Normativa Europea.

Se realizan dos pruebas de aproximadamente 60km cada una, las rutas establecidas se ejecutaron en la Ciudad de Cuenca, siguiendo la normativa europea (REGULATION, 2016), la cual indica que se debe realizar un monitoreo de rutas como se muestra en la figura 19, las mismas que consisten en los porcentajes específicos como se indican a continuación:

- 34 % en área urbana

- 33 % en área rural
- 33 % en autopista




Figura 19. Monitoreo de rutas.

Fuente: Propia.

A partir de las velocidades establecidas se clasifican los recorridos:

a. Zona urbana

- Dentro de esta área la velocidad del vehículo puede ser hasta de 60km/h.
- Entre 15 y 30 km/h debería ser la velocidad media de la parte de conducción.
- Se establece que las paradas, las cuales se definen como períodos en los que la velocidad es menor a 1 km/h, deben representar al menos el 10 % del tiempo total de funcionamiento.
- Se producirán varias paradas de diez segundos o más durante el funcionamiento. Se evitará incluir una parada que ocupe más del 80 % del tiempo total de parada de la operación.

b. Zona rural

- Este rango de velocidades del vehículo abarca valores comprendidos entre 60 y 90 km/h.
- Al atravesar áreas urbanas puede interrumpirse con cortos lapsos de funcionamiento.

c. Autopista

- Las velocidades serán superiores a 90km/h.
- Al atravesar áreas urbanas o rurales, así como al pasar por peajes puede interrumpirse con cortos lapsos de funcionamiento.
- Este rango de velocidades del vehículo abarca valores comprendidos entre 90 y 110 km/h.
- Se permite una velocidad mayor a 100 km/h durante al menos cinco minutos como mínimo.

En tanto que se realicen los recorridos se debe tomar en cuenta lo siguiente:

- Los porcentajes declarados podrían tener una brecha de 10 puntos porcentuales a su alrededor.
- El funcionamiento en las 3 zonas deberá ser continuo.
- La diferencia de altitud sobre el nivel del mar entre los puntos de partida y de llegada no deberá ser mayor a 100 metros.
- Se establece que la distancia mínima a recorrer mientras se opera en una zona urbana, una zona rural y una carretera será de 16 kilómetros cada una.

2.2.4. Protocolo para obtención de datos con dispositivo Ulbotech L102

Previo a realizar los recorridos para la recolección de datos se debe tomar en cuenta el protocolo explicado:

- Preparar los instrumentos de diagnóstico y medición.
- Conectar dispositivo L102 Ulbotech al puerto OBD II del vehículo.
- Prender el motor del vehículo.

- Se debe verificar que la temperatura del refrigerante del motor sea mayor a 80°C.
- Realizar un ciclo de conducción aleatorio.
- Colocar la tarjeta de memoria del L102 en el ordenador para separar la información.
- Ejecutar la extracción de la información almacenada usando el interfaz *L102 Configurator* que se indica en la figura 20.
- Finalmente realizar su la lectura mediante Matlab®.

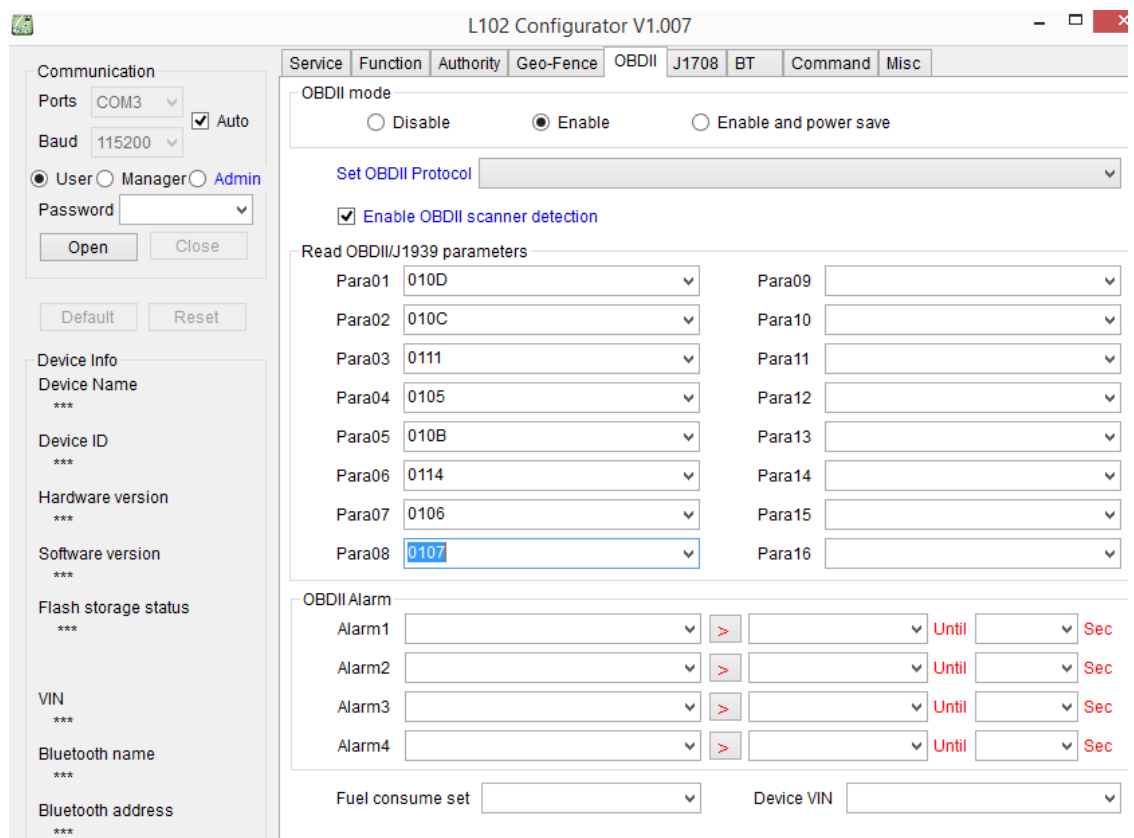


Figura 20. L102 Configurator V1.007.

Fuente: (Ulbotech, 2014).

En la figura anterior la información de los sensores que se tendrán en cuenta para el estudio está relacionados con una medida específica del modo 1x01 mencionados en el capítulo 1, se introduce el PID hexagonal en el orden en el cual serán tabulados, los valores obtenidos de los mismos se presentan a continuación.

Tabla 9. Valores máximos y mínimos de los parámetros.

Parámetro	Símbolo	Mínimo	Máximo	Unidad
Velocidad del vehículo	VSS	0	255	[Km/h]
Velocidad del motor	RPM	0	15880,65	Rpm
Posición del acelerador	TPS	0	100	[%]
Temperatura del refrigerante	ECT	-40	215	[°C]
Temperatura de aire de admisión	IAT	-40	215	[°C]
Presión absoluta del colector	MAP	0	255	kPa
Oxígeno o Sonda lambda	O2	0	1.325	V
Ajuste de combustible a corto plazo	(STFT)	-25	25	[%]
Ajuste de combustible a largo plazo	(LTFT).	-25	25	[%]

2.3. Representación gráfica de variables obtenidas a través de L102 Configurator y Matlab®.

Las señales que se tendrán en cuenta para la programación son:

- Velocidad del vehículo
- Velocidad del motor
- Posición del acelerador
- Temperatura del refrigerante del motor
- Temperatura de aire de admisión
- Presión absoluta del colector
- Oxígeno o Sonda lambda
- Ajuste de combustible a corto plazo
- Ajuste de combustible a largo plazo

2.3.1. Velocidad del vehículo

El conductor se involucra en varias técnicas de conducción a lo largo del recorrido experimental. La señal exhibe un comportamiento proporcional a la velocidad del vehículo, lo que implica que su variación está directamente relacionada con los cambios en la velocidad del vehículo (Km/h) en la Figura 21 cuando se muestra un corte de una muestra aleatoria de la señal.




Figura 21. Datos obtenidos del sensor de velocidad.

Fuente: Propia.

2.3.2. Régimen de giro del motor

La figura 22 muestra una ventana de una muestra aleatoria de velocidad de rotación (RPM) y tiempo (s), donde se puede observar que el motor se comporta moderadamente, con un régimen de ralentí que oscila entre 700 y 100 RPM. Sin embargo, se tiene en cuenta la velocidad de giro a altas revoluciones porque es necesario realizar un cambio de marcha.




Figura 22. Datos obtenidos del sensor CKP.

Fuente: Propia.

2.3.3 Posición del acelerador

La Unidad de Control Electrónico utiliza esta señal para ajustar y controlar la sincronización y la cantidad de inyección de combustible en un vehículo. La Figura 23 muestra un corte de una muestra aleatoria de la apertura, donde se representa el porcentaje del 0 al 100%.




Figura 23. Datos obtenidos del sensor TPS.

Fuente: Propia.

2.3.4. Temperatura del refrigerante

El ECM recibe la señal de voltaje del sensor y la convierte en una señal de temperatura para regular las operaciones esenciales de los componentes del motor, tales como los inyectores, la válvula EGR y el ventilador del radiador, en la figura 24 se presenta un recorte de una muestra aleatoria de la temperatura del motor que indica la etapa de calentamiento del motor, dado que el refrigerante inicia el recorrido a una temperatura de 20 °C muy próximos a la temperatura ambiente y alcanza un máximo de 83°C que es donde el ventilador se activa descendiendo la temperatura del refrigerante.




Figura 24. Datos del sensor de temperatura del refrigerante.

Fuente: Propia.

2.3.5. Temperatura del aire de admisión

La densidad del aire que ingresa al motor puede verse afectada por la temperatura, lo cual puede tener un impacto en el rendimiento del motor. Para asegurarse de que el motor reciba la cantidad adecuada de combustible en función de la densidad del aire, se utiliza un sistema de control electrónico conocido como Módulo de Control del Motor. En la figura 25 se muestra un recorte de una muestra aleatoria de la señal, la cual varía a lo largo del tiempo en función de la temperatura. Los cambios en la señal no son repentinos, considerando que la temperatura ambiente en Cuenca es de aproximadamente 20 °C.




Figura 25. Datos del sensor de temperatura del aire.

Fuente: Propia.

2.3.6. Presión absoluta del colector

Se presenta un recorte de la muestra de la señal que indica la presión obtenida en el colector de admisión en la figura 26, en donde las variaciones de la señal son respuestas a cambios rápidos de la carga y aceleraciones exigidas al motor, la presión a Ralentí se da en un rango de 0 a 25Kpa y el valor máximo de presión del colector es 75KPa correspondiente a la presión atmosférica en Cuenca la cual está a 2500 msnm.




Figura 26. Datos obtenidos por el sensor MAP.

Fuente: Propia.

2.3.7. Sensor de oxígeno

El sensor de O₂ identifica la cantidad de oxígeno sin combinarse encontrado en la salida del escape, para establecer una diferencia entre mezcla rica o mezcla pobre, en función de esta información la computadora decide cómo debe inyectarse el combustible para obtener una mezcla estequiométrica, en la figura 27 se muestra un fragmento de una muestra aleatoria de la señal que está comprendida entre 0 y 1V se observa su comportamiento a ralentí y a diferentes regímenes, se tiene que el valor se encuentra en los 0.45V por lo que siempre se encontrará fluctuando ante este valor, lo que indica que se encuentra en funcionamiento normal.




Figura 27. Datos obtenidos por el sensor de oxígeno.

Fuente: Propia.

2.3.8. Ajuste de combustible a corto plazo

Utilizando la señal de oxígeno como guía, el STFT nivela la mezcla estequiométrica. El valor del ajuste se muestra como un porcentaje positivo o negativo.

En la figura 28 se presenta el fragmento de una muestra aleatoria de la señal donde se puede observar que cuando se presenta una mezcla rica, el STFT rápidamente presenta un porcentaje negativo lo que indica que está restando combustible, una vez que el sensor queda en valores de mezcla pobre la ECU envía más cantidad de combustible del calculado, después de estas correcciones se logra que el sensor de oxígeno empiece a oscilar de manera normal, el comportamiento del ajuste se encuentra dentro de los valores normales para ralentí, para un régimen de giro en altas revoluciones o para una variación de esfuerzo para el motor llega hasta los $\pm 25\%$ que se encuentra dentro de los valores normales.




Figura 28. Datos obtenidos del STFT.

Fuente: Propia.

2.3.9. Ajuste de combustible a largo plazo

Cuando el STFT está trabajando con valores mayores a los establecidos por mucho tiempo, los valores del compensador del LTFT van a empezar a oscilar alrededor del 12% mientras logra que el STFT se acerque a 0 lo más rápido posible.

El rango de ajuste del LTFT tiene como máximo una corrección permitida de $\pm 25\%$.

En la figura 29 se muestra el recorte de una muestra aleatoria de la señal del comportamiento del ajuste se encuentra dentro de los valores normales.




Figura 29. Datos obtenidos del ajuste de combustible a corto plazo.

Fuente: Propia.

3. APLICACIÓN DE ALGORITMOS DE APRENDIZAJE AUTÓNOMO PARA LA DETECCIÓN DE OPERACIONES DE CONDUCCIÓN Y SU INFLUENCIA EN LOS AJUSTES DE COMBUSTIBLE.

3.1. Validación de los datos adquiridos

La validación de datos es un proceso crucial para obtener datos limpios, correctos y útiles que puedan ser aplicados en las arquitecturas de aprendizaje automático propuestas en el presente estudio.

La lógica de validación implementada consiste en comparar los rangos de las diferentes señales obtenidas en la experimentación con los rangos descritos en la normativa SAE J1979, de esta forma los valores atípicos o aberraciones estadísticas no serán considerados para los análisis que se realizarán en la posteridad, y de ser el caso invalidarán las señales a estudiar y se debería repetir la corrida experimental.

Los resultados de la corrida experimental están en la tabla 10, comparados con los límites expuestos en la norma SAE J1979 que define los modos de operación de OBD II (no se trata de un protocolo de comunicación), de donde se concluye que todas las variables adquiridas cumplen con el criterio de validación.

Tabla 10. Resultados de la corrida experimental.

Parámetro	Designación OBD II		Experimental		Unidad	Cumple Validación
	Mínimo	Máximo	Mínimo	Máximo		
VSS	0	255	0	97	[Km/h]	SI
RPM	0	16383.75	0	3516	Rpm	SI
TPS	0	100	0	99	[%]	SI
ECT	-40	215	25	92	[°C]	SI
IAT	-40	215	28	40	[°C]	SI
MAP	0	255	18	74	kPa	SI
O2	0	1.325	0	0.98	V	SI
STFT	-100	99.2	-17	10	[%]	SI
LTFT	-100	99.2	-10	1	[%]	SI

3.2. Representación de las señales en microciclos de conducción.

Un microciclo de conducción se define como el período de funcionamiento desde que el vehículo parte del reposo hasta que retorna al mismo (Jiménez, López, & Alfonso, 2013), mientras que a los períodos en los cuales la velocidad es menor a 1km/h se los considera como zonas de parada (Ralentí), según lo mostrado en la normativa (Euro 6, 2016).

Un ciclo de conducción completo y su segmentación en microciclos, acorde a lo antes descrito, puede apreciarse la consecución de zonas de parada y los microciclos mostrados en un pequeño tramo del recorrido para su mejor visualización en la figura 30.

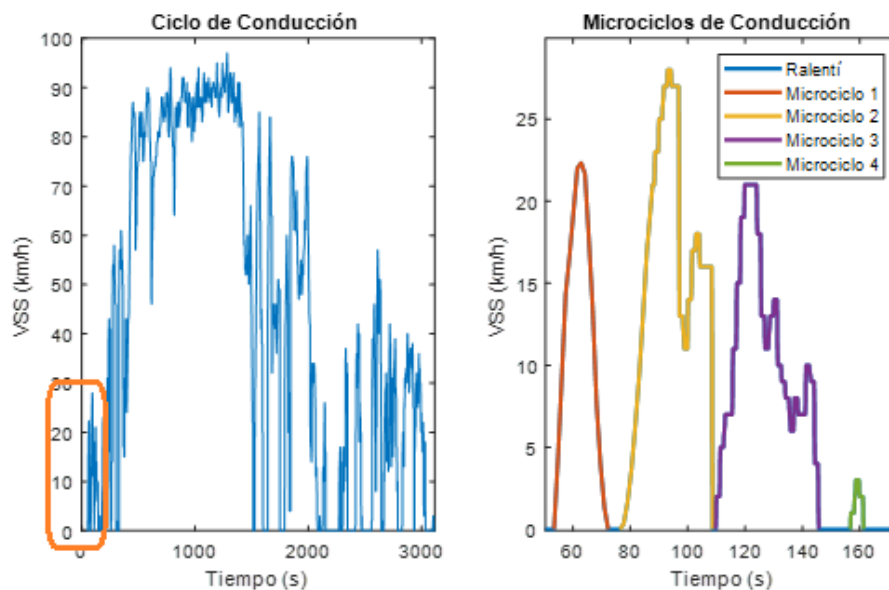


Figura 30. Ciclo y microciclos de conducción.

Fuente: Propia.

3.3. Extracción de características de las señales

Para la correcta aplicación de las diversas arquitecturas de aprendizaje automático es muy importante conocer el comportamiento de cada una de las señales a ser analizadas, por lo que resulta imperativo realizar un estudio estadístico de las señales para poder determinar patrones en los comportamientos de las mismas. Para este efecto, se identifican las propiedades de las señales en el dominio del tiempo y se extraen valores descriptivos de tendencia central y dispersión, tales como el máximo, mínimo, media, mediana, moda y desviación estándar.

3.3.1 Sensor de Oxígeno

Mantiene un comportamiento binomial como se indica en la figura 31, esto debido a la característica de funcionamiento del sensor. La distribución binomial o también denominada bimodal se genera cuando el experimento del cual se obtuvieron los datos es dicotómico, es decir en los datos de análisis (la señal del sensor de oxígeno) solo existen dos resultados posibles. Como se conoce el vehículo de pruebas consta de un sensor de oxígeno de banda estrecha (narrow band), que genera su señal a partir del contenido de oxígeno en el conducto de escape, si bien esta señal es analógica entrega resultados de interpretación digital, es decir únicamente se puede resolver si la mezcla es rica o es pobre, no cuan rica o cuan pobre es, por la tanto mediante el análisis de esta señal no se puede estimar el dosado de la mezcla. En el histograma de la señal se puede también apreciar la aparición de dos grupos en torno a dos valores característicos que denotan mezcla pobre y mezcla rica respectivamente.




Figura 31. Histograma de la señal del sensor de oxígeno.

Fuente: Propia.

Los valores estadísticos descriptivos derivados de la señal en estudio se ven afectados por el comportamiento binomial, como se muestra en la Tabla 11. Cabe señalar que no existe correlación entre los valores de tendencia central media, mediana y moda, mientras que, en otra distribución de datos, como la normal, mantienen un alto grado de similitud y solo se distinguen por valores atípicos, lo que no ocurre en el presente análisis.

Tabla 11. Estadísticos descriptivos de la señal del sensor de oxígeno

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
0.89	0	0.479	0.63	0	0.3184	V

3.3.2 Ajuste de combustible de corto plazo STFT

El STFT presenta un comportamiento aproximadamente normal como indica en la figura 32, casi simétrico respecto de cero, esto a pesar de tratarse de una magnitud discreta, lo que ocasiona las breves diferencias con la tendencia de la campana de Gauss. Cabe destacar que el comportamiento del STFT está directamente ligado a la señal del sensor de oxígeno, que como se analizó a priori mantiene un comportamiento binomial.




Figura 32. Histograma de la señal del ajuste de combustible STFT.

Fuente: Propia.

El STFT se mantiene estático (generalmente en 0%) cuando la Unidad de Control Electrónico no realiza ajustes sobre el tiempo de inyección, es decir cuando el lazo de control se encuentra en estado abierto también conocido como "Open Loop", de allí que la mayor concentración de datos se da en torno al valor del 0%. Existen dos posibles escenarios para que la ECU corrija el tiempo de inyección cuando el sistema está en circuito a través del STFT en función del sensor de O_2 cuando:

- a) Es menor a 0.45 V (valor teórico). Mezcla pobre: la ECU determina que la mezcla que se acaba de combustionar en el motor es pobre, por lo cual para el próximo ciclo de trabajo necesita enriquecer la mezcla, es decir incrementar el tiempo de inyección para aportar mayor cantidad de combustible, esto se consigue a través del incremento del STFT que es una variación porcentual del tiempo de inyección teórico.

- b) Es superior a 0.45 V. Mezcla Rica: la ECU determina que la mezcla que se acaba de combustionar en el motor es rica, por lo cual para el próximo ciclo de trabajo necesita empobrecer la mezcla, es decir disminuir el tiempo de inyección para disminuir la cantidad de combustible aportada, esto se consigue a través de la disminución del STFT.

Para cumplir con dicho propósito, independientemente de la situación específica, la ECU lleva a cabo la tarea de regulación mediante un controlador PID (Proporcional, Integral y Derivativo), el cual no debe confundirse con un simple parámetro de operación. La ECU modifica el STFT acorde a la evolución de la variable del proceso es decir la señal del sensor de oxígeno, para lo cual no utiliza una señal de control tipo ON/OFF si no una señal de control proporcional a la diferencia, existente entre la señal actual del sensor de oxígeno y el valor nominal de funcionamiento (0.45 V) y proporcional a sus respectivas integral y derivada. Por tal motivo la señal resultante del STFT mantiene un comportamiento temporal próximo a una señal "diente de sierra", como puede mostrarse en la figura 33.




Figura 33. Comportamiento del sensor de oxígeno.

Fuente: Propia.

Al tratarse de una magnitud de comportamiento discreto se puede notar en la tabla 12 que la mediana y la moda son iguales entre sí, pero diferentes al valor de la media, razón por la cual se determina que el STFT mantiene un comportamiento aproximadamente normal y no únicamente normal.

Tabla 12. Estadísticos descriptivos del ajuste de combustible de corto plazo.

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
23	10	-0.477	0	0	2.73	%

3.3.3 Ajuste de combustible de Largo plazo LTFT

Presenta un comportamiento cuasi binomial con dos tendencias bien establecidas en los valores próximos a 0 y a -9% respectivamente, como se muestra en la representa 34. El comportamiento del LTFT está directamente ligado al STFT y por ende a la señal del sensor de oxígeno, que como se analizó a priori también mantiene un comportamiento binomial.




Figura 34. Comportamiento de la señal LTFT.

Fuente: Propia.

Los valores estadísticos descriptivos son influenciados por el comportamiento cuasibinomial del LTFT, y que se muestran en la tabla 13. Se puede notar que no existe correlación alguna entre los valores de tendencia central media, mediana y moda.

Tabla 13. Estadísticos descriptivos del ajuste de combustible de corto plazo

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
7	0	1.07	1	0	1.31	%

3.3.4. MAP

La señal del sensor MAP mantiene una distribución binomial mostrado en la figura 35, en los datos de análisis se presentan dos picos, es decir existen dos tendencias, una tendencia en puntos bajos y otra en puntos altos, los puntos bajos indican que un gran número de valores se encuentran por debajo de la presión de ralenti entonces es cuando el conductor desacelera, y la tendencia de los puntos altos es cuando se encuentra a plena

carga con el acelerador pisado a fondo con el motor dando al máximo, es cuando arranca o cuando quiere ganar velocidad, por esta razón se llama tendencia binomial.




Figura 35. Histograma de la señal del sensor MAP.

Fuente: Propia.

La tabla 14 presenta los valores estadísticos descriptivos, los cuales son influenciados por el comportamiento binomial del MAP (Modelo de Análisis de Procesos). Se puede observar que no hay ninguna correlación entre la media, la mediana y la moda.

Tabla 14 Estadísticos descriptivos del sensor MAP.

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
76	16	35.84	27	18	18.11	KPa

3.3.5. TPS

El TPS presenta una distribución binomial con dos tendencias bien establecidas, en los datos de análisis se presentan dos picos en los valores próximos a 10% y a 80% respectivamente como se aprecia en la figura 36, una tendencia en puntos bajos y otra en puntos altos, los puntos bajos indican que un gran número de valores se encuentran en

baja carga con el TPS (%) casi cerrado, mientras que el conductor permanece gran parte del tiempo en ralentí, en media carga es lo que más utiliza que es aproximadamente un 8%.




Figura 36. Histograma de la señal del sensor TPS.

Fuente: Propia.

Al tratarse de un comportamiento binomial los valores estadísticos descriptivos se ven influenciados como se puede apreciar en la tabla 15, en donde se puede notar que no existe correlación alguna entre los valores de tendencia central Media, mediana y moda.

Tabla 15. Estadísticos descriptivos del TPS.

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
99	2	11.04	6	2	15.96	%

3.3.6. Derivada del TPS

EL comportamiento del sistema de control del motor no solo se ve limitado a la influencia señal del sensor TPS, sino también a su derivada temporal que es un excelente indicativo de las intenciones del conductor, denotando así las acciones de aceleración, desaceleración y períodos estacionarios de funcionamiento.

Uno de los factores de los que depende la aceleración del vehículo es el torque entregado por el motor que depende directamente del TPS y su derivada. La derivada del TPS se determina mediante la ecuación (1).

$$\frac{dTPS}{dt} = \left(\frac{TPS_n - TPS_{n-1}}{t_n - t_{n-1}} \right) [\%/s] \quad (1)$$

La derivada del TPS presenta un comportamiento aproximadamente normal como se muestra en la figura 37, casi simétrico respecto de cero, lo que ocasiona las breves diferencias con la tendencia de la campana de Gauss. Se puede observar que muchos valores se encuentran alrededor de cero debido a que la mayor parte del tiempo del pedal se encuentra cerrado.




Figura 37. Histograma de la derivada del TPS.

Fuente: Propia.

La derivada del TPS al ser una magnitud de comportamiento discreto tiene valores estadísticos indicados en la tabla 16 en donde los valores de la mediana y la moda son iguales entre sí, pero diferentes al valor de la media, razón por la cual se determina que la dTPS/dt mantiene un comportamiento aproximadamente normal y no únicamente normal.

Tabla 16. Estadísticos descriptivos del ajuste de combustible de corto plazo.

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
13.8	-14.8	0.00007	0	0	0.82	%/s

3.3.7 IAT

Es una variable aleatoria, es un evento que no representa el mismo interés como las otras variables que si tienen que analizarse, sin embargo, su comportamiento cuasinormal se aprecia en la ilustración 38.




Figura 38. Histograma del sensor IAT.

Fuente: Propia.

En la tabla 17 se presentan los valores estadísticos descriptivos, los cuales permiten observar que no existe ninguna correlación entre las medidas de tendencia central, como la media, la mediana y la moda.

Tabla 17. Estadísticos descriptivos del sensor IAT.

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
51	24	38.11	37	23	7.82	°C

3.3.8 ECT

Es una variable aleatoria, es un evento que no representa el mismo interés como las otras variables que si tienen que analizarse, sin embargo, se observa que presenta una distribución aproximadamente normal como se indica en la figura 39.




Figura 39. Histograma del sensor ECT.

Fuente: Propia.

La ECT al presentar un comportamiento aproximadamente normal influye en los valores estadísticos descriptivos que se indica en la tabla 18 en donde se nota que la mediana y la moda son iguales entre sí, pero diferentes al valor de la media.

Tabla 18. Estadísticos descriptivos del ECT.

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
97	87	90.47	90	90	1.77	°C

3.3.9 Velocidad

La velocidad presenta una distribución binomial, en la figura 40 se observa que existen dos tendencias bien establecidas, en los datos de análisis se presentan dos picos en los valores próximos a 0 y a 40km/h respectivamente,




Figura 40. Histograma de la velocidad.

Fuente: Propia.

La velocidad al presentar un comportamiento binomial, se puede apreciar en la tabla 19, que no existe correlación alguna entre los valores de Media, mediana y moda.

Tabla 19. Estadísticos descriptivos de la velocidad.

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
122	0	38.49	34	0	27.01	Km/h

3.3.10. Aceleración

La respuesta dinámica del vehículo es influenciada por diversas fuerzas longitudinales que se aplican al desplazamiento del automovil, como son la resistencia aerodinámica y a la rodadura, la resistencia al desplazamiento en pendientes entre las más destacadas, a más del torque producido por el motor y transmitido hacia las ruedas.

La aceleración longitudinal del vehículo se determina mediante la ecuación (2).

$$a_x = 3.6 \left(\frac{VSS_n - VSS_{n-1}}{t_n - t_{n-1}} \right) [m/s^2] \quad (2)$$

La aceleración presenta una distribución normal, se encuentra centrada en los valores de cero indicado en la figura 41, se aprecia que tiene pocos valores a la derecha e izquierda lo que significa que es conducción agresiva es decir cuando se acelera bastante, la gran cantidad de valores que están apegados al centro o a 0 indican que se condujo en un gran tramo urbano.




Figura 41. Histograma de la aceleración.

Fuente: Propia.

La media presenta un valor de 0.00001^a diferencia de la mediana y la moda que son iguales entre sí como lo indica la tabla 20, esto es debido a que la aceleración está centrada en un

valor que coincide con el valor medio de la distribución, lo que concluye que la aceleración mantiene un comportamiento normal.

Tabla 20. Estadísticos descriptivos del ajuste de aceleración.

Máximo	Mínimo	Media	Mediana	Moda	Desviación estándar	Unidad
1.97	-2.41	0.00001	0	0	0.389	m/s ²

3.4 Aplicación de arquitecturas de aprendizaje automático

3.4.1 Estimación del umbral de control del Sensor de Oxígeno

El sensor de oxígeno genera una señal que varía entre los 0 y 1 V teniendo como umbral de detección los 0.5 V, para otros autores la señal del sensor varía entre los 0 y 0.9 V y el umbral de detección es de 0.45 V, determinando que la amplitud de la señal y su comportamiento dependen directamente de la temperatura a la cual se encuentra laborando el sensor. Esta temperatura de funcionamiento depende de varios factores, como son el desempeño del calefactor integrado y el régimen de funcionamiento del motor que infiere directamente sobre la temperatura de los gases contaminantes.

El problema radica en que se sabe que el sensor de oxígeno produce señales que indican si la mezcla es rica o pobre, y que el umbral de detección depende de los factores comentados anteriormente. Por esta razón, se utiliza un algoritmo de agrupamiento de aprendizaje no supervisado porque es imposible asignar etiquetas al estado de mezcla.

En la figura 42 se puede apreciar cómo se comporta la señal del sensor durante todo el período de experimentación, se destacan las variaciones de amplitud de la señal que se representa como una variable continua pero que en realidad es una variable discreta.




Figura 42. Señal del sensor de oxígeno durante la experimentación.

Fuente: Propia.

El agrupamiento de los datos que el algoritmo K-means ha ejecutado de forma automática, se han determinado 2 categorías que se pueden apreciar de color amarillo y azul. Se destaca que para la clasificación no se ha utilizado ningún tipo de umbral, sino que el algoritmo ha determinado uno basado en los centroides de las categorías.




Figura 43. Diferenciación de grupos de mezcla.

Fuente: Propia.

Tras la aplicación del algoritmo de agrupamiento los resultados muestran que las mediciones obtenidas se dividen en dos grupos previamente determinados como mezcla rica y pobre, que en teoría deberían separarse en el umbral de los 0.45 V, pero dado que el funcionamiento del vehículo en las condiciones de Cuenca dista de lo normalmente establecido, el límite de separación es de 0.4233 V, lejos de la media y mediana de la señal.




Figura 44. Mezcla rica vs mezcla pobre.

Fuente: Propia.

3.4.2. Estimación del estado de funcionamiento

3.4.2.1. Estimación del Ralentí

La normativa 2017/1154 que establece los procesos de homologación de los vehículos Euro 5 y 6, determina en los ciclos de conducción las zonas de parada, en las que la velocidad del automóvil es menor a 1 km/h (Euro 6, 2016). Bajo esta única condición resulta sencillo poder establecer un algoritmo para la detección de las zonas de parada basados únicamente en el valor de la velocidad del vehículo; pero hay que considerar que durante una parada no existe garantía de que el motor va a estar siempre en ralentí, por lo que la detección de este estado de funcionamiento no puede basarse exclusivamente en la velocidad del vehículo, sino también en el accionamiento del acelerador y la velocidad de

giro del motor, que de acuerdo a la Norma (INEN, 2017) no podrá ser superior a las 1200 RPM en esta condición de operación.

Tras esta premisa se puede plantear reconocer mediante una sencilla ecuación del tipo:

$$Ral = (VSS < 1) * (RPM < 1200) * (TPS == \min(TPS)) \quad (3)$$

En la cual los vectores corresponden a:

VSS: velocidad del vehículo

RPM: velocidad del motor

TPS: posición del acelerador

Ral: valores de 1 a ralenti, y 0 para cualquier otro estado de funcionamiento.

Este método planteado es muy práctico debido a su sencillez, pero presenta algunos inconvenientes a ser analizados. Si el vehículo se encuentra en desplazamiento significa que alguna marcha está seleccionada, lo que conlleva a que el motor y las ruedas están mecánicamente acopladas, por lo tanto, las velocidades del motor y del vehículo serán proporcionales. En el instante de cambiar de marcha el acople entre el motor y las ruedas se pierde y como parte de la maniobra es cerrar totalmente el acelerador el motor pasa a funcionar en ralenti en un breve período de tiempo, esto sucede también si en algún intervalo del recorrido el conductor dispone circular el vehículo en neutro, desplazándose este por la inercia obtenida. En ambos casos podemos notar que el motor puede encontrarse en ralenti no necesariamente con el vehículo detenido, por lo cual la ecuación (3) pierde aplicabilidad.

Por otra parte, el vehículo de pruebas al igual que la mayoría de vehículos de transmisión manual no dispone de un sensor de marchas o de neutro, por tal efecto esta información no puede ser conseguida de forma directa desde la ECU. Dadas las condiciones descritas es necesario recurrir a un clasificador basado en máquinas de soporte vectorial que pueda determinar cuando el motor se encuentre en ralenti basándose en los datos existentes de los vectores mostrados en la ecuación (3).

La clase pronosticada se muestra en el eje horizontal y la clase real se muestra en el eje vertical en la matriz de confusión, que también se conoce como matriz de clasificación. En la Figura 48, la diagonal verde indica las ubicaciones donde coinciden la clase verdadera y la clase pronosticada. Las celdas fuera de la diagonal representan cada clase predicha

incorrectamente. Se tienen en total 73434 muestras de las cuales solo 63 observaciones de la clase “1” son predichas como clase “0”, por lo que están ubicados fuera de la diagonal principal. No existen errores de observación de la clase “0” predichas como clase 1. Existen 73371 muestras clasificadas correctamente (99,91%) y tan solo 63 (0,09%) de forma incorrecta.




Figura 45. Matriz de confusión del número de observaciones para la estimación de ralentí.

Fuente: Propia.

La Figura 46 ilustra la construcción de la curva de características operativas del receptor (ROC) usando la unión de varios puntos, con el eje Y representando los verdaderos positivos y el eje X representando los falsos negativos. En ambos ejes se encuentran valores entre 0 y 1 (0% a 100%), y se traza una diagonal de referencia desde el punto 0,0 al punto 1,1, se puede observar también que el clasificador se encuentra en la coordenada (0.00, 1.00) es decir en el punto más alto de la unidad, mientras que los que fueron clasificados incorrectamente se encuentran en el punto más bajo. También tienen un área bajo la curva de 1,00, lo que demuestra que el clasificador asigna correctamente todas las observaciones a la clase verdadera.




Figura 46. Curva ROC para la estimación de ralentí.

Fuente: Propia.

Tras aplicar los vectores mostrados en la ecuación (3) a una máquina de soporte vectorial lineal como modelo clasificador se tiene la separación entre los datos obtenidos en ralentí y los obtenidos en otros regímenes de giro indicados en la figura 47.




Figura 47. Algoritmo para ralentí.

Fuente: Propia.

3.4.2.2. Estimación de la marcha seleccionada.

La relación de transmisión de cada marcha enumeradas en la tabla 21 tendrán un impacto directo en la cantidad de información que se puede obtener acerca del rendimiento del vehículo. Esto se debe a que no hay un sensor que pueda detectar automáticamente en qué marcha se encuentra el vehículo. Por lo tanto, estos valores se obtuvieron mediante la observación de la relación entre la velocidad del motor y la velocidad del vehículo durante un ciclo de conducción.

Tabla 21. Relaciones de transmisión

Relaciones de transmisión en ((km/h) /RPM)					
Neutro	1	2	3	4°	5
	◦	◦	◦		◦
0	0.0082	0.0136	0.0209	0 0.0274	0.0288

Para determinar la pendiente que corta por la mitad de los datos, tal como se muestra en la figura 48, se debe calcular la velocidad y agrupar los datos en un diagrama de velocidad. Se aplican límites de velocidad que dependen de la marcha para identificar cuántos datos pertenecen a cada marcha y así trazar una mediana precisa. Esto permite encontrar la pendiente que atraviesa el punto medio de los datos y brinda una representación visual y precisa de la relación entre la velocidad del motor y la velocidad del vehículo en cada marcha.




Figura 48. Diagrama de velocidades.

Fuente: Propia.

Con 11 observaciones neutrales fuera de la diagonal principal, la matriz que se muestra en la figura 49 refleja la precisión del 99,98 por ciento que se logró en el entrenamiento de confiabilidad, que es predicha incorrectamente como primera marcha y correctamente clasificada en 8351 observaciones, además se tienen 2 observaciones en primera marcha y quinta marcha predichas incorrectamente.




Figura 49. Matriz de confusión.

Fuente: Propia.

Se puede observar que el clasificador está en la coordenada (0.00, 1.00), indicando que están en la unidad que está en el punto más alto, mientras que los que fueron clasificados incorrectamente están en el punto más bajo y tienen un área bajo la curva de 1,00, lo que significa que el clasificador clasifica correctamente el 100% de las observaciones.




Figura 50. Curva ROC.

Fuente: Propia.

3.4.2.3 Estimación de aceleración, desaceleración y crucero

Durante el ciclo de conducción la velocidad parece ser constante sin embargo presenta variaciones, para poder identificar dichas variaciones y establecer una diferencia entre aceleración, crucero o desaceleración no se puede basar en la pendiente de la velocidad debido a que la derivada de dicha variable es la aceleración razón por la cual siempre habrá pendientes positivas y negativas es decir existirá un comportamiento de aceleración o desaceleración.

Se utiliza la lógica difusa para poder estimar en qué condiciones se encuentra el vehículo, para ello se entrena un sistema que se basa en la velocidad y en la posición del acelerador, mediante la interpretación de reglas se obtiene las conclusiones de variables de salida es decir va a indicar bajo qué condiciones se encuentra en aceleración, desaceleración y crucero, con esto se optimiza la clasificación que podría presentar un problema si no se utiliza un método convencional o una programación formal.

Como se indica en la figura 51 el método de inferencia del conjunto difuso utilizado en el presente estudio es el Mandami que tiene como vectores de entrada el TPS, la derivada

del TPS y la aceleración longitudinal con el fin tener un gasto computacional menor y de reducir su tiempo de ejecución como se mencionó en el capítulo anterior.




Figura 51. Método de inferencia del conjunto difuso.

Fuente: Propia.

3.4.2.3.1 Fuzzificación

El sistema difuso cuenta con tres variables de entrada TPS, $dTPS/dt$ (variación del TPS) y a_x (aceleración longitudinal). En la figura 52 (a) se indica que la variable TPS se evalúa de 0 a 100%, a la misma se le asociará tres conjuntos difusos con las etiquetas lingüísticas "Baja", "Media" y "Plena" esto en función de lo que se puede observar en el histograma del TPS (figura 36). La tasa de variación del TPS va del -15 al 15 %/s, en la cual se distinguen tres conjuntos difusos con las etiquetas "Desacelerado", "Neutro" y "Acelerado" como se indica en la figura 52(b), por último, la aceleración longitudinal oscila desde los -3 hasta los $3m/s^2$ a la que se asocia con tres conjuntos difusos aceleración positiva, aceleración negativa, aceleración neutra mostrados en la figura 52(c).

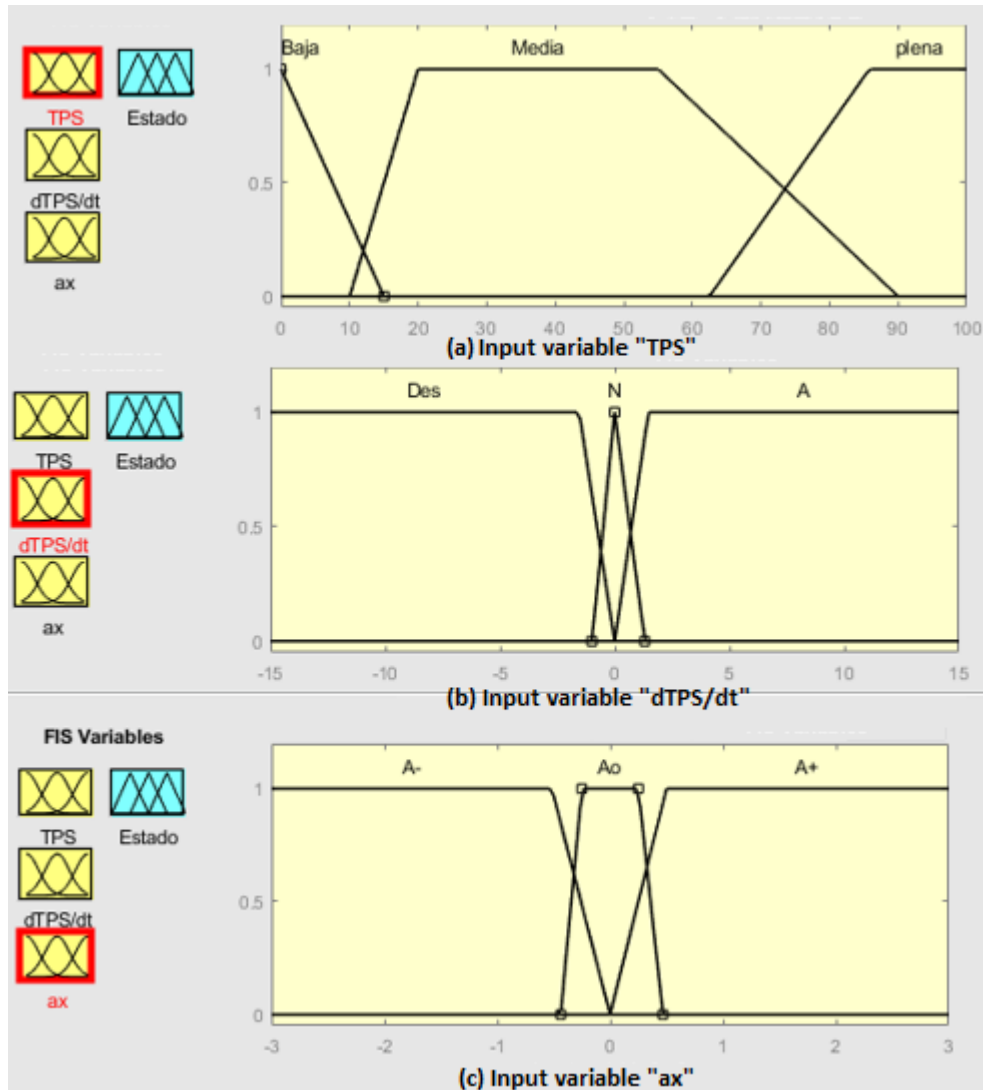


Figura 52. Función de membresía para aceleración, desaceleración y crucero.

Fuente: Propia.

3.4.2.3.2 Evaluación de reglas

Al usar un conjunto de reglas difusas (IF-THEN) del método Mandami, las mismas que han sido elaboradas por un experto en el ámbito de análisis de señales PID, el mismo menciona las siguientes reglas:

1. If (TPS is Baja) and (dtps/dt is N) and (ax is Ao) then (Estado is C) (1)
2. If (TPS is Media) and (dtps/dt is N) and (ax is Ao) then (Estado is C) (1)
3. If (TPS is plena) and (dtps/dt is N) and (ax is Ao) then (Estado is C) (1)
4. If (TPS is Baja) and (dtps/dt is Des) and (ax is A-) then (Estado is D) (1)

5. If (TPS is Media) and (dtps/dt is Des) and (ax is A-) then (Estado is D) (1)
6. If (TPS is plena) and (dtps/dt is Des) and (ax is A-) then (Estado is D) (1)
7. If (TPS is Baja) and (dtps/dt is A) and (ax is A+) then (Estado is D) (1)
8. If (TPS is Media) and (dtps/dt is A) and (ax is A+) then (Estado is A) (1)
9. If (TPS is plena) and (dtps/dt is A) and (ax is A+) then (Estado is A) (1)
10. If (TPS is plena) and (ax is A+) then (Estado is A) (1)
11. If (TPS is Media) and (ax is A+) then (Estado is A) (1)
12. If (TPS is Baja) and (ax is A+) then (Estado is A) (1)
13. If (TPS is Baja) and (ax is A-) then (Estado is D) (1)
14. If (TPS is Media) and (ax is A-) then (Estado is D) (1)
15. If (TPS is plena) and (ax is A-) then (Estado is D) (1)

Las superficies es la expresión gráfica de las reglas se presentan a continuación:




Figura 53. Expresión gráfica de las reglas.

Fuente: Propia.

3.4.2.3.3 Validación del sistema de inferencia del sistema difuso.

En la imagen 54 se presenta una herramienta para comprobar el modelo difuso, mediante la validación experimental de las reglas difusas, como se puede ver la variable de salida “ESTADO” concuerda con las tres variables de entrada, los estados presentados por el sistema de inferencia difuso autorizados por el experto son congruentes.

Ingresa al sistema difuso, el sistema difuso interpreta en que porcentaje de apertura se encuentra la mariposa, si es 6% interpreta como baja, 25% media, 80% alta. Para ello se encuentra las reglas difusas.

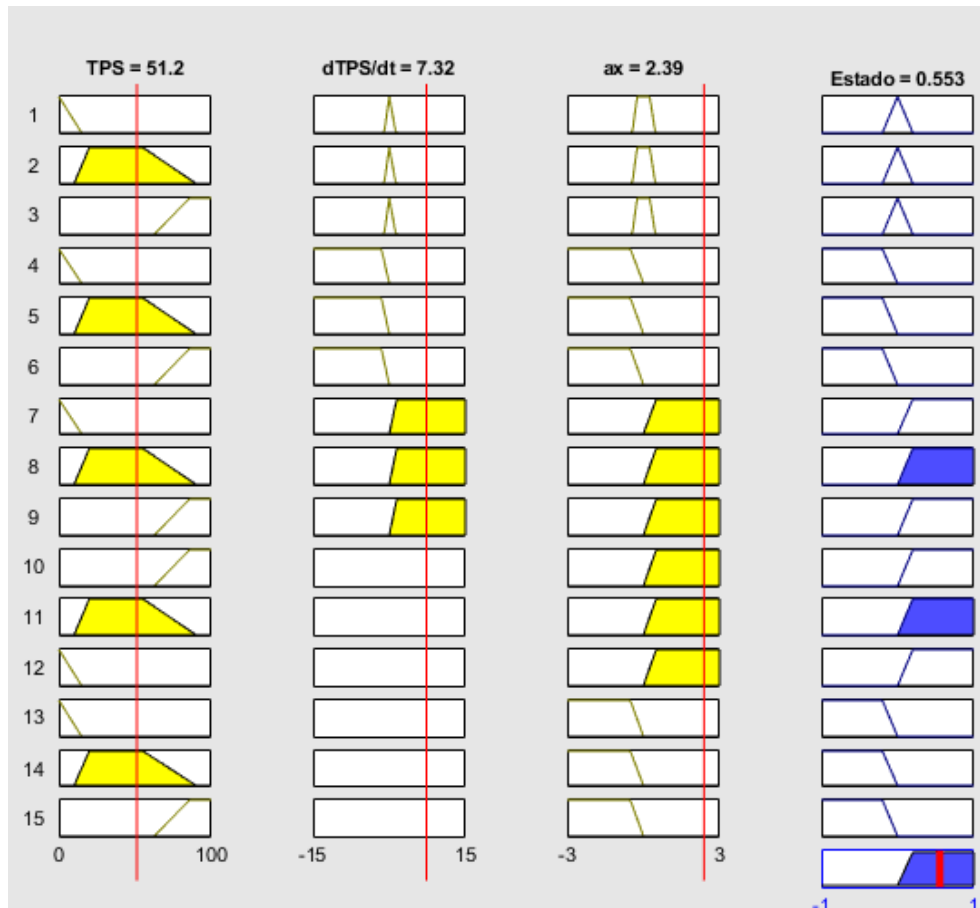


Figura 54. Validación del modelo difuso.

Fuente: Propia.

3.4.2.3.4. Defuzzificación

En el proceso de defuzzificación se asocia un valor numérico a los conjuntos difusos para calcular el valor de salida del clasificador difuso obtenido, la variable de salida se muestra como "Estado" tal como se indica en la figura 55, la variable se evalúa de 1 a -1, a la misma se le asociará un grado de pertenencia a: Desaceleración, Crucero, Aceleración.

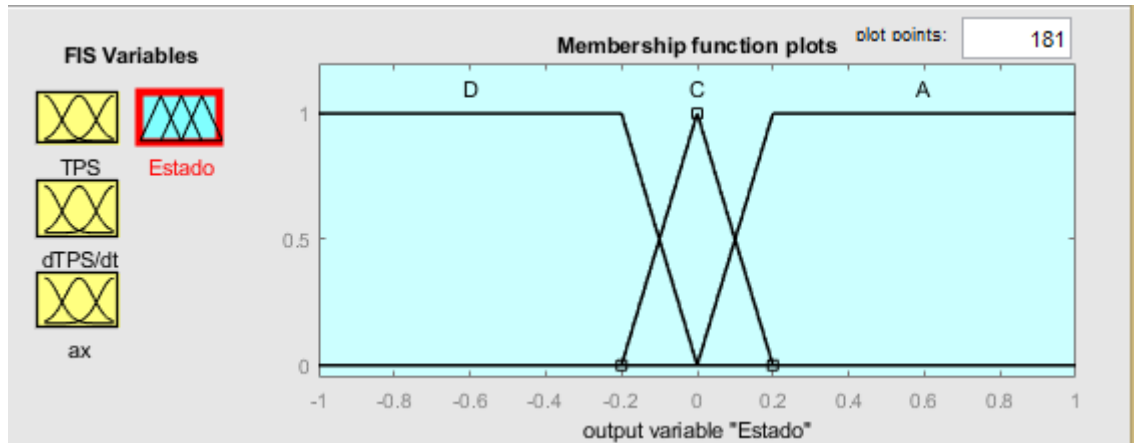


Figura 55. Función de membresía salida.

Fuente: Propia.

3.4.2.3.5. Resultados del estimador difuso

Al obtener el primer intento de calibración, las funciones de pertenencia están mal calibradas, según lo indica la figura 56, las curvas se encuentran muy separadas es decir existen datos en una sola categoría "cruceiro". El experto realiza la calibración del estimador difuso de donde se obtiene el segundo intento (b), se tiene que la categoría "cruceiro" es demasiado pequeña.




Figura 56. Calibración del estimador difuso.

Fuente: Propia.

Finalmente, el experto realiza la calibración del estimador difuso obteniendo un resultado óptimo presentado en la figura 57. Esto corresponde a ciclos reales no idealizados, por esta razón no se encuentran velocidades de cruceiro constantes, mientras que en

aceleración y desaceleración tienden a una velocidad constante con pequeñas oscilaciones.




Figura 57. Calibración del estimador difuso.

Fuente: Propia.

A partir de la ecuación (2) se obtiene la aceleración teórica, sin embargo, en la realidad no se puede decir que la aceleración cero es crucero por que no existe una velocidad constante en la trayectoria del vehículo.

El modelo difuso planteado anteriormente da como resultado el histograma que tiene ver con el TPS y la velocidad de la apertura del TPS indicado en la figura 58, presenta tres colores, los mismos que indican aceleración, crucero, y desaceleración.

La aceleración presenta una distribución normal, en la que se pueden distinguir diferentes niveles de aceleración negativa, neutral y positiva.




Figura 58. Histograma en función del TPS y velocidad de apertura del TPS.

Fuente: Propia.

3.4.2.4 Estimación del arranque en frío

Después de que el motor haya arrancado por primera vez y el refrigerante aún esté frío, el término "arranque en frío" se utiliza para describir el período de tiempo antes de que el refrigerante alcance la temperatura ideal de funcionamiento.

En el comportamiento de la temperatura del refrigerante en el arranque y durante la fase de calentamiento, se puede observar que la temperatura inicia en valores bajos, hasta alcanzar una temperatura de 90°C en donde se mantiene hasta llegar a una zona estrecha.




Figura 59. Estimación del arranque en frío.

Fuente: Propia.

Usando el estándar EURO 6 y la herramienta K-means, las dos áreas de trabajo, la fase de calentamiento y la fase de funcionamiento en caliente, se distinguen entre sí.

La Normativa EURO 6 establece que el periodo de arranque en frío se considera durante los primeros cinco minutos después de que el motor ha sido encendido, y finaliza cuando llega por primera vez a los 343 k (70°C), como se muestra en la figura 60. Sin embargo, este periodo de arranque en frío no se aplica nuevamente después del primer arranque del motor, una vez que la temperatura del refrigerante ha alcanzado el umbral establecido.




Figura 60. Estimación de la fase de calentamiento según Euro 6.

Fuente: Propia.

La herramienta k-means, basada en el centroide más cercano a la recta, utiliza dos grupos distintos para clasificar las fases de calentamiento y la fase de funcionamiento en caliente, tal como se ilustra en la figura 61. Esta técnica de análisis de datos permite agrupar y clasificar los datos en dos categorías diferentes, lo cual facilita la identificación y separación de las fases de calentamiento y operación en caliente en el proceso de análisis, las dos fases son separadas por un umbral de 80°C.

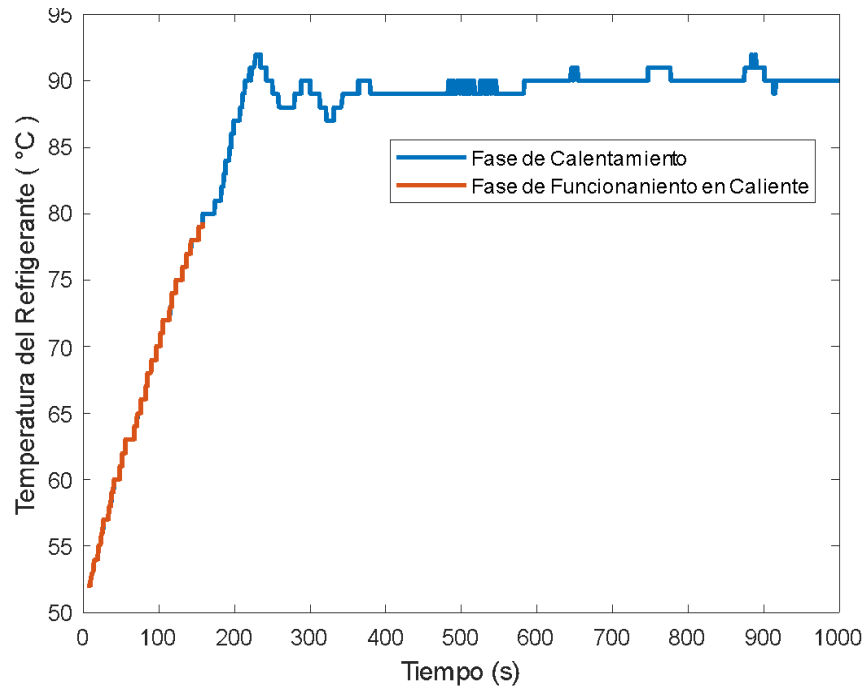


Figura 61. Estimación de la fase de calentamiento por K-means.

Fuente: Propia.

Se crea un vector que usa el tamaño de las variables de temperatura que se usarán como entrada y la temperatura que se puede usar como vector de salida como referencia antes de continuar con el entrenamiento de las RNA para clasificar las zonas de trabajo. Según la Figura 62, es una red de dos fases con seis capas y 10 neuronas., cabe mencionar que para el entrenamiento de utilizó el método de Scaled Conjugate Gradient que presenta 68 Iteraciones.

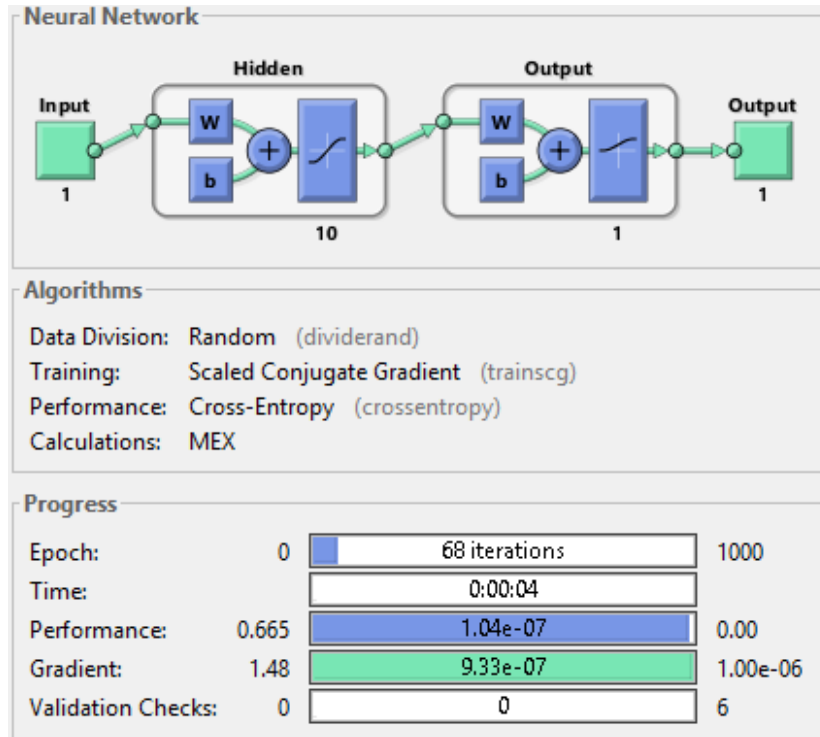


Figura 62. Red neuronal.

Fuente: Propia.

Para entrenar la red neuronal se utilizaron 59987 muestras para el entrenamiento, 12855 para la validación y 12855 para la prueba de la RNA según la figura 63.

Results			
	Samples	CE	%E icon"/> %E
Training:	59987	3.62009e-1	0
Validation:	12855	1.07707e-0	0
Testing:	12855	1.06546e-0	0

Figura 63. Resultados de la red neuronal.

Fuente: Propia.

A continuación, se presenta la validación, se puede observar que no existen errores.

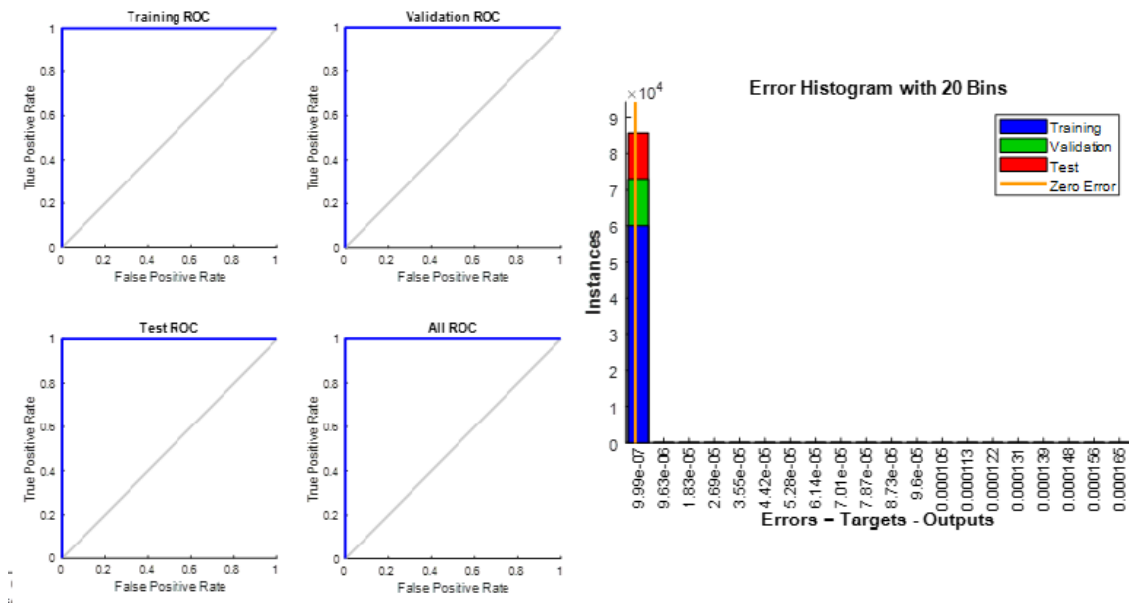


Figura 64. Validación de la red neuronal.

Fuente: Propia.

La figura 65 indica la matriz de confusión para entrenar la red, donde el porcentaje de la red entrenada y el número de instancias clasificadas correctamente se muestran en las dos primeras celdas diagonales. Esto significa que las corridas de temperatura experimental 59987 se categorizan apropiadamente con sus condiciones de operación correspondientes. Como se puede observar en la validación también se clasifica correctamente lo que indica que no existen errores.

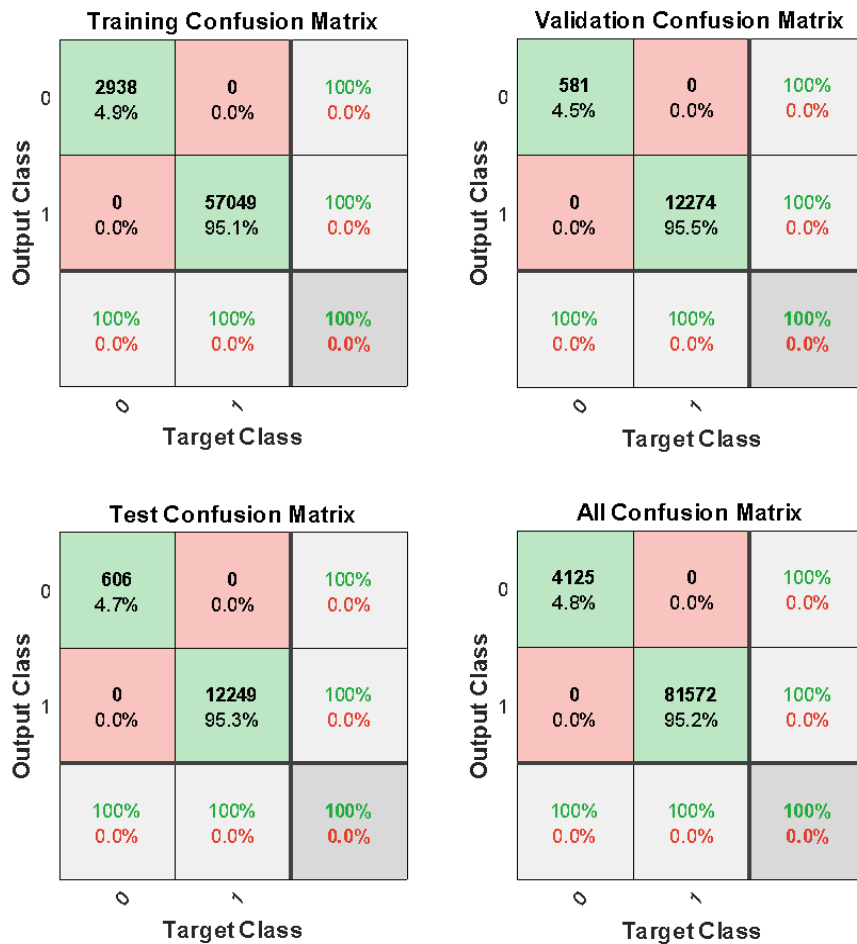


Figura 65. Matriz de validación.

Fuente: Propia.

Para estimar la fase de calentamiento por redes neuronales, se encuentra el valor de la moda que es 90°C como se indica en la figura 66, desde este valor hasta el máximo 93°C existe una distancia de 3°C, y por simetría se determina desde la moda hasta los 87°C zona como la de trabajo en caliente, cualquier valor por debajo de este se considera en la fase de calentamiento, con estos datos se obtienen las etiquetas para entrenar la red neuronal.




Figura 66. Estimación de la fase de calentamiento por redes neuronales

Fuente: Propia.

En la figura 67 se indica que la fase de calentamiento se da desde que el motor arranca hasta que alcanza una temperatura de 80° en donde existen menor cantidad de datos, se observa que y que gran cantidad de datos se encuentran en la fase de funcionamiento en caliente.




Figura 67. Histograma de fase de calentamiento vs fase de funcionamiento en caliente.

Fuente: Propia.

4. GENERACIÓN DE MODELOS MATEMÁTICOS

4.1. Modelación del algoritmo obtenido.

4.1.1 Sensor de oxígeno

Durante la toma de las muestras de las señales del O2, MAP, TPS, FTFT, LTFT, existen eventos como la aceleración, desaceleración y el recorrido en crucero y el ralentí del motor en cuyo estado no se genera la circulación del vehículo como lo indica el histograma de la figura 68, las barras de color rojo correspondientes a ralentí tienen pocas muestras y las de color azul que corresponden a todos los regímenes tienen muchas. Debido a que ralentí solo es un fragmento, no se puede realizar una comparación directa, para evitar dicho inconveniente se utiliza el histograma de área unitaria.




Figura 68. Histograma del comportamiento del sensor de oxígeno.

Fuente: Propia

El histograma de área unitaria toma una muestra sin importar su tamaño y hace que el área bajo la curva sea igual a 1, con lo que resulta posible comparar dos poblaciones de diferente tamaño, como una población de 7400 muestras correspondiente a la operación en todos los regímenes de funcionamiento y una población de 1000 muestras en ralentí. Se observa que durante la prueba en todos los regímenes de operación el valor que más

veces se repite en la tasa de variación del sensor de oxígeno es -0.1V/s que es donde la curva azul alcanza su valor máximo, mientras en ralentí la mayoría de los valores están en la banda de -0.5 a 0.4 V/s , como se muestra en el histograma de área unitaria de la tasa de variación en la figura 69.




Figura 69. Histograma de área unitaria de la tasa de variación del sensor de oxígeno en ralentí y todos los regímenes

Fuente: Propia

En la figura 70 se compara el comportamiento del sensor de oxígeno entre todos los regímenes de funcionamiento frente a la operación durante aceleración, desaceleración y crucero. Se observa que durante las aceleraciones se generan mayor cantidad de mezclas ricas alcanzando la señal su valor máximo en 0.73V , mientras que la mayor cantidad de mezclas pobres se consiguen en la gráfica que representa a todos los regímenes y se sitúa en un valor de 0.02V . La desaceleración se puede producir por dos razones, la primera es por soltar el acelerador en cuyo caso se empobrece la mezcla, lo que provoca que la señal del sensor de oxígeno llegue a un mínimo de 0.06V y la segunda causa se da por el incremento en la carga del motor en cuyo caso la mezcla se enriquece ocasionando que el sensor de oxígeno detecte la máxima cantidad de mezclas ricas alrededor de los 0.83V . En crucero la mayor concentración de datos se encuentra en 0.734V , presentando un

comportamiento bastante similar a la circulación en todos los regímenes de funcionamiento.




Figura 70. Histograma de área unitaria del sensor de oxígeno en todos los regímenes, aceleración, desaceleración y crucero.

Fuente: Propia

Es importante analizar también cómo se comporta la señal en estudio acorde a la marcha seleccionada por el conductor, en la imagen 71 se muestra el comportamiento del sensor de oxígeno durante todo el recorrido de prueba y mientras se utiliza cada una de las marchas del vehículo. En primera marcha se puede apreciar que se obtienen mayor cantidad de datos en mezcla rica, esto debido a que cuando la primera marcha se utiliza generalmente para el arranque del vehículo y recorridos donde se necesite de una alta fuerza tractora en los neumáticos por ende el accionamiento del acelerador será el máximo por parte del conductor. En segunda marcha se puede notar la disminución de la concentración de datos en mezcla rica esto debido a que esta es una marcha únicamente de paso entre primera y tercera, por lo que el motor no trabaja en altas prestaciones como es el caso de la primera marcha. Se debe considerar a la tercera marcha para analizar el sensor de oxígeno ya que la muestra es más estable y más representativa de lo que está sucediendo durante la circulación, al ser la marcha más utilizada durante la conducción en

las pruebas realizadas. Cuando se utiliza cuarta y quinta marcha se puede notar que la mezcla tiende nuevamente a enriquecerse, generando altas cantidades de datos en valores próximos a los 0.9V, esto debido a que estas marchas son utilizadas generalmente para que el vehículo circule a altas velocidades en autopistas o avenidas.




Figura 71. Histograma de área unitaria de la señal del sensor de oxígeno en todas las marchas y 1°, 2°, 3°, 4° Y 5° marcha.

Fuente: Propia.

En la figura 72, el comportamiento del sensor de oxígeno en la fase de calentamiento y en la fase de funcionamiento en caliente, se puede apreciar que durante la fase de calentamiento se presentan una mayor cantidad de datos en mezcla rica que en la fase de funcionamiento en caliente.




Figura 72. Histograma de área unitaria del sensor de oxígeno en la fase de calentamiento.

Fuente: Propia.

La figura 73 muestra el comportamiento del STFT durante la fase de calentamiento y la fase de funcionamiento. Se puede observar que, durante la fase de calentamiento, la densidad muestral es mayor en torno al 2% en comparación con la fase de funcionamiento. Esto indica que durante la fase de calentamiento, se realizan ajustes más frecuentes en el combustible para lograr una adecuada combustión y alcanzar el óptimo funcionamiento del motor.




Figura 73. Histograma de área unitaria en todas las marchas y en tercera.

Fuente: Propia

En la figura 74, la densidad muestral es mayor que en la fase de funcionamiento en caliente. se aprecia que la figura en cruceo se desplaza a la derecha, lo que indica un funcionamiento normal del LTFT.




Figura 74. LTFT en la fase de calentamiento y funcionamiento en caliente.

Fuente: Propia.

4.1.2 STFT

En el funcionamiento del automovil se aprecia que durante todos los regímenes la mayor cantidad de datos del STFT se encuentran en 0,72 %, al momento de acelerar los valores adoptados llegan a -0.45 %, lo que es un buen indicativo de su comportamiento normal. Durante el recorrido en cruceo el STFT se establece en valores próximos a 0.25% manteniendo un comportamiento bastante parecido al de todos los regímenes de funcionamiento, mientras que durante la aceleración la curva se desplaza a la izquierda y durante la desaceleración se desplaza mueve hacia la derecha, lo que quiere decir que el vehículo se encuentra en buenas condiciones permitiendo de esta manera encontrar patrones de conducta.




Figura 75. Histograma de área unitaria del ajuste de combustible a corto plazo en todos los regímenes, aceleración, desaceleración y cruceero.

Fuente: Propia.

4.1.3 LTFT

El LTFT mantiene un comportamiento similar en todos los regímenes, aceleración, desaceleración y cruceero como puede apreciarse en la figura 76. Durante las aceleraciones los valores de LTFT tienden a desplazarse hacia la izquierda es decir a valores próximos al 0%, mientras que en cruceero los valores tienden a dirigirse hacia la derecha con una diferencia del 0.3% respecto del comportamiento durante todos los regímenes de funcionamiento.




Figura 76. Histograma de área unitaria del LTFT en todos los regímenes, aceleración, desaceleración y cruceero.

Fuente: Propia.

4.2. Aplicación del algoritmo obtenido

Después de la recopilación de datos usando el automóvil en circunstancias normales de conducción "OK", se procede a generar fallas para aplicar el algoritmo obtenido.

Las fallas son generadas en el filtro de aire y en la calibración de las bujías, estas se eligen debido a su alta incidencia y puesto que son fallas incipientes que no generan código de avería, aparentemente no dan síntomas porque se encuentran en la primera etapa de ocurrencia.

Después de generar la falla 1 se recorren 30km de manera que se estabilizan los parámetros de funcionamiento para poder tomar los datos, posterior a ello se corrige la falla se recorren 30km y se genera la falla 2 se recorre 30km, para obtener la información se sigue el diagrama de la figura 77.

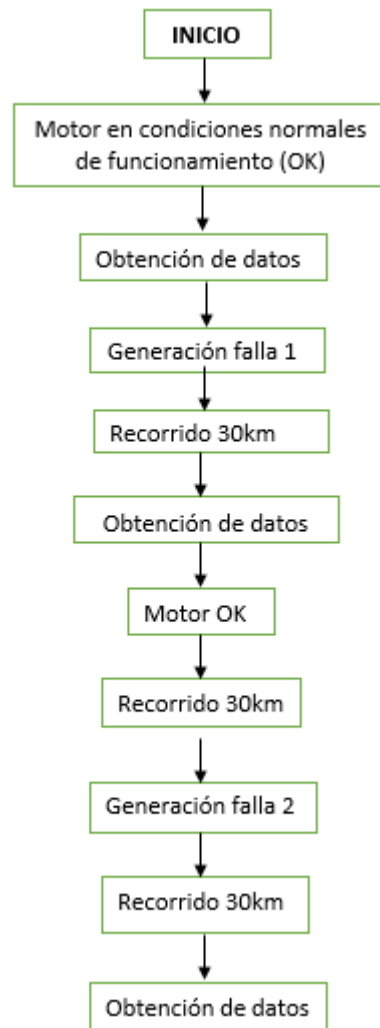


Figura 77. Esquema de generación de fallas.

Fuente: Propia.

4.2.1. Generación de fallas

Falla 1. Obstrucción del filtro de aire

El filtro de aire impide el ingreso de impurezas o partículas de polvo a la cámara de combustión, lo que ocasiona que este se tape, un filtro tapado presenta una modificación importante en los gases de escape, este aumento que proviene por una restricción del flujo de aire genera una mezcla rica y puede acompañarse por humo negro en la salida del escape, además de una disminución de potencia.

Para investigar esta falla, se analiza el funcionamiento del motor utilizando tanto un filtro de aire limpio como un filtro de aire sucio que obstruye el paso de aire durante la aspiración, cubriendo una parte significativa del filtro, tal como se indica en la figura 78.



Figura 78.Falla 1 Obstrucción del filtro de aire.

Fuente: Propia.

Falla 2. Calibración de las bujías

Las bujías garantizan buen rendimiento del motor, según la calibración de la bujía, dependerá el voltaje y la chispa entre sus electrodos, si se encuentran bien calibradas generan menor consumo de combustible, y baja expulsión de gases, por el contrario, si la separación de los electrodos es mayor ocasionará una mezcla pobre generando una disminución de potencia. Los fabricantes afirman que separación entre los electrodos para

motores de encendido por chispa es de aproximadamente 1 mm, valor que se determina para cada motor.

Para realizar las pruebas se utiliza una bujía en excelentes condiciones con una calibración de 1mm entre sus electrodos y una bujía en mal estado con una separación de sus electrodos de 1.3mm.



Figura 79. Calibración de las bujías.

Fuente: Propia.

4.2.2. Análisis de las señales O_2 , STFT, LTFT

En la imagen 80 se indica un extracto de como se comporta de la señal temporal del sensor de oxígeno cuando el motor está funcionando de manera normal para lo cual se cumple con los mantenimientos que recomienda el fabricante.




Figura 80. Extracto de la señal del sensor de oxígeno con motor OK

Fuente: Propia

4.2.2.1 Comportamiento con el filtro obstruido

Una vez generado el fallo la mezcla se enriquece debido a la dificultad que tiene el aire para ingresar al colector de admisión y por ende a los cilindros, por tal efecto se analiza la señal del sensor de O_2 , LTFT y STFT.

4.2.2.1.1. Sensor de oxígeno

La figura 81 muestra un extracto del comportamiento de la señal temporal del sensor de oxígeno durante el funcionamiento del motor con una mezcla rica, si se compara con la imagen 80 de cuando el motor se encuentra en estado "OK" no se puede apreciar ninguna diferencia para poder ser analizada esta señal se utilizaron las herramientas máquinas de soporte vectorial, redes neuronales, lógica difusa, etc.




Figura 81. Extracto de la señal del sensor de oxígeno con el filtro de aire obstruido
Fuente: Propia

Tras aplicar las diferentes herramientas se obtiene la señal del sensor de O_2 durante su operación normal y con mezcla rica presentada en la figura 82, se puede observar que cuando se da la falla existen más valores en mezcla rica, cuando se encuentra en operación normal los valores máximos llegan la mayoría de veces hasta 0.75 mientras que con falla se tiene una concentración en 0.8.




Figura 82. Sensor de oxígeno durante operación normal y mezcla rica.

Fuente: El autor.

4.2.2.1.2. STFT

En la figura 83 se presentan las curvas del STFT en operación normal y durante mezcla rica. Si el motor está trabajando con una mezcla rica el ajuste de corto plazo se hace más pequeño es decir se desplaza hacia la izquierda para disminuir el combustible por lo que presenta valores negativos, tiene muchos más valores negativos que en operación normal que prácticamente está sobre el cero.




Figura 83. STFT en operación normal y mezcla rica

Fuente: Propia

4.2.2.1.3. LTFT

En la figura 84 se indica el comportamiento del LTFT durante su operación normal y cuando se genera una mezcla rica, se puede observar que la señal se desliza hacia la izquierda lo que indica que se está retirando combustible.

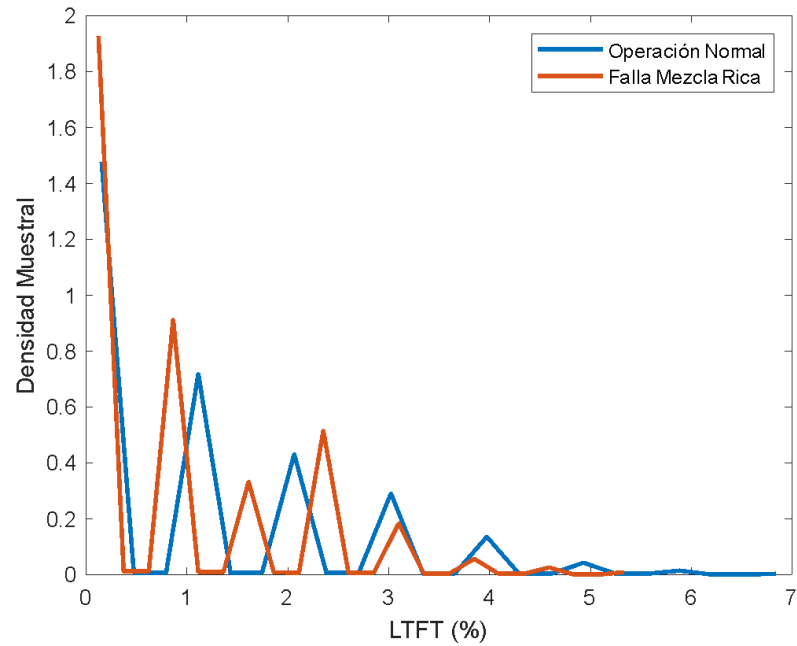


Figura 84. LTFT en operación normal y falla mezcla rica.

Fuente: Propia.

4.2.2.2 Falla en calibración de las bujías

4.2.2.2.1 Sensor de oxígeno

En la figura 85 se indica un extracto de la señal temporal cuando el motor trabaja con las bujías con una calibración de 1.3 mm, a simple vista resulta difícil poder interpretarla por lo que es necesario utilizar herramientas como máquinas de soporte vectorial, redes neuronales, lógica difusa, etc., para poder analizar las señales.




Figura 85. Extracto de la señal del sensor de oxígeno con bujías abiertas

Fuente: Propia

Al utilizar una bujía con un electrodo desgastado se genera un comportamiento similar al empobrecimiento de la mezcla debido a la mayor presencia de O_2 en los gases contaminantes, en la figura 86 se presenta la señal del sensor de durante su operación normal y con las bujías descalibradas, se puede observar que cuando se da la falla existen más valores en mezcla pobre, cuando se encuentra en operación normal los valores máximos llegan la mayoría de veces hasta 0.78 mientras que con falla se tiene una concentración en 0.65.




Figura 86. Señal del Sensor de oxígeno durante su operación normal y cuando falla la bujía
Fuente: Propia

4.2.2.2.2 STFT

Cuando las bujías se encuentran con los electrodos desgastados se incrementa el nivel de O_2 en los gases contaminantes lo genera que el sensor de oxígeno capte una mezcla pobre, en la figura 103 se puede apreciar su comportamiento durante dicha mezcla y durante su operación normal. Si el motor está trabajando normalmente se observa que la señal se encuentra en 0, si empieza a empobrecer la mezcla el ajuste de corto plazo se desplaza hacia la derecha para aumentar el combustible por lo que presenta valores positivos.




Figura 87. Señal del STFT durante operación normal y con falla en la bujía
Fuente: Propia.

4.2.2.2.3 LTFT

Los gases de escape contienen más oxígeno porque la mezcla aire-combustible no se quema completamente. En la Figura 88, el ajuste a largo plazo se representa con un comportamiento de 0 durante la operación normal y deslizándose hacia la derecha cuando ocurre una falla, agregando combustible.




Figura 88. Señal LTFT Operación normal y falla en la bujía

Fuente: Propia

Se puede concluir que el algoritmo obtenido ofrece mayor sensibilidad para la detección de fallas que no genera códigos de falla, puesto que al observar la señal del sensor de oxígeno en los tres casos planteados no se presentan aparentemente diferencias entre el motor en funcionamiento correcto y el motor con las 2 fallas planteadas.

CONCLUSIONES

- El umbral de control del Sensor de O₂ depende directamente de la temperatura, por lo cual se utiliza un algoritmo de aprendizaje no supervisado dado que no se tienen etiquetas que determinen el estado de la mezcla, tras la aplicación del algoritmo este divide en dos grupos previamente determinados como mezcla rica y pobre, que en teoría deberían separarse en el umbral de los 0.45 V, pero dado que el funcionamiento del vehículo en las condiciones de Cuenca dista de lo normalmente establecido, el límite de separación es de 0.4233 V.
- Para la estimación del estado ralentí, los instrumentos de clasificación y aprendizaje basadas en SVM lineal, consiguen una exactitud de 99.92%, debido a la correcta elección de las variables para el entrenamiento, y de que su adquisición se realizó acorde a las pautas de la normativa Euro 6.
- La MSV realizó la clasificación del diagrama de velocidad con un 99,98 % de precisión, lo que demostró la técnica de conducción, así como la marcha seleccionada y la que lleva más tiempo en el coche.
- En futuros estudios se debe considerar a la tercera marcha para analizar el sensor de oxígeno ya que la muestra es más estable y es más representativa de lo que está sucediendo en el vehículo.
- El algoritmo obtenido puede detectar comportamientos anómalos en la señal del sensor de O₂, que no se pueden detectar a simple vista en la señal temporal del mismo. A más de que puede detectar y diagnosticar una falla en etapa incipiente antes de la que la ECU genere un código de avería.

RECOMENDACIONES

- Encontrar el enfoque de aprendizaje y clasificación que tenga la mayor probabilidad de éxito es crucial para el entrenamiento de la base de datos porque surgirán fallas cuando se obtengan nuevos datos y nublarán la toma de decisiones.
- El algoritmo contiene todos los datos para este estudio, y los vectores de cada maniobra de conducción tratada pueden utilizarse para realizar una investigación más exhaustiva en situaciones en las que entran en juego otros factores.
- Esta característica requerirá un extenso registro de datos porque la herramienta K-means tiene problemas cuando los datos que se estudian tienen muy poca información.
- Repetir la investigación en varios vehículos para que la información se pueda aplicar a otras situaciones.

BIBLIOGRAFÍA

- Arévalo, F., & Ortega, A. (2016). *Desarrollo de una interfaz para la visualización y adquisición de datos provenientes de la ECU a través de OBD-II mediante un dispositivo de comunicación serial y del analizador de gases QROTECH 6000*. Cuenca: Universidad Politécnica Salesiana.
- Blanco, J., & Sanz, H. (2016). *Algoritmos de clustering y aprendizaje automático aplicados a Twitter*. Barcelona: Universidad Politécnica de Catalunya.
- Cabrera, A. &. (2018). *Desarrollo de un algoritmo mediante análisis de aprendizaje automático para la detección de fallos en vehículos M1 con motores de encendido provocado*. Cuenca: Universidad Politécnica Salesiana.
- Calderón, A. (2012). *Optimización de la potencia de un motor de combustión interna gasolina mediante el control de ajuste combustible y el monitoreo del sensor de oxígeno*. Latacunga: Escuela Politécnica del Ejército.
- Caparrini, F. (14 de Diciembre de 2019). *DISQUS*. Obtenido de <http://www.cs.us.es/~fsancho/?e=72>
- Casa, R. (2011). *Análisis de Parámetros de Información de Información de Diagnostico Pid's y Ajuste de Combustible LFT-SFT Mediante el Uso de Escáner en Vehículos de la Marca Chevrolet D-mas 3.0 Perteneciente a la ESPE Extensión*.
- Concepción, M. (2010). *Estrategias de Sistemas OBD II. U.S.A.: Automotive Diagnostics & Publishing*.
- Concepcion, M. (2011). *Sensores Automotrices y Análisis de Ondas de Osciloscopio*. En *Sensores Automotrices y Análisis de Ondas de Osciloscopio* (pág. 8). Londres: Paperbackshop-US.

- Euro 6, U. (2016). *REGLAMENTO (UE) 2016/427 DE LA COMISIÓN*. España.
- Gárate, D. (2018). *Desarrollo de un algoritmo para la adquisición y almacenamiento de datos provenientes del sistema de diagnóstico a bordo OBD II*. Cuenca: Universidad Politécnica Salesiana.
- INEN, 2. (2017). *GESTIÓN AMBIENTAL. AIRE. VEHÍCULOS AUTOMOTORES*. Quito.
- Martínez. (2009). *Estudio del comportamiento de las variables de un motor de Inyección electrónica respecto a la altura sobre el nivel del mar*. Quito: Universidad Politécnica Nacional.
- Matich, J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario: Universidad Tecnológica Nacional.
- Monroy, E., & Pérez, J. (2005). *Máquinas de soporte vectorial (SVM)*. Cartagena de Indias: Universidad Tecnológica de Bolívar.
- Ortiz, J. (2014). *Diseño de escáner automotriz OBDII multiprotocolo*. Guatemala: Universidad de San Carlos de Guatemala.
- REGULATION, C. (16 de Mayo de 2016). *Official Journal of the European Union*.
Obtenido de https://eur-lex.europa.eu/legal-content/EN/TXT/?qid=1582919720028&uri=CELEX:32016R0427&fbclid=IwAR2mfU5q4rNduu_8xlNkbTxqOrLXFi13vmNaSp8IgjP7tZPPid6zAO-lzX0
- Rivera, N., & Chica, J. (2015). *Estudio del comportamiento de motor ciclo otto de inyección electrónica respecto a la estequiometría de la mezcla y del adelanto al encendido para la ciudad de cuenca*. Quito: Escuela Politécnica Nacional.
- Rivera, N., & Vacacela, J. (2018). *Estudio de las señales PID's obtenidas a través de OBD II en función de las maniobras de conducción, arranque, cambio de marcha y freno*

- motor para el desarrollo de un algoritmo*. Cuenca: Universidad Politécnica Salesiana.
- Guzmán, D., & Castaño, M. (2006). La lógica difusa en ingeniería: Principios, aplicaciones y futuro. *Ciencia y Tecnología*, 87-107.
- Richard J. DuMont, J. A. (2009). Test and Control of Fuel Injector Deposits in Direct Injected Spark Ignition Vehicles. *SAE International by Big Ten Academic*, 1-6.
- Sánchez, C., & Delgado, S. (2012). *Implementación de un tablero didáctico del sistema de inyección electrónica multipunto Multec IEFI-6 para la Escuela de Ingeniería Automotriz*. Riobamba: Escuela de Ingeniería Automotriz.
- Sanahuja, S. (2017). *Sistemas de Control con Lógica Difusa: Métodos de Mandami y de Takagi-Sugeno-Kang*. Castellón: Univerasitat Jaume.
- Jiménez, F., López, J., & Alfonso, R. (2013). Determinación de ciclos de conducción en rutas urbanas fijas. *Dyna Ingeniería e Industria*, 681-688.
- Rivera, N., Muñoz, J., & Arenas, B. (2021). Estimación de emisiones contaminantes en condiciones reales de conducción basada en datos de OBD y aprendizaje automático. *Sensors*, 1-16.
- S. Scott Smith, W. I. (2013). Measurement and Control of Fuel Injector Deposits in Direct Injection Gasoline Vehicles. *SAE International by University of British Columbia*, 1-10.
- Smith, S. (2013). Measurement and Control of Fuel Injector Deposits in Direct Injection Gasoline Vehicles. 1-10.

- Académica, P. (15 de Noviembre de 2015). *Programa de integración a la docencia*.
Obtenido de <http://aprendeenlinea.udea.edu.co/lms/investigacion/mod/page/view.php?id=9131>
- AEADE. (24 de 09 de 2020). *Asociación de empresas automotrices del Ecuador*. Obtenido de <https://www.aeade.net/>: 2020
- Amat, R. (15 de Abril de 2017). *Máquinas de Vector Soporte (Support Vector Machines, SVMs)*. Recuperado el 23 de Septiembre de 2021, de https://www.cienciadedatos.net/documentos/34_maquinas_de_vector_soporte_support_vector_machines
- Booster, B. (25 de Noviembre de 2016). *Diagnostico por escáner*. Cuenca: Nuk publicaciones. Obtenido de slideshare: <https://es.slideshare.net/marcosch1/diagnostico-automotriz-1>
- Ulbotech. (29 de Abril de 2014). *Ulbotech*. Obtenido de <https://www.ulbotech.com/>

ANEXOS

