



**UNIVERSIDAD NACIONAL DEL ALTIPLANO**  
**FACULTAD DE INGENIERÍA MECÁNICA ELÉCTRICA,**  
**ELECTRÓNICA Y SISTEMAS**  
**ESCUELA PROFESIONAL DE INGENIERÍA MECÁNICA**  
**ELÉCTRICA**



**PREDICCIÓN DEL COMPORTAMIENTO DEL SENSOR DE**  
**PRESIÓN ABSOLUTA DEL MÚLTIPLE DE ADMISIÓN**  
**DE UN MOTOR A COMBUSTIÓN MEDIANTE**  
**REDES NEURONALES ARTIFICIALES**

**TESIS**

**PRESENTADA POR:**

**Bach. BELISARIO CALLASACA QUILCA**

**PARA OBTAR EL TÍTULO PROFESIONAL DE:**  
**INGENIERO MECÁNICO ELECTRICISTA**

**PUNO – PERÚ**

**2024**



# BELISARIO CALLASACA QUILCA

## PREDICCIÓN DEL COMPORTAMIENTO DEL SENSOR DE PRESIÓN ABSOLUTA DEL MÚLTIPLE DE ADMISIÓN DE UN M...

 Universidad Nacional del Altiplano

### Detalles del documento

Identificador de la entrega  
trn:oid::8254:415084875

107 Páginas

Fecha de entrega  
11 dic 2024, 1:00 p.m. GMT-5

17,558 Palabras

Fecha de descarga  
11 dic 2024, 1:08 p.m. GMT-5

100,555 Caracteres

Nombre de archivo  
TESIS UNA PUNO - BELISARIO CALLASACA Q 0.1 11\_12.pdf

Tamaño de archivo  
4.9 MB





## 19% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

### Filtrado desde el informe

- Bibliografía
- Texto citado
- Texto mencionado
- Coincidencias menores (menos de 8 palabras)

### Fuentes principales

- 15% Fuentes de Internet
- 4% Publicaciones
- 14% Trabajos entregados (trabajos del estudiante)

### Marcas de integridad

#### N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

JOSE MANUEL RAMOS CUTIPA  
ING MECANICO ELECTRICISTA  
CP 78419

M.Sc. Felipe Conderi Chambilla  
SUBDIRECTOR DE INVESTIGACIÓN  
EPIME



## DEDICATORIA

*A mis padres, Luis A. Callasaca Chuqitarqui y Delia Quilca de Callasaca, Agradezco mucho los valores y las lecciones que me han enseñado desde mi niñez y el apoyo que siempre me proporcionaron en todos los pasos de mi formación profesional. Nunca podré expresar completamente lo agradecido que estoy con ustedes. Este proyecto de tesis es un homenaje a su legado.*

*A mi prometida, por el apoyo mutuo que me ha brindado en este proceso de mi formación profesional y por ser una idónea perfecta que Dios me ha dado.*

***Belisario Callasaca Quilca***



## AGRADECIMIENTOS

*Antes que nada, quisiera dar gracias a nuestro Dios, por concederme la inteligencia para completar este trabajo de investigación, por brindarme el coraje para continuar y no darme por vencido. Este logro lo dedico a Dios.*

*A mis padres, por apoyarme siempre y su amor hacia mí. A mis hermanos menores, por estar siempre ahí presentes motivándome de una u otra manera y a mi novia por apoyarme en los momentos más arduos de nuestra vida. Sin ustedes, este logro no habría sido posible.*

*Además, deseo expresar mi agradecimiento a la Universidad Nacional del Altiplano, específicamente a la Escuela Profesional de Ingeniería Mecánica Eléctrica, por su formación profesional.*

***Belisario Callasaca Quilca***



# ÍNDICE GENERAL

	Pág.
<b>DEDICATORIA</b>	
<b>AGRADECIMIENTOS</b>	
<b>ÍNDICE GENERAL</b>	
<b>ÍNDICE DE TABLAS</b>	
<b>ÍNDICE DE FIGURAS</b>	
<b>ÍNDICE DE ANEXOS</b>	
<b>ACRÓNIMOS</b>	
<b>RESUMEN .....</b>	<b>17</b>
<b>ABSTRACT.....</b>	<b>18</b>
<b>CAPÍTULO I</b>	
<b>INTRODUCCIÓN</b>	
<b>1.1 PLANTEAMIENTO DEL PROBLEMA.....</b>	<b>19</b>
1.1.1 Formulación de problema .....	20
<b>1.2 OBJETIVOS.....</b>	<b>21</b>
1.2.1 Objetivo general .....	21
1.2.2 Objetivos específicos .....	21
<b>1.3 HIPÓTESIS .....</b>	<b>21</b>
1.3.1 Hipótesis general.....	21
<b>CAPÍTULO II</b>	
<b>REVISIÓN DE LITERATURA</b>	
<b>2.1 ANTECEDENTES .....</b>	<b>22</b>



2.1.1	Antecedentes internacionales .....	22
2.1.2	Antecedentes nacionales .....	24
<b>2.2</b>	<b>EL MOTOR DE ENCENDIDO PROVOCADO (MEP) .....</b>	<b>27</b>
2.2.1	Ciclo Ideal de operación.....	28
2.2.2	Ciclo Real de operación .....	29
<b>2.3</b>	<b>LA FORMACIÓN DE LA COMBINACIÓN DE AIRE-COMBUSTIBLE 30</b>	
2.3.1	Propiedades del Aire .....	32
2.3.2	Aportación del combustible .....	33
2.3.3	Dinámica del combustible.....	34
2.3.4	Formación del chorro .....	35
<b>2.4</b>	<b>SENSOR MAP.....</b>	<b>38</b>
2.4.1	Tipos de sensor MAP .....	40
2.4.2	Funcionamiento del Sensor MAP .....	40
2.4.3	Aplicaciones del sensor MAP .....	40
2.4.4	Tecnología del Sensor MAP.....	41
<b>2.5</b>	<b>REDES NEURONALES.....</b>	<b>42</b>
2.5.1	Neurona biología y artificial .....	42
2.5.2	Topología de una red neuronal .....	44
2.5.3	Elementos de una red neuronal .....	44
2.5.4	Aprendizaje y Entrenamiento.....	46
2.5.5	Clasificación de las redes neuronales.....	47
<b>2.6</b>	<b>DEFINICIÓN DE TÉRMINOS .....</b>	<b>47</b>



<b>2.7</b>	<b>RASPBERRY PI .....</b>	<b>50</b>
2.7.1	Características principales.....	52
<b>2.8</b>	<b>PYTHON.....</b>	<b>53</b>
2.8.1	Editor de texto IDLE para Python.....	53
<b>CAPÍTULO III</b>		
<b>MATERIALES Y MÉTODOS</b>		
<b>3.1</b>	<b>METODOLOGÍA DE INVESTIGACIÓN .....</b>	<b>54</b>
<b>3.2</b>	<b>VARIABLES DE LA INVESTIGACIÓN .....</b>	<b>55</b>
3.2.1	Definición de las variables .....	55
3.2.2	Operacionalización de variables .....	55
<b>3.3</b>	<b>POBLACIÓN Y MUESTRA.....</b>	<b>56</b>
3.3.1	Población.....	56
3.3.2	Muestra.....	56
<b>3.4</b>	<b>TÉCNICAS DE RECOLECCIÓN DE DATOS .....</b>	<b>56</b>
3.4.1	Recolección de datos .....	56
<b>3.5</b>	<b>MATERIALES .....</b>	<b>56</b>
<b>3.6</b>	<b>CONEXIÓN RASPBERRY PI CON EL PUERTO OBDII .....</b>	<b>59</b>
<b>3.7</b>	<b>SELECCIÓN DE DATOS DE MUESTRA.....</b>	<b>63</b>
3.7.1	Adquisición de Muestras .....	63
3.7.2	Selección de muestras .....	69
<b>3.8</b>	<b>ARQUITECTURA DE LA RED NEURONAL.....</b>	<b>74</b>
3.8.1	Tipo de red neuronal.....	74



3.8.2	Ingreso de datos.....	75
3.8.3	Red neuronal .....	80
3.8.4	Entrenamiento .....	80

## **CAPÍTULO IV**

### **RESULTADOS Y DISCUSIÓN**

<b>4.1</b>	<b>ANÁLISIS DESCRIPTIVO DE LOS DATOS OBTENIDOS .....</b>	<b>84</b>
4.1.1	Descripción General de las Muestras y Condiciones Experimentales ....	84
4.1.2	Comportamiento del Sensor MAP en diferentes escenarios de operación .....	84
4.1.3	Análisis Estadístico de las variables recolectadas.....	85
<b>4.2</b>	<b>RESULTADOS DEL MODELO DE PREDICCIÓN BASADO EN REDES NEURONALES.....</b>	<b>89</b>
4.2.1	Configuración y Entrenamiento del Modelo Predictivo .....	89
4.2.2	Evaluación de la Precisión y Confiabilidad del Modelo .....	90
<b>4.3</b>	<b>DISCUSIÓN DE RESULTADOS .....</b>	<b>92</b>
4.3.1	Precisión del Modelo Predictivo .....	92
4.3.2	Análisis del Comportamiento del Error .....	93
4.3.3	Comparación con Estudios Anteriores .....	93
4.3.4	Implicaciones Prácticas y Futuras Aplicaciones .....	94
<b>V.</b>	<b>CONCLUSIONES.....</b>	<b>96</b>
<b>VI.</b>	<b>RECOMENDACIONES .....</b>	<b>97</b>
<b>VII.</b>	<b>REFERENCIAS BIBLIOGRÁFICAS .....</b>	<b>98</b>
	<b>ANEXOS.....</b>	<b>101</b>



**Área:** Control y procesos

**Tema:** Predicción del comportamiento del sensor MAP

**Fecha de sustentación:** 18 de diciembre del 2024



## ÍNDICE DE TABLAS

	<b>Pág.</b>
<b>Tabla 1</b> Composición del aire .....	32
<b>Tabla 2</b> Características técnicas de la Raspberry pi.....	52
<b>Tabla 3</b> Definición de las variables independiente y dependiente .....	55
<b>Tabla 4</b> Operacionalización de variables independientes y dependientes .....	55
<b>Tabla 5</b> Parámetros de la red neuronal.....	75



## ÍNDICE DE FIGURAS

	<b>Pág.</b>
<b>Figura 1</b> Ciclo de motor de cuatro tiempos.....	28
<b>Figura 2</b> Diagrama PV del ciclo otto .....	29
<b>Figura 3</b> Diagrama PV real .....	30
<b>Figura 4</b> Sistema de admisión del aire .....	33
<b>Figura 5</b> Dinámica del combustible .....	35
<b>Figura 6</b> Inyector.....	36
<b>Figura 7</b> Inyección Monopunto y Multipunto.....	37
<b>Figura 8</b> El sensor MAP (Manifold Absolute Pressure) .....	39
<b>Figura 9</b> Circuito del sensor MAP .....	39
<b>Figura 10</b> Representación de una neurona biológica .....	43
<b>Figura 11</b> Neurona artificial.....	43
<b>Figura 12</b> Topología de la red neuronal perceptrón multicapa (MLP) .....	44
<b>Figura 13</b> Elementos de una neurona artificial .....	45
<b>Figura 14</b> Funciones de activación .....	46
<b>Figura 15</b> Unidad de control del motor ECU.....	48
<b>Figura 16</b> Diagnostico a Bordo (OBD).....	49
<b>Figura 17</b> Placa Raspberry Pi.....	50
<b>Figura 18</b> Conexiones hardware en Raspberry Pi.....	51
<b>Figura 19</b> Icono de Python.....	53
<b>Figura 20</b> Vehículo de prueba .....	57
<b>Figura 21</b> Motor de vehículo.....	57
<b>Figura 22</b> Raspberry Pi .....	58
<b>Figura 23</b> Sensor MAP.....	58



<b>Figura 24</b>	Escáner Automotriz ELM327.....	59
<b>Figura 25</b>	Diagrama de conexión.....	59
<b>Figura 26</b>	Conexión del escáner hacia el puerto OBDII.....	60
<b>Figura 27</b>	Conexión bluetooth del escáner con la Raspberry Pi.....	60
<b>Figura 28</b>	Códigos PID, primeros dígitos.....	61
<b>Figura 29</b>	Códigos PID, últimos dígitos.....	61
<b>Figura 30</b>	Diagrama de Flujo de obtención de datos.....	62
<b>Figura 31</b>	Datos obtenidos.....	63
<b>Figura 32</b>	Datos obtenidos de los sensores.....	64
<b>Figura 33</b>	Diagrama en función del tiempo del sensor MAP.....	65
<b>Figura 34</b>	Diagrama del sensor del Pedal del acelerador en función del tiempo.....	66
<b>Figura 35</b>	Diagrama del sensor de velocidad en función del tiempo.....	67
<b>Figura 36</b>	Diagrama de relación entre sensores a través del tiempo.....	68
<b>Figura 37</b>	Datos de la Muestra 1.....	70
<b>Figura 38</b>	Datos de la Muestra 2.....	71
<b>Figura 39</b>	Datos de la Muestra 3.....	72
<b>Figura 40</b>	Datos de la muestra 4.....	73
<b>Figura 41</b>	Datos de entrada y salida de la red neuronal.....	76
<b>Figura 42</b>	Matriz de entrada y salida de la red neuronal.....	77
<b>Figura 43</b>	Normalización de datos.....	79
<b>Figura 44</b>	Código de la red neuronal.....	80
<b>Figura 45</b>	Código para el entrenamiento de la red neuronal.....	82
<b>Figura 46</b>	Función de perdida.....	82
<b>Figura 47</b>	Histograma del sensor MAP.....	86
<b>Figura 48</b>	Velocidad del motor.....	87



<b>Figura 49</b>	Relación entre el pedal del acelerador y la cantidad de combustible .....	87
<b>Figura 50</b>	Gráfica de correlación de variables .....	89
<b>Figura 51</b>	MAPE a través del tiempo.....	91



## ÍNDICE DE ANEXOS

	<b>Pág.</b>
<b>ANEXO 1</b> Código Python para la inspección de datos .....	101
<b>ANEXO 2</b> Código Python para la implementación de la red neuronal.....	104
<b>ANEXO 3</b> Panel fotográfico.....	105
<b>ANEXO 4</b> Declaración jurada de autenticidad de tesis.....	106
<b>ANEXO 5</b> Autorización para el depósito de tesis de investigación en el repositorio institucional .....	107



## ACRÓNIMOS

RNR:	Red neuronal recurrente
MAPE:	Error porcentual absolute medio
MSE:	Error cuadrático medio
RNA:	Red neuronal artificial
OBD:	Diagnostico abordó
OBDII:	Diagnostico abordó segunda generación
MAP:	Sensor de Presión del múltiple de admisión
MLP:	Perceptrón multicapa



## RESUMEN

El problema general aborda la predicción del comportamiento del sensor MAP, esencial para el control de gases de escape y la eficacia del motor, de esta manera se busca mejorar la confiabilidad de los motores a combustión interna y garantizar un control eficiente de las emisiones contaminantes, contribuyendo así al cumplimiento de las regulaciones ambientales y a la reducción del impacto ambiental negativo. El objetivo es desarrollar un modelo que prediga con precisión las acciones del sensor MAP, aumentará la confiabilidad operativa y ayudará a reducir la contaminación del aire. Según la hipótesis general que se formuló consideraba que el comportamiento del sensor MAP se puede pronosticar con la mínima cantidad de equivocaciones utilizando el modelo que se basa en la red neuronal Perceptrón Multicapa (MLP). Los resultados mostraron una gran exactitud en la predicción, respaldados por análisis estadísticos, avanzando en el conocimiento del diagnóstico de motores a combustión interna y en la aplicación práctica en la industria automotriz. El experimento consistió en el estudio del sistema de admisión y el sensor MAP, se instaló un sistema de recolección de información que se fundamenta en una Raspberry Pi que se conectara a la computadora del automóvil por el puerto OBDII, se extrajeron los datos de diferentes sensores del automóvil en diferentes condiciones de manejo obteniendo así un data confiable y robusta, por último, se evaluó las entradas hacia la red neuronal obteniendo así el valor deseado del sensor MAP.

**Palabras clave:** Modelo de predicción, OBDII, Python, Preprocesamiento de datos, Raspberry Pi, Redes neuronales artificiales, Sensor MAP.



## ABSTRACT

The general problem addresses the prediction of MAP sensor behavior, essential for exhaust gas control and engine efficiency, thus seeking to improve the reliability of internal combustion engines and ensure efficient control of pollutant emissions, thus contributing to compliance with environmental regulations and reducing negative environmental impact. The objective is to develop a model that accurately predicts the actions of the MAP sensor, will increase operational reliability and help reduce air pollution. According to the general hypothesis that was formulated considered that the behavior of the MAP sensor can be predicted with the minimum amount of errors using the model that is based on the Multi-Layer Perceptron (MLP) neural network. The results showed a high accuracy in the prediction, supported by statistical analysis, advancing the knowledge of the diagnosis of internal combustion engines and the practical application in the automotive industry. The experiment consisted in the study of the intake system and the MAP sensor, an information gathering system was installed based on a Raspberry Pi that was connected to the car's computer through the OBDII port, the data from different sensors of the car in different driving conditions were extracted obtaining a reliable and robust data, finally, the inputs to the neural network were evaluated obtaining the desired value of the MAP sensor.

**Keywords:** Prediction model, OBDII, Python, Data preprocessing, Raspberry Pi, Artificial neural networks, MAP sensor.



# CAPÍTULO I

## INTRODUCCIÓN

Debido a las estrictas legislaciones relacionadas con las emisiones y al creciente requisito de economía de combustible por parte de los usuarios, se introdujo la utilización de sistemas de diagnóstico a bordo (OBD) en los motores de automóviles. Ahora la atención se ha centrado en los vehículos propulsados por motores diésel. El OBDII de los motores diésel utilizados en vehículos de carretera es obligatorio para los modelos a partir de 2010 en Estados Unidos, mientras que el EOBD (Diagnóstico a bordo europeo) es obligatorio en Estados Unidos desde 2000 (Carrabs Gonçalves, 2022).

Una parte importante del diagnóstico de fallas de los motores diésel en OBDII es el sistema de admisión de aire. Los sensores del sistema de aire desempeñan un papel vital en el control del estado del sistema de admisión de aire. El sensor de presión del colector de admisión se emplea para calcular la capacidad laboral del motor y su señal se utiliza para calcular el flujo de admisión del motor. Así se determina la cantidad de combustible que requiere el sistema de control del motor diésel.

### 1.1 PLANTEAMIENTO DEL PROBLEMA

El sistema de admisión en motores a combustión es inherentemente no lineal, y la dificultad para establecer modelos precisos de predicción y diagnóstico de fallas de manera efectiva plantea desafíos significativos en la operación y mantenimiento de estos motores (W. Contreras & J. Maldonado, 2019). Además, Carrabs Gonçalves (2022), indica que la correcta operación de un motor a combustión depende crucialmente del buen estado de componentes clave, como el Sensor de Presión Absoluta del Múltiple (MAP)



ya que es fundamental en el control de los gases de escape, contribuyendo directamente a la reducción de gases contaminantes hacia el medio ambiente.

El buen estado del sensor MAP garantiza una medición precisa de la presión de admisión, lo cual, a su vez, impacta directamente en la dosis de combustible inyectado y en la eficiencia de la combustión por lo que un sensor MAP en condiciones óptimas no sólo mejora la eficiencia del motor, sino que también ayuda a minorar las emisiones contaminantes hacia el medio ambiente (W. Contreras & J. Maldonado, 2019).

Por lo tanto, realizar un modelo que pueda predecir el comportamiento del sensor MAP no solo tiene implicaciones en la confiabilidad operativa de los motores a gasolina y diésel, sino también tiene un papel esencial en la reducción de la contaminación atmosférica.

Este trabajo de investigación no solo se enfocó en mejorar la confiabilidad de los motores a combustión mediante el pronóstico del comportamiento del sensor MAP, sino que también resalta la importancia ambiental al garantizar un control eficiente de las emisiones contaminantes.

### **1.1.1 Formulación de problema**

¿Cómo predecir el comportamiento del sensor de Presión Absoluta del Múltiple de Admisión (MAP) de un motor a combustión mediante el uso de redes neuronales artificiales?



## **1.2 OBJETIVOS**

### **1.2.1 Objetivo general**

Diseñar un modelo que pueda predecir el comportamiento del sensor de Presión Absoluta del Múltiple de Admisión (MAP) de un motor a combustión mediante el uso de redes neuronales artificiales.

### **1.2.2 Objetivos específicos**

- Describir el sistema de admisión de un motor a combustión y la función que cumple el Sensor MAP en dicho sistema.
- Implementar un sistema de adquisición de datos utilizando una Raspberry Pi para recopilar información en tiempo real del Sensor MAP.
- Evaluar la precisión y confiabilidad de las predicciones del comportamiento del sensor MAP de un motor de combustión realizadas por el modelo de redes neuronales artificiales.

## **1.3 HIPÓTESIS**

### **1.3.1 Hipótesis general**

Se plantea que el modelo de predicción del comportamiento del sensor de Presión Absoluta del Múltiple de Admisión (MAP) de un motor de combustión, utilizando redes neuronales artificiales, es capaz de predecir dicho comportamiento con el menor margen de error posible.



## CAPÍTULO II

### REVISIÓN DE LITERATURA

#### 2.1 ANTECEDENTES

##### 2.1.1 Antecedentes internacionales

Contreras & Arichávala (2018), en su proyecto de tesis desarrollaron "Determinación de la presión máxima de compresión de un motor de encendido provocado basado en una red neuronal artificial recurrente" una técnica nueva enfocada en el análisis de las curvas de consumo de corriente del sistema de arranque con el fin de calcular la presión máxima de compresión en un motor de combustión interna alternativo de encendido provocado (MEP). La metodología, que incluye la adquisición de datos, análisis estadístico y entrenamiento de una red neuronal artificial recurrente (RNAR), demostró una capacidad predictiva sobresaliente con un error total inferior al 2%. La validación práctica en motores en bancos didácticos y vehículos reales resalta la viabilidad y aplicabilidad del método en entornos del mundo real, subrayando la relevancia de esta propuesta para establecer con exactitud el nivel de presión máxima en los motores de combustión interna.

El trabajo de Escandon (2024) , se centra en el “Desarrollo de un sistema inteligente de diagnóstico de fallas mecánicas en motores de encendido provocado a través del sensor MAP para dispositivos móviles en plataforma Android”. Este proyecto técnico propone un enfoque novedoso para el análisis promedio de motores no invasivo , utilizando aprendizaje automático y redes neuronales para analizar datos de sensores MAP y predecir errores mecánicos , con la finalidad de



subir el rango de precisión y eficiencia en el mantenimiento automotriz. El sistema está validado mediante análisis estadístico ANOVA, demostrando una alta confiabilidad en la detección de errores y proporcionando una herramienta útil para los profesionales técnicos en el área de la ingeniería automotriz.

A. Cabrera (2018), desarrollo el proyecto técnico titulado “Desarrollo de un Algoritmo mediante Análisis de Aprendizaje Automático para la Detección de Fallos en Vehículos M1 con Motores de Encendido Provocado”. El trabajo se centra en crear un algoritmo de aprendizaje automático para detectar problemas tempranos en los vehículos M1, utilizamos una tecnología llamada Máquinas de Soporte Vectorial (SVM's) y el programa informático Matlab para estudiar cómo funcionan los sistemas y predecir posibles problemas para repararlos a tiempo. Esto nos ayuda a mejorar el servicio de mantenimiento de los automóviles, reduciendo el gasto de combustible, los costos de reparación y contaminación del aire.

Namigtle Jiménez (2018), en su tesis "Diagnóstico de fallas en un riel de inyectores mediante redes neuronales", propone una nueva forma de encontrar y arreglar problemas en los inyectores de un motor de carro. La solución propuesta utiliza un esquema basado en la identificación de señales mediante redes neuronales artificiales para clasificar las fallas. Este esquema opera en un sistema embebido, específicamente en un FPGA, implementándose al interior del sistema de inyección de combustible electrónico. La idea es usar tres redes de computadoras que simulan el cerebro humano para resolver problemas. Cada red tiene diferentes partes que trabajan juntas usando un algoritmo especial para aprender.



Tapia & Vasquez (2020) , en su tesis titulada “Diseño e Instalación de un Sistema de Control para Entrenamiento en el Sistema Electrónico del Vehículo Chevrolet Optra T/A”, presentan un estudio detallado sobre los sistemas electrónicos que controlan la inyección de combustible, la transmisión automática y los frenos antibloqueo de un carro. El documento explica cómo funcionan las partes eléctricas del Chevrolet Optra A/T, describiendo el diseño y diagramación de los circuitos electrónicos, así como su armado, desarmado y pruebas. Además, explica cómo hacer un sistema para aprender a usar la computadora del carro, que abarca características, elección de componentes, evaluaciones, instalación del sistema y manuales de prueba para cada sistema.

### **2.1.2 Antecedentes nacionales**

El siguiente proyecto de tesis titulado “Sistema de monitoreo para la detección automática de placas de vehículos en Lima Metropolitana utilizando redes neuronales” fue desarrollado por Montero & Ponce (2022), la investigación propone un sistema que mejora el reconocimiento y localización de vehículos reportados como hurtados o con infracciones viales en Lima, empleando redes neuronales y el algoritmo YOLOv4 para la identificación de placas de carros en tiempo real. El sistema se integra con bases de datos de entidades reguladoras para actualizar continuamente las infracciones y apoyar a la PNP en sus operativos. Además, se abordan apariencias de gestión de proyecto según la Guía PMBOK y para entender el problema, usamos el enfoque de Zachman. El diseño de la solución se representa mediante los diagramas del modelo C4, y se incluyen estudios de costos, prototipos de la aplicación y análisis de requerimientos.



Carrabs Gonçalves (2022), aborda en su tesis "Análisis de un sistema de combustión alimentado con combustibles (e-fuels) usando redes neuronales" los desafíos asociados con la predicción de procesos físico-químicos en la compleja y no lineal cámara de combustión de sistemas de propulsión actuales. En contraste con los costosos modelos tradicionales basados en dinámica de fluido computacional (CFD), la propuesta de este trabajo introduce una metodología alternativa que emplea técnicas de redes neuronales (Machine Learning - ML) para predecir de manera eficiente parámetros cruciales de la secuencia de combustión, como su impacto en las emisiones y rendimiento. El enfoque se centra en variar cinco parámetros clave del sistema de combustión y, mediante el modelo simulado, Se sugiere una mejora que tiene como objetivo disminuir la emanación de NOx y potenciar el desempeño térmico del motor.

El trabajo de ChafueL (2022), titulado como "Diseño y Construcción de un Sistema de Simulación de Circuitos para Pruebas en Banco de Sensores y Actuadores del Sistema de Gestión Electrónica del Motor de Combustión Interna", Se centra en creando un conjunto de pruebas que replican la combustión interna Unidad de Control Electrónico (ECU) del Motor de Combustión interna para diagnosticar eficazmente los sensores y actuadores del motor. El plan trata la urgencia de contar con herramientas de diagnóstico pendientes, dado el incremento en la complejidad de la electrónica de los automóviles, su impacto en las emisiones y el funcionamiento. Usando un enfoque analítico y experimental, se crea un conjunto de pruebas y se introduce una interfaz para el diagnóstico de vehículos de diferentes marcas, con el propósito de beneficiar tanto a la educación como a la industria del automóvil.



El proyecto de tesis «Reconocimiento automático de matrículas mediante una red neuronal convolucional para el ingreso de vehículos en la Universidad Ricardo Palma» presentado por B. Ramirez (2020), en la Universidad Ricardo Palma están trabajando en hacer un sistema que reconozca automáticamente las placas de los autos, empleando software Matlab y redes neuronales. El objetivo es reducir el tráfico al capturar y procesar fotos de placas de autos para crear una base de datos. Así, se puede mejorar la conexión de red neuronal para controlar el acceso de vehículos de forma más eficiente. La tesis se destaca por su enfoque práctico y aplicado, ofreciendo un prototipo que podría disminuir la interacción física entre el personal de seguridad y los conductores, mejorando así la seguridad y la eficiencia en los entornos universitarios.

Rodriguez & Castellanos (2020), en su artículo “Sensor MAF en vehículos utilitarios - posibles fallas un estado del arte”, presentan un estudio sobre el sensor de Flujo de Masa de Aire (MAF) abordando su importancia, funcionamiento, tipos, fallas y diagnósticos en vehículos. El artículo describe el desarrollo de sensores electrónicos en la industria automotriz, su papel principal en el desempeño del sistema de gestión del motor y la variedad de sensores, incluidos el MAP, el TPS y el sensor de oxígeno. El enfoque se centra en el sensor MAF, explicando su funcionamiento básico, errores comunes y métodos para diagnosticar y mantener esta parte esencial para la eficiencia del motor de mezcla de aire y combustible. También se cubren los requisitos para la correcta instalación del sensor MAF.



## 2.2 EL MOTOR DE ENCENDIDO PROVOCADO (MEP)

Los motores de combustión interna son aquellos que transforman la energía creada al quemar gasolina o diésel en movimiento para impulsar un vehículo. Reanudar Los motores de arranque a través de chispa (MEP) requieren un impulso externo para iniciar el proceso de combustión.

Actualmente, para que el motor funcione bien, se genera una chispa fuerte de electricidad entre los dos extremos de una bujía en el momento preciso, esto hace que el motor quemé combustible de la mejor manera. (Garzón & Urdiales, 2017).

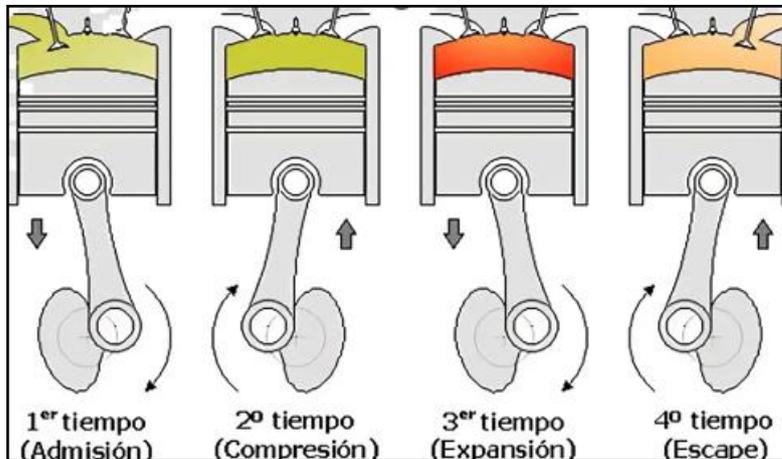
Los motores de arranque a través de chispa, La combinación de aire y combustible pueden mezclarse antes de entrar en el cilindro del motor, o simplemente entra aire durante este proceso, mientras que la compresión en el cilindro, se inyecta combustible, creando de esta manera una mezcla diversa y variada. El procedimiento de combustión se inicia con la ignición de una chispa en la bujía y la propagación de una llama a través de la cámara de combustión interna.

Es necesario mantener una combinación equilibrada de aire y combustible para que funcione bien, calculando el porcentaje de combustible y aire que se utiliza. Esto suele implicar la restricción del flujo en el conducto de admisión. En los motores de coche que funcionan con chispa, se controla el porcentaje de combustible que ingresa al motor de dos maneras diferentes: inyección directa o indirecta.

La figura 1 muestra el ciclo de un motor de cuatro tiempos.

### Figura 1

*Ciclo de motor de cuatro tiempos*



Nota. En la figura se observa un motor de cuatro tiempos, cada una de ellas realiza una de las fases del motor de cuatro tiempos, permitiendo de esta forma un movimiento continuo, tomado de Garzón & Urdiales (2017).

#### 2.2.1 Ciclo Ideal de operación

Los motores de cuatro tiempos de Otto necesitan girar dos veces el cigüeñal y mover el pistón cuatro veces para funcionar. Este método funciona muy bien, porque hace que el motor funcione mejor y más eficientemente (Maldonado, 2018).

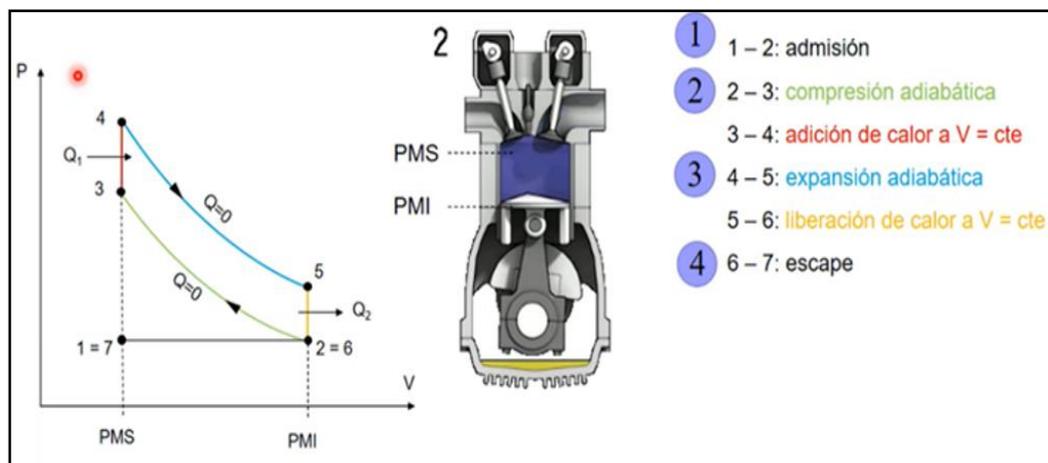
En el motor de cuatro tiempos de Otto, se toman en cuenta ciertas condiciones ideales: los gases que se queman son como un gas perfecto, la quema se realiza con el volumen constante, el pistón se considera un sistema cerrado y se asume que los calores específicos no cambian en todo el proceso (Montesinos, 2017).

El ciclo ideal de Otto se inicia al recibir el motor una combinación de aire y combustible. Esta combinación se comprime para permitir que reaccione al calor

agregado, convirtiendo la energía química en energía térmica. Posteriormente, cuando el motor se enciende, la combinación de aire y combustible explota en los cilindros y eso crea movimiento para que el auto funcione. Después de quemar los gases, se echan fuera y comienza otra vez el proceso de cargar el motor con una combinación nueva de aire y combustible, ver figura 2 (Moreno, 2016).

**Figura 2**

*Diagrama PV del ciclo otto*



Nota. La figura representa el proceso del ciclo ideal PV de un motor de cuatro tiempos, tomado de Moreno (2016).

### 2.2.2 Ciclo Real de operación

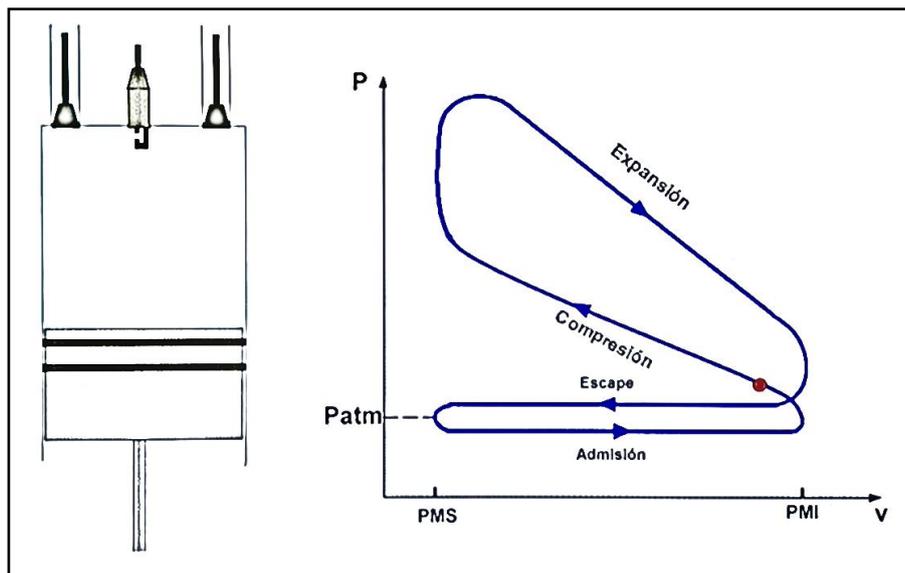
Según Montesinos (2017), el funcionamiento de un motor de gasolina o diésel, no se consideran las pérdidas de energía causadas por el calor producido por el roce entre las piezas mientras el motor se mueve. Estas carencias provocadas por fricción son consideradas como las más relevantes, representando aproximadamente el 60% del total de las pérdidas. En comparación, las pérdidas debidas al bombeo durante la renovación de la carga, su porcentaje es del 25% y las pérdidas del 15 % debido al accionamiento de elementos auxiliares. Además, en un ciclo real, se considera la disminución de energía causada por la refrigeración.

Las pérdidas mecánicas causadas por los sistemas auxiliares son responsables de que la eficiencia de los motores a combustión se sitúe típicamente entre el 20% y el 30%.

La figura 3 muestra el ciclo real P-V de un motor a 4 tiempos.

**Figura 3**

*Diagrama PV real*



Nota. El diagrama indicado o ciclo real representa el funcionamiento del motor de cuatro tiempos, tomado de Maldonado (2018).

### 2.3 LA FORMACIÓN DE LA COMBINACIÓN DE AIRE-COMBUSTIBLE

Es muy importante la combinación de aire-combustible en un motor de combustión interna es un proceso fundamental para el rendimiento eficiente del motor. Este proceso ocurre en el sistema de admisión del motor y se puede dividir en varios pasos:

**Admisión de aire:** El aire es aspirado desde el ambiente hacia el interior del cilindro del motor a través del sistema de admisión. Esto sucede cuando el pistón baja mientras entra aire en el motor (Carrabs Gonçalves, 2022).



**Mezcla de combustible:** Dependiendo del tipo de motor, se coloca el combustible en el cilindro del motor junto con el aire o se inyecta en forma de neblina o vapor. En motores de combustible la combinación de aire y combustible se produce tanto en el carburador (en los motores más antiguos) como en el sistema de inyección de combustible (en motores más actuales). En motores diésel, el combustible se añade directamente al interior del motor justo antes de que se encienda para que funcione (Carrabs Gonçalves, 2022).

**Mezcla homogénea o estratificada:** En los motores a gasolina, la combinación aire-combustible puede ser homogénea (una combinación uniforme de aire y combustible) o estratificada (donde el combustible se suministra en una cantidad reducida a la cámara de combustión y se concentra cerca de la bujía). La estratificación ayuda a que el motor funcione mejor y contamine menos en ciertas situaciones.

**Relación estequiométrica:** En motores que se usan combustible otto, es importante tener la dosis correcta de aire y combustible para que se quemé todo y funcione bien. Se busca tener más o menos 14.7 partes de aire por cada parte de combustible para lograr una buena combustión. Se puede usar más combustible en comparación con la porción de aire, porque la combustión se hace apretando el aire en lugar de encenderlo con una chispa. (Carrabs Gonçalves, 2022).

Una vez formada la combinación de aire-combustible dentro del cilindro, el pistón comprime la combinación durante la carrera de compresión, la mezcla experimenta un aumento en su temperatura y presión, preparándola para la combustión durante la carrera de potencia.

### 2.3.1 Propiedades del Aire

En términos prácticos, se extrae el oxígeno requerido para elaborar la mezcla de combustible del aire atmosférico. El aire está compuesto por distintos elementos, pero los principales son el nitrógeno y el oxígeno, que cercanos representan aproximadamente el 98,7% de la masa total. Se puede decir que hasta más o menos 15 kilómetros de altura, ver tabla 1 para ver los componentes del aire (Nevot, 1999).

**Tabla 1**

*Composición del aire*

Gas	% volumen	% masa	Peso Molecular (g)
$N_2$	78,09	75,52	28,02
$O_2$	20,95	23,15	32
Ar	0,93	1,28	39,95
$CO_2$	0,03	0,05	44,01
Ne	0,0018	0,0012	20,18
He	0,0005	0,00007	4,003
Kr	0,0001	0,0003	83,80
Xe	0,000009	0,00004	131,3
$H_2$	0,00005	0,000004	2,016
Aire seco	100	100	28,96

Nota. La tabla 1 nos indica la composición del aire, obtenido de Nevot (1999).

El oxígeno tiene alrededor de un 21% de oxígeno. En peso, ese porcentaje es un poco más alto, alrededor del 23%. Esto es así cuando nos referimos al aire seco al nivel del mar. Se mantiene igual hasta los 15 km de altura, luego va disminuyendo 0,2% por cada km que sube.

Los cilindros se llenan cuando el pistón baja y succiona aire por medio de la válvula de admisión abierta, o cuando se comprime el aire antes de entrar, que es lo que se llama sobrecarga. En contraste con un motor diésel, el motor Otto solo

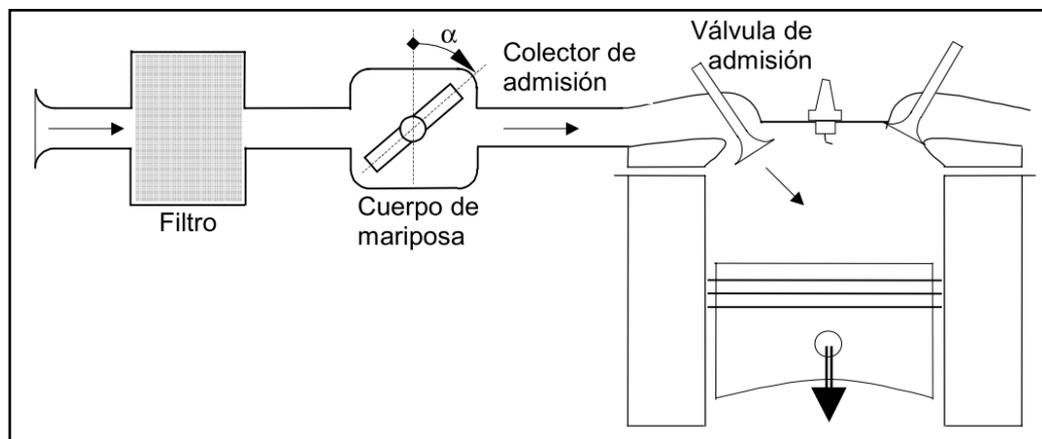
tiene la capacidad de controlar la carga mediante la cantidad de combinación que ingresa y se quema en el cilindro.

Como la potencia que se genera en cada ciclo depende de la cantidad de aire que se utiliza, es necesario mantener la misma cantidad de aire para obtener buenos resultados.

La regulación del flujo de aire se realiza a través de una válvula de mariposa, instalado en el colector de admisión, y el conductor la controla a través del pedal del acelerador. La mariposa hace que el flujo de agua se reduzca de forma diferente, por lo que la presión arriba es como la del aire, pero abajo siempre será más baja (Nevot, 1999).

#### Figura 4

##### *Sistema de admisión del aire*



Nota. La figura muestra cómo controlar la cantidad de aire con una válvula de mariposa, tomado de Nevot (1999).

#### 2.3.2 Aportación del combustible

La gasolina es un tipo de combustible muy común que se obtiene de ciertas partes del petróleo cuando se calienta a temperaturas entre 20 y 150 grados



Celsius. Esto significa que es una combinación de sustancias que se hallan en estado líquido cuando están a temperatura y presión normales (Nevot, 1999).

Desde el punto de vista químico, estos hidrocarburos pueden clasificarse en:

- **Parafinas o alcanos:** se componen de cadenas saturadas vinculadas por enlaces sencillos, con la fórmula habitual  $C_nH_{2n+2}$ .
- **Olefinas:** cadenas insaturadas que contienen al menos un doble enlace. Se formulan como  $C_nH_{2n}$  (monoolefinas o alquenos) si tienen un enlace doble, y como  $C_nH_{2n-2}$  (diolefinas o alcadienos) si tienen dos enlaces dobles.
- **Naftenos o cicloalcanos:** Los naftenos son unas sustancias con moléculas en forma de anillo cerrado y solo tienen enlaces simples, su fórmula es  $C_nH_{2n}$ .
- **Aromáticos:** son como anillos conectados, pero con dos enlaces en lugar de uno. Este grupo está hecho principalmente de benceno ( $C_6H_6$ ), una sustancia con tres enlaces dobles.

### 2.3.3 Dinámica del combustible

Independientemente del sistema utilizado para formar la mezcla, se siguen una serie de fases desde que el combustible se introduce en la corriente de aire que entra al motor sigue su camino hasta mezclarse con el combustible y quemarse.

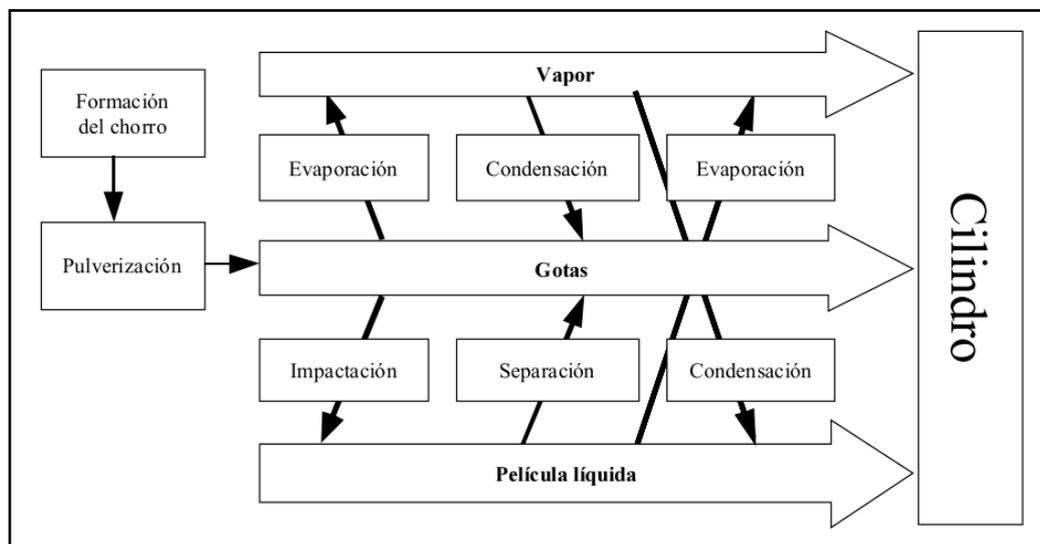
Primero, se coloca la gasolina en el motor, ya sea por succión (a través de la carburación) o por presión (a través de la inyección). Este combustible se rompe en pedacitos muy pequeños, que se convierten en líquido y después en vapor. El vapor y las gotas van al cilindro rápido, pero el líquido va lento. Pero parte de la

gasolina que está líquida se convierte en vapor otra vez. Esto ocurre cuando la válvula de admisión está abierta, y tanto la gasolina líquida como la vaporizada entran en el cilindro (Nevot, 1999).

La figura 5 resume todos los estados y fenómenos que ocurren, que se detallan en los siguientes segmentos.

**Figura 5**

*Dinámica del combustible*



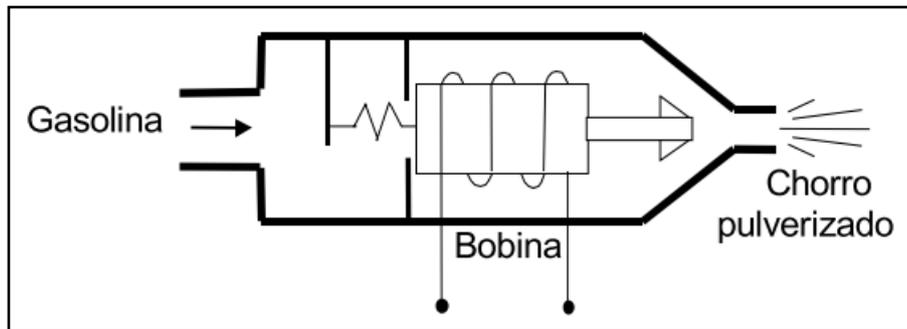
Nota. La figura muestra cómo cambian las fases de combustible en el colector de admisión, tomado de Nevot (1999).

### 2.3.4 Formación del chorro

Desde que dejamos de usar el carburador, ahora usamos solo el inyector para mezclar el combustible en los motores, en la fig. 6 puedes ver cómo es este aparato.

## Figura 6

### *Inyector*



Nota. La figura representada de forma esquemática es el inyector, tomado de Nevot (1999).

Lo que más importa es que la cantidad de combustible que se usa no depende del porcentaje de aire que ingresa al motor, al contrario de los carburadores donde se relacionan por leyes físicas.

Según Nevot (1999), la inyección ocurre cuando un líquido presurizado llega al inyector, gracias a una bomba eléctrica que está en el tanque. Una aguja, cuyo extremo se presiona contra el final del inyector mediante un muelle, obstruye los conductos de escape y obstaculiza la expulsión del combustible. Cuando la central eléctrica manda una señal, un electroimán hace que la aguja suba y los orificios queden visibles al neutralizar la fuerza del muelle. La cantidad, dimensión y ubicación de los orificios facilitan la obtención de un flujo de combustible pulverizado, que se combina con la corriente de aire que pasa por el colector de admisión, dando lugar a la mezcla de combustible.

Además, Nevot (1999), indica que es importante mantener siempre la misma presión de alimentación del combustible en el colector de admisión para que el inyector funcione correctamente. Esto se logra con un regulador de presión bien ajustado. Si hay demasiado combustible, vuelve al depósito.

Los sistemas de inyección pueden categorizarse de la forma siguiente:

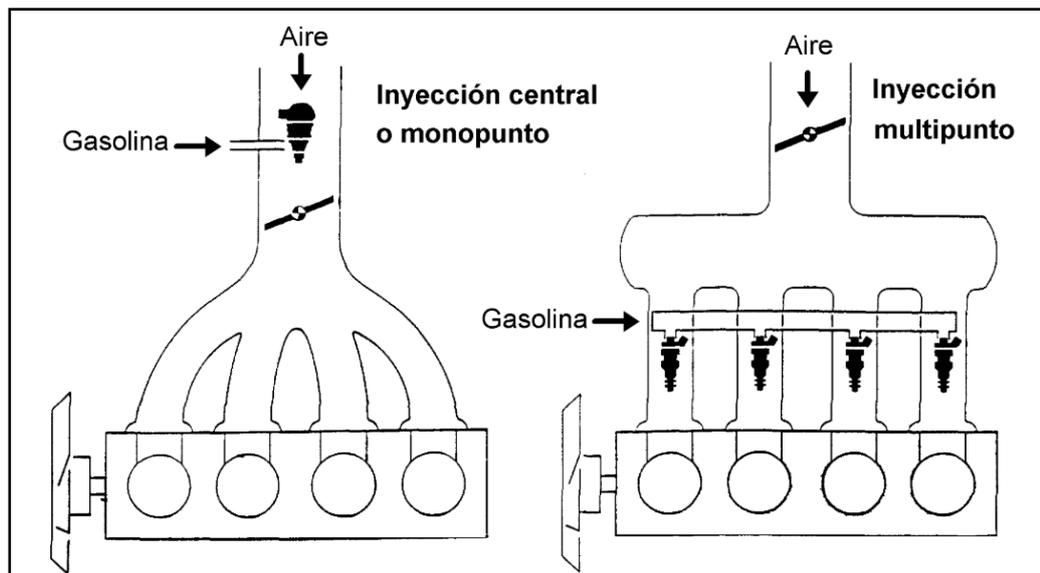
Debido a la cantidad de inyectores:

- **Monopunto o central:** un solo inyector en lugar de varios para todos los cilindros antes de la entrada de aire. Es como una versión mejorada del carburador, tiene cosas buenas y malas igual que él.
- **Multipunto:** un inyector por cilindro, después de la mariposa. Esto hace que el combustible llegue más rápido al motor para que funcione mejor y responda rápidamente aun cuando está frío. Además, permite un mayor rendimiento volumétrico.

La fig. 7 se observa la clasificación de los dos sistemas de inyección monopunto y multipunto.

**Figura 7**

*Inyección Monopunto y Multipunto*



Nota. En esta fig. se puede ver la clasificación de los sistemas de inyección monopunto y multipunto, tomado de Nevot (1999).

Debido al sincronismo de la inyección:

- **Simultánea:** los inyectores se destapan o se abren a la misma vez. Es más fácil de gestionar.
- **Secuencial:** Los inyectores se abren en el instante que es necesario para cada cilindro, concretamente antes de que la válvula de entrada se abra. Esto lo hace posible distribuir la mezcla con mayor precisión, más precisamente para bajar Riesgo de explosión y reducir también las emisiones que contaminan el aire (Nevot, 1999).

Por la posición del inyector:

- **Directa:** dentro de la parte donde se quema el combustible. Se necesita una presión elevada, que pueda superar los 100 bares.
- **Indirecta:** en la culata o en el colector de la válvula de admisión es el más ampliamente aplicable.

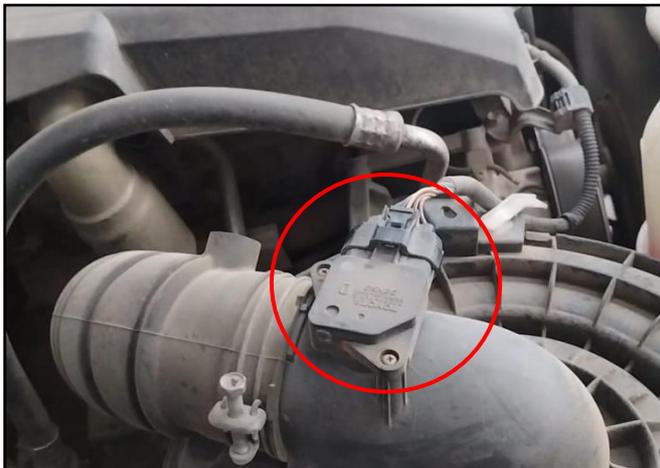
## 2.4 SENSOR MAP

El sensor MAP (Presión Absoluta del Múltiple) es una pieza muy importante en los autos, porque nos dice cuánto aire entra al motor y así podemos saber cuánto combustible necesita para funcionar bien. En muy poco tiempo, el sensor del motor manda una señal a la computadora del carro para saber cuándo encender el motor o cuándo abastecer combustible (Rodríguez & Castellanos, 2020).

El sensor MAP se conecta al motor a través de una manguera. Está ubicado en el motor después de la mariposa de admisión, como se muestra en la figura 8.

## Figura 8

*El sensor MAP (Manifold Absolute Pressure)*

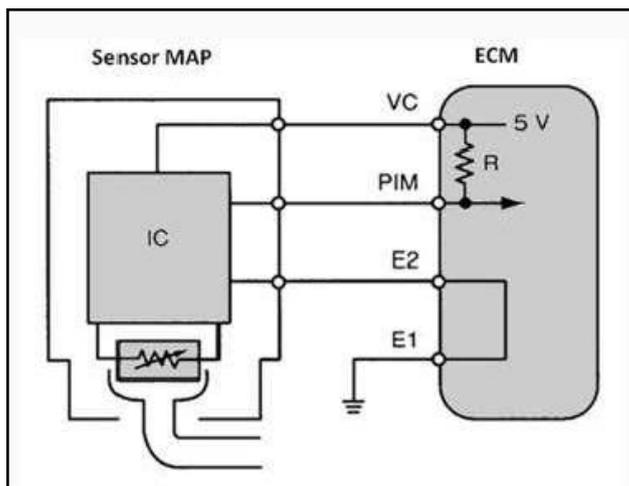


Nota. El sensor MAP se encarga de controlar la cantidad de aire que puede entrar al motor.

La señal de voltaje del sensor MAP es más alta cuando la presión del múltiple de admisión es mayor, como cuando enciendes el carro o aceleras de repente. Cuando levantas el pie del acelerador, la señal de voltaje del sensor MAP es la más baja porque la presión en el múltiple de admisión también es la más baja.

## Figura 9

*Circuito del sensor MAP*



Nota. El ECM mide la señal de voltaje en el terminal PIM. El sensor percibe 5 voltios del ECM a través de la línea VC. El sensor se conecta a la computadora a través de un cable. Si se desconecta el cable, la señal será de 5 volts, tomado de Rodríguez (2020).



### 2.4.1 Tipos de sensor MAP

Existen 2 tipos de sensores MAP que funcionan de manera diferente, pero hacen lo mismo:

- **Por cambio de frecuencia:** El sensor mide la presión absoluta dentro del motor. El sensor envía una señal eléctrica a la computadora del carro dependiendo de cuánto aire entre al motor.
- **Por variación de voltaje:** El sensor usa cristales de silicio para medir la cantidad de aire, ya que son resistentes al calor. La tensión y el voltaje de la resistencia cambian dependiendo del flujo que llegue al sensor. La señal se envía a la unidad de control del coche para que comprenda la información.

### 2.4.2 Funcionamiento del Sensor MAP

El sensor MAP es un aparato que mide la presión del aire dentro del motor y la compara con la presión atmosférica. Manda esos datos a la computadora del carro, que decide si se necesita más combustible. Gracias al sensor, el motor funciona de forma más eficiente.

El ECM utiliza estos datos para calcular la densidad del aire que ingresa al motor y ajustar la porción de material inflamable que se enciende de manera correspondiente (Hurtado Cortés et al., 2016).

### 2.4.3 Aplicaciones del sensor MAP

El sensor MAP se utiliza en muchas cosas para controlar cómo funciona el motor, entre las que se incluyen son:



- **Control de la sobrealimentación:** En el caso de los motores sobrealimentados se utiliza el sensor MAP para regular la presión de sobrealimentación, lo que permite el ECM regule la magnitud de aire y combustible suministrado al motor para maximizar la potencia y la eficiencia.
- **Control de combustible:** El sensor MAP proporciona datos en tiempo real sobre la presión del aire en el múltiple de admisión, lo que permite que el ECM controle la cantidad de combustible que entra en el motor para que la mezcla de aire y combustible sea la adecuada y el motor funcione correctamente.
- **Control de la recirculación de gases de escape (EGR):** En algunos sistemas, el sensor MAP se usa para controlar la cantidad de gases de escape que vuelven al motor a través del conducto de admisión.
- **Diagnóstico de fallas:** El sensor MAP también se utiliza para detectar errores o fallos en el motor. Si el sensor falla o proporciona lecturas inexactas, el ECM puede identificar el problema y encender la luz de advertencia del motor en el salpicadero (Carrabs Gonçalves, 2022).

#### 2.4.4 Tecnología del Sensor MAP

Los sensores de presión de aire en el motor usan tecnología avanzada para medir con exactitud cuánto aire entra al motor. Algunas características adicionales de los sensores MAP están incluidas:

- **Tecnología de película delgada:** Diversos sensores MAP emplean una capa fina de silicio para calcular la presión del aire. Esta tecnología ofrece

un veredicto rápido y una gran precisión en una amplia gama de circunstancias de funcionamiento del motor.

- **Compensación de temperatura:** Los sensores MAP avanzados están creados para tener en cuenta cómo la temperatura afecta a las mediciones de presión del aire.
- **Autodiagnóstico:** Algunos sensores MAP tienen funciones de autodiagnóstico que permiten la ECM identificar y diagnosticar problemas con el sensor, como lecturas inexactas o fallas en el circuito (Hurtado-Cortés et al., 2016).

## 2.5 REDES NEURONALES

Son como un programa de computadora que imita cómo funciona nuestro cerebro para encontrar cosas repetitivas en la información. Para comprender cómo funcionan las redes neuronales, primero se debe de comprender las diferencias o similitudes entre microprocesador, computadora y el cerebro humano, que analiza las bases teóricas de las redes neuronales y las explica (Oquendo, 2011).

### 2.5.1 Neurona biología y artificial

#### 2.5.1.1 Neurona biológica

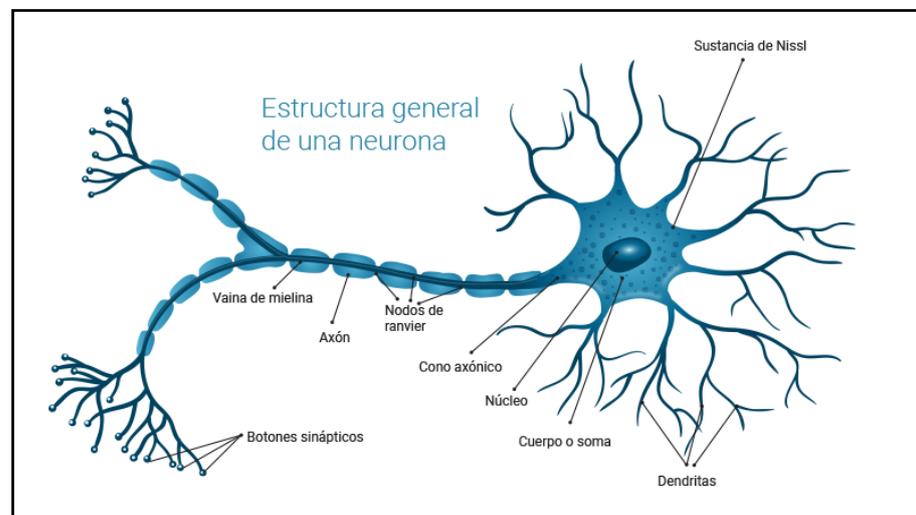
En el sistema nervioso biológico, las neuronas son células especiales que se encargan de enviar información a otras células a través del sistema nervioso. El cuerpo de una neurona tiene tres partes importantes: el cuerpo celular, el axón y las dendritas. Las dendritas reciben mensajes de otras neuronas, luego el cuerpo celular los procesa y el axón los envía a otras neuronas, ver figura 10 (Manchado, 2018).

### 2.5.1.2 Neurona artificial

Una neurona artificial efectúa una suma ponderada de los ingresos que admite, aplica una función de activación no lineal al resultado de esta suma, y produce una salida. La neurona artificial simula el desempeño de una neurona biológica de una manera simplificada, ver figura 11.

**Figura 10**

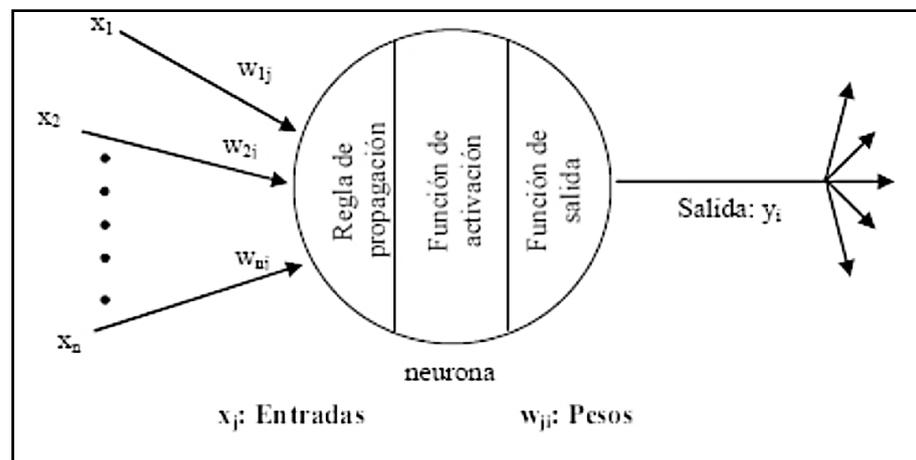
*Representación de una neurona biológica*



Nota. La figura representa una neurona biológica, tomado de Manchado (2018).

**Figura 11**

*Neurona artificial*



Nota. La figura representa una neurona artificial, tomado de Manchado (2018).

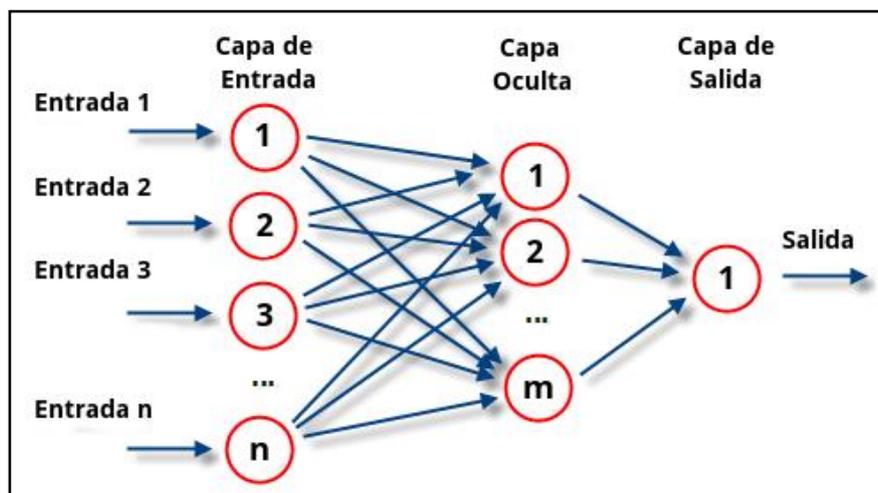
## 2.5.2 Topología de una red neuronal

**Capas:** La red neuronal está conformada por una serie de capas de neuronas interconectadas. La capa de ingreso acoge las entradas del sistema, la capa de salida genera las salidas del sistema y una o varias capas escondidas llevan a cabo los cálculos intermedios requeridos para solucionar el problema.

**Conexiones:** Las neuronas en una red neuronal están interconectadas mediante conexiones llamadas sinapsis. Cada sinapsis posee un peso vinculado que establece la intensidad de la vinculación entre las neuronas.

**Figura 12**

*Topología de la red neuronal perceptrón multicapa (MLP)*



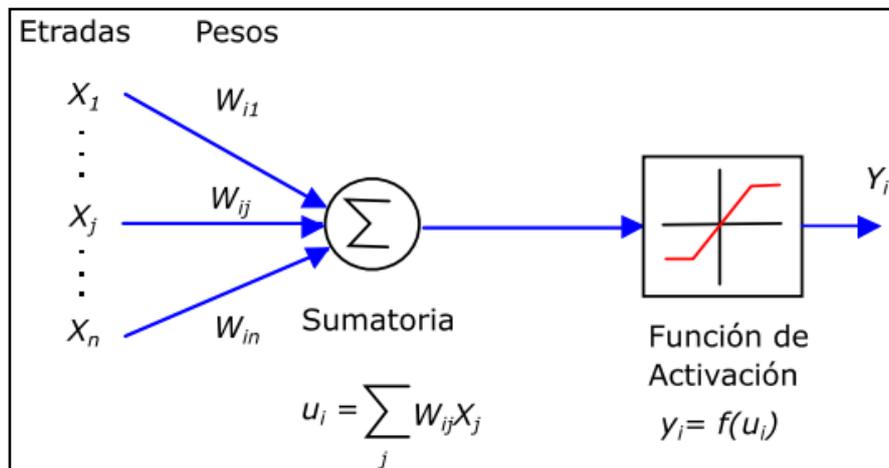
Nota. Una Red Neuronal Artificial simple con  $n$  entradas,  $m$  neuronas en la capa oculta y una neurona de salida, tomado de Sinaluisa Lozano (2017).

## 2.5.3 Elementos de una red neuronal

La red neuronal es un sistema que está formado por muchas neuronas conectadas entre sí, la fig. 13 detalla los elementos de una neurona artificial.

**Figura 13**

*Elementos de una neurona artificial*



Nota. Elementos de una neurona artificial, tomado de Morillo Tarapués (2020).

**Neuronas:** Son las unidades de procesamiento en una red neuronal. Cada neurona efectúa una multiplicación ponderada de los ingresos que recibe, implementa una función de activación no lineal al resultado de dicha multiplicación y originar una salida.

**Pesos:** Las conexiones entre las neuronas están representadas por pesos que indican qué tan fuerte es la conexión entre ellas. Estos pesos se modifican durante la formación de la red neuronal con el fin de reducir la falla en la salida.

**Función de activación:** La función de activación de una neurona establece si la neurona necesita ser activada o no, basándose en la suma de los impulsos recibidos. Algunas funciones activadas habituales comprenden la función sigmoide, la función ReLU (Unidad Lineal Rectificada) y la función tangente hiperbólica.

**Figura 14**

*Funciones de activación*

	Función	Rango	Gráfica
<b>Identidad</b>	$y = x$	$[-\infty, +\infty]$	
<b>Escalón</b>	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
<b>Lineal a tramos</b>	$y = \begin{cases} -1, & \text{si } x < -1 \\ x, & \text{si } -1 \leq x \leq 1 \\ +1, & \text{si } x > 1 \end{cases}$	$[-1, +1]$	
<b>Sigmoidea</b>	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
<b>Gaussiana</b>	$y = Ae^{-2x^2}$	$[0, +1]$	
<b>Sinusoidal</b>	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Nota. La figura representa muestra las funciones de activación de una neurona, tomado de Manchado (2018).

### 2.5.4 Aprendizaje y Entrenamiento

**Aprendizaje:** El desarrollo de formación en una red neuronal implica la modificación de los pesos de los vínculos entre las neuronas con el fin de disminuir el error en la salida de la red. Esto se ejecuta mediante un proceso iterativo de presentación de ejemplos de entrenamiento a la red.

**Entrenamiento:** se entrena una red neuronal alimentándola con una serie de ejemplos de entrenamiento y modificando los componentes que conectan a las neuronas hasta que la red pueda trabajar bien con esos datos. Esto lo hacemos varias veces para que la red aprenda de forma efectiva.

### 2.5.5 Clasificación de las redes neuronales

Existen varias clases de redes neuronales, cada una está hecha para abordar un determinado tipo de problema, las redes neuronales más comunes son:

- **Redes Neuronales Profundas (DNN):** Son redes neuronales que contienen múltiples capas ocultas. Estas plataformas poseen la habilidad de adquirir representaciones en forma de jerarquías de la información, resultan especialmente benéficas en situaciones complicadas relacionadas con el aprendizaje automático.
- **Redes Neuronales Recurrentes (RNN):** Las neuronas conectadas entre sí crean bucles permitiendo que la red procese información de manera secuencial, como textos o secuencias temporales.
- **Redes Neuronales Feedforward (FNN):** Las redes guardan información en una dirección específica, desde el punto que inicia hasta el punto de finalización, sin ningún tipo de bucles ni retroalimentación.
- **Redes Neuronales Convolucionales (CNN):** Pertenecen a un tipo específico de redes neuronales creadas para manejar datos organizados, como las imágenes. Estas redes han demostrado una productividad excepcional en tareas de clasificación e identificación de imágenes.

## 2.6 DEFINICIÓN DE TÉRMINOS

**Sensor MAP:** Es un elemento empleado para los sistemas de inyección de combustible en motores de combustión. El responsable de medir la presión absoluta del aire y suministrar información al sistema de control del motor (ECM) es el sensor MAP (presión absoluta del múltiple), para que la porción adecuada de combustible llegue a los cilindros del motor (Carrabs Gonçalves, 2022).

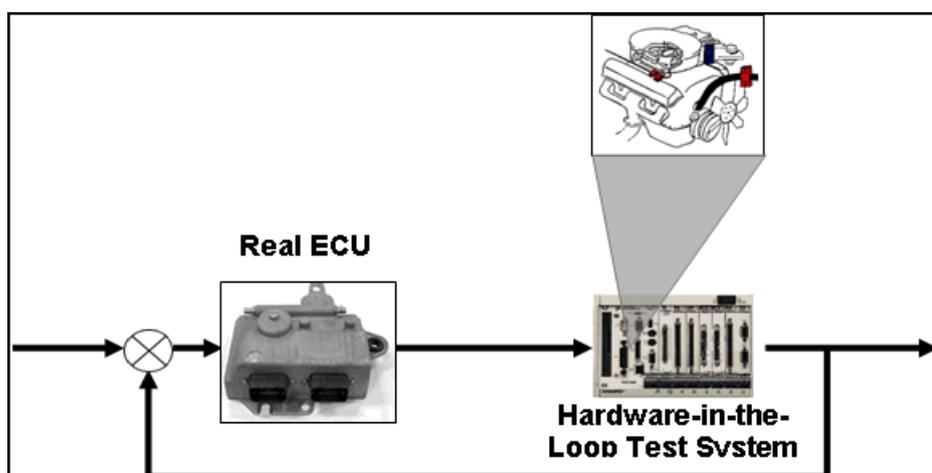
**Sistema de Admisión:** Este sistema es encargado de suministrar aire al motor para que pueda funcionar. El sistema consta de varias partes diseñadas para maximizar el flujo de aire hacia los cilindros del motor.

**Motor de Combustión Interna:** Se denominan motores de combustión interna todos aquellos que transforman la energía derivada de la combustión en energía mecánica. Los motores de gasolina se usan en muchas cosas diferentes, como autos, motos, generadores y máquinas en fábricas (Booster, 2010).

**ECM (Engine control module):** El Módulo de Control del Motor (ECM) es una unidad de control electrónica que verifica y controla diversas funciones del motor de un carro. También se conoce como Unidad de Control del Motor (ECU) o Módulo de Control Electrónico (ECM). El ECM recoge datos de diferentes partes del motor para controlar cómo funciona y mejorar su rendimiento, haciendo que contamine menos (García-Basurto et al., 2021).

**Figura 15**

*Unidad de control del motor ECU*

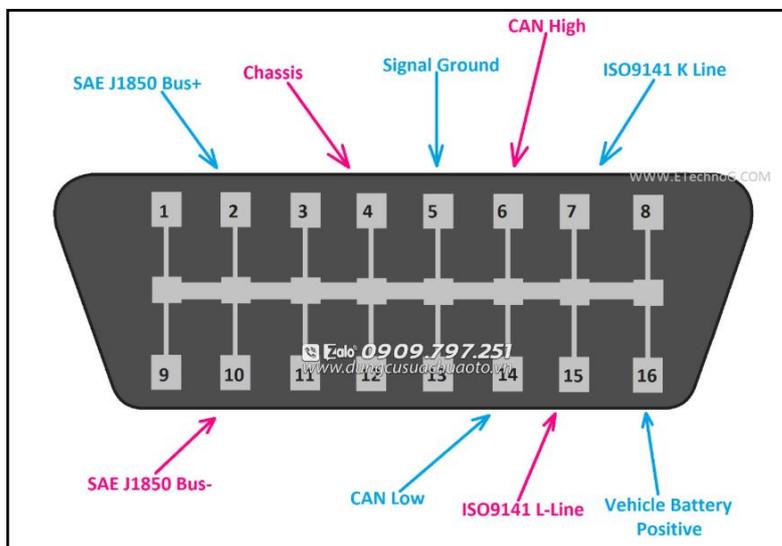


Nota. Las ECU guardan la información de fallas que puedan ser detectadas de diferentes partes del motor, tomado de Aldo Calsin (2015).

**OBD (On-Board Diagnostics):** El Diagnóstico a Bordo (OBD) es un sistema de monitoreo y diagnóstico integrado en los vehículos modernos que supervisan el rendimiento del motor y otros sistemas que afectan las emisiones para asegurarse de que todo está en orden. El OBD ayuda a identificar y diagnosticar problemas de rendimiento del motor, emisiones y otros sistemas relacionados con el control del motor (Booster, 2010).

**Figura 16**

*Diagnostico a Bordo (OBD)*



Nota. El protocolo OBD admite varios protocolos de señales que determinan cómo se transfieren los datos entre el vehículo y la herramienta de diagnóstico, tomado de <https://www.embien.com>.

**Red Neuronal:** Las redes neuronales son como un programa de computadora que simula cómo funciona el cerebro. Está compuesta por unidades que se conectan entre sí, como si fueran piezas de un rompecabezas, y que trabajan juntas para solucionar obstáculos difíciles de identificación de patrones y aprendizaje automático (W. Contreras & J. Maldonado, 2019).

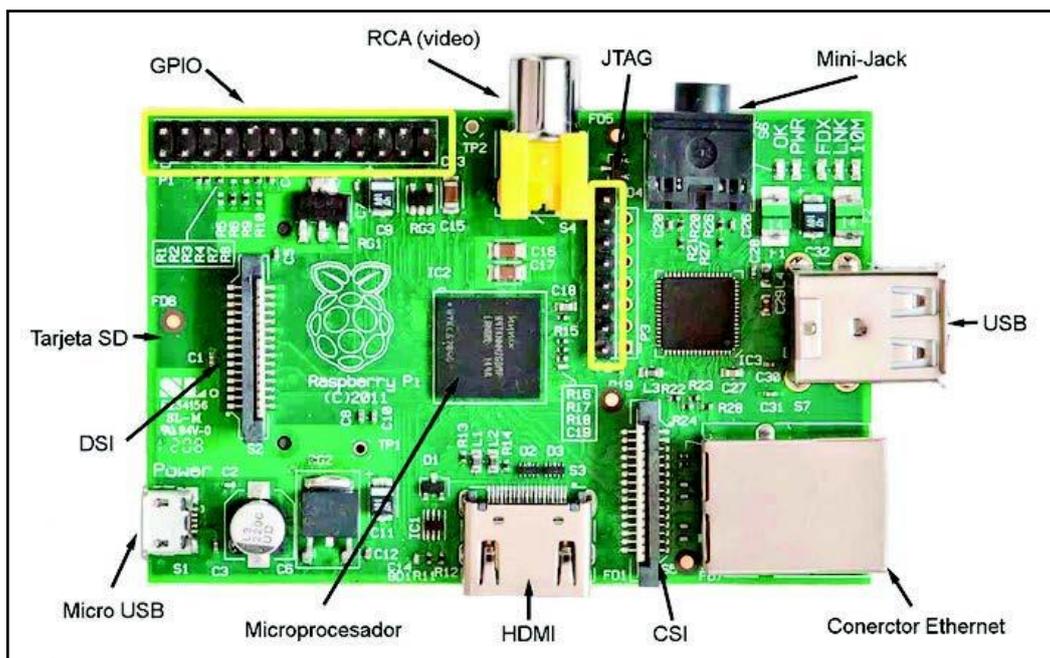
**Machine Learning (Aprendizaje Automático):** Es una parte de la inteligencia artificial que usa datos y algoritmos para que las computadoras aprendan como lo hacemos los humanos, volviéndose más precisas con el tiempo (Carrabs Gonçalves, 2022).

## 2.7 RASPBERRY PI

Se trata de una computadora de tamaño reducido parecida a una placa que ha sido desarrollada por la organización Raspberry Pi Foundation en el territorio británico. Las computadoras han sido creadas con el propósito de brindar información y enseñar programación, además de ofrecer programas de aprendizaje en tecnología en general. La Raspberry Pi es una plataforma de menor precio y mayor rendimiento que ha sido bien recibida en una extensa variedad de usos, como proyectos educativos hasta aplicaciones industriales, características de raspberry pi ver tabla 2 (Escandon Christian, 2024).

**Figura 17**

*Placa Raspberry Pi*

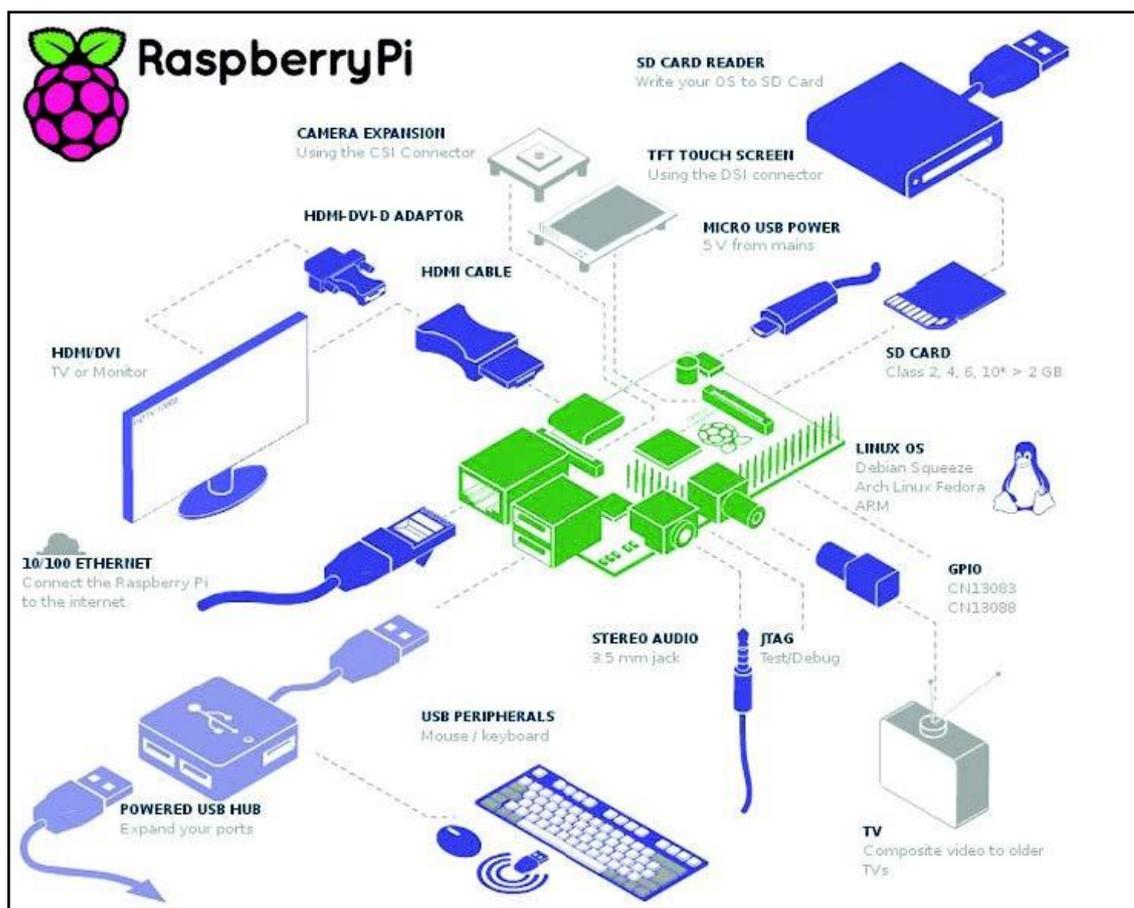


Nota. Es una computadora de tamaño reducido y baratas que fue creada para proyectos educativos, tomado de Lopez Aldea (2017).

La placa tiene un chip llamado Broadcom BCM2835, con un procesador ARM que puede funcionar a diferentes velocidades, e incluso puede overclockearse hasta 1 GHz. El SoC de Broadcom tiene un procesador gráfico VideoCore IV, diferentes cantidades de memoria RAM dependiendo del modelo, salida de video y audio a través de un conector HDMI, salida de video compuesto y audio a través de un minijack, y conexión Ethernet 10/100. Hay varios tipos, pero la mayoría de la gente en casa usa el modelo Raspberry Pi 2 Modelo B. El nuevo Raspberry Pi 3 se está empezando a usar cada vez más. Estos modelos se ampliarán más adelante.

**Figura 18**

*Conexiones hardware en Raspberry Pi*



Nota. En la figura se observa el resumen de las conexiones hardware en Raspberry Pi, tomado de Lopez Aldea (2017).

**Tabla 2**

*Características técnicas de la Raspberry pi.*

Definición	Características
Procesador	Broadcom BCM2711 Core Cortex-A72 a 1.5 GHz
Memoria RAM	2GB 4GB 8GB LPDDR4
Almacenamiento	Según tarjeta SD usada
Conectividad	Ethernet Gigabit Wi-Fi 80.11ac Bluetooth 5.0
Puertos USB	2 puertos USB 3.0 2 puertos USB 2.0
Alimentación	A través de un conector USB-C
Sistema operativo	Compatible co una variedad de sistemas operativos, incluyendo Raspbian (basado en Debian) y otros sistemas operativos Linux.

Nota. Esta tabla da a conocer las características técnicas de la Raspberry pi. Tomado de Escandon Christian (2024).

### 2.7.1 Características principales

- **Versatilidad:** Se usa para muchas cosas diferentes, desde tareas escolares, arreglos, hasta guardar archivos en casa.
- **Bajo costo:** La Raspberry Pi es barata, por lo que la pueden comprar estudiantes, fans y profesionales que no tienen mucho dinero.
- **Comunidad activa:** Un grupo de personas que utilizan Internet para compartir e interactuar entre sí.
- **Expansión:** La presencia de pines GPIO (General Purpose Input/Output, salida/entrada de propósito general) permite el uso de sensores y dispositivos periféricos que facilita la ampliación del hardware.

- **Bajo consumo de energía:** Hecha para usar poca energía, perfecta para proyectos con baterías.

## 2.8 PYTHON

Entre los diversos lenguajes posibles para desarrollar programas, destaca el Python como lenguaje sencillo y muy intuitivo, muy popular, por lo que existe mucha documentación y potente. Es un lenguaje de computación importante que se usa en trabajos de programación. También, se hace con un tipo de licencia que se llama código abierto, esto indica que podemos usar en cualquier sistema sin problemas, incluso para hacer negocios. Python, aunque no es el único, es el lenguaje más estándar elegido para la Raspberry Pi. Así mismo, recibe el apoyo de los desarrolladores en sus distribuciones.

### Figura 19

*Icono de Python*



Nota. Es un lenguaje de programación ampliamente usado, tomado de Lopez Aldea (2017).

#### 2.8.1 Editor de texto IDLE para Python

Una forma de introducirse en la programación de la Raspberry Pi con Python es a través del Editor de Texto IDLE (Integrated DeveLopment Environment, entorno de desarrollo integrado). Con este editor se podrá crear, editar, guardar y ejecutar los programas escritos en él. IDLE se trata de un intérprete de programación, que ofrece un entorno sencillo para la creación de aplicaciones en electrónica con Raspberry Pi (Lopez Aldea, 2017).



## CAPÍTULO III

### MATERIALES Y MÉTODOS

#### 3.1 METODOLOGÍA DE INVESTIGACIÓN

El estudio emplea una metodología experimental, que incluye simulaciones y pruebas prácticas en un motor de combustión. Para evaluar la efectividad del método sugerido, se recopilarán datos del sistema de admisión, del sensor MAP y técnicas de análisis estadístico.

##### **Tipo de Investigación**

- Predictivo: Predecir eventos o resultados futuros en función de datos recolados.

##### **Diseño**

- Experimental: Controlar variables y evaluar el impacto del modelo de detección en situaciones controladas. Se realizan pruebas controladas para recopilar datos del sensor MAP en diversas situaciones de operación del motor. Estos números se usan para enseñar y comprobar un tipo de inteligencia artificial llamado red neuronal perceptrón multicapa (MLP).

##### **Enfoque**

- Cuantitativo: Buscar medir y cuantificar la efectividad del modelo de detección.

## 3.2 VARIABLES DE LA INVESTIGACIÓN

### 3.2.1 Definición de las variables

**Tabla 3**

*Definición de las variables independiente y dependiente*

<b>Variable</b>	<b>Tipo</b>	<b>Concepto</b>
Sensor MAP	Cuantitativa Independiente	El Sensor de Presión Absoluta del Múltiple (MAP), que mide la presión del múltiple de admisión, es la variable independiente que se manipula para observar su efecto en el modelo de predicción basado en redes neuronales.
Modelo de Predicción	Cuantitativa Dependiente	El modelo de predicción basado en redes neuronales artificiales es la variable dependiente que se ve afectada por las diferentes condiciones del Sensor MAP.

### 3.2.2 Operacionalización de variables

**Tabla 4**

*Operacionalización de variables independientes y dependientes*

<b>Variable</b>	<b>Indicador</b>	<b>Técnica</b>	<b>Instrumento</b>
Sensor MAP	Lectura de la presión absoluta en el múltiple de admisión.	Mediciones directas, utilizando el Sensor MAP	Sensor MAP, Computadora Automotriz
Modelo de Predicción	Precisión y confiabilidad de las predicciones del comportamiento del Sensor MAP	(MAPE)	Python



### 3.3 POBLACIÓN Y MUESTRA

#### 3.3.1 Población

Motores a combustión interna en la ciudad de Juliaca.

#### 3.3.2 Muestra

Para la muestra estamos utilizando un vehículo marca Zuzuki, modelo K10 del año 2016.

### 3.4 TÉCNICAS DE RECOLECCIÓN DE DATOS

- **Documental:** Revisión de literatura y documentación técnica relacionada con sistemas de admisión y el sensor MAP.
- **Observacional no Experimental:** Observación directa del automóvil en diversas condiciones de uso.
- **Experimental:** Evaluación del modelo de predicción.

#### 3.4.1 Recolección de datos

Los pasos para recopilar datos son los siguientes:

- Exploración de datos en la web, artículos y libros.
- Extracción de datos del sensor MAP utilizando una raspberry Pi.

### 3.5 MATERIALES

- Computadora.
- Software Python.
- Vehículo automotor de pruebas.
  - Marca: Suzuki.

- Modelo: Alto k10.
- Año: 2016.
- Motor: 796 CC.

**Figura 20**

*Vehículo de prueba*



**Figura 21**

*Motor de vehículo*



- Raspberry Pi

Se trata de una mini computadora de tamaño reducido que puede ser usado como ordenador personal, para este proyecto será encargado de ejecutar el programa que extraerá los datos de los sensores del automóvil.

**Figura 22**

*Raspberry Pi*



Nota. La figura representa una Raspberry Pi con una serie de ordenadores, obtenido de wikipedia.org.

- Sensor MAP

Es el responsable de calcular la cantidad de aire que puede ingresar al motor.

**Figura 23**

*Sensor MAP*



Nota. Un sensor que controla cuánto aire entra en el motor, tomado de <https://www.map-sensor-replacement.com>.

- Escáner automotriz

El escáner se encarga de vincular la Raspberry Pi y el vehículo.

**Figura 24**

*Escáner Automotriz ELM327*

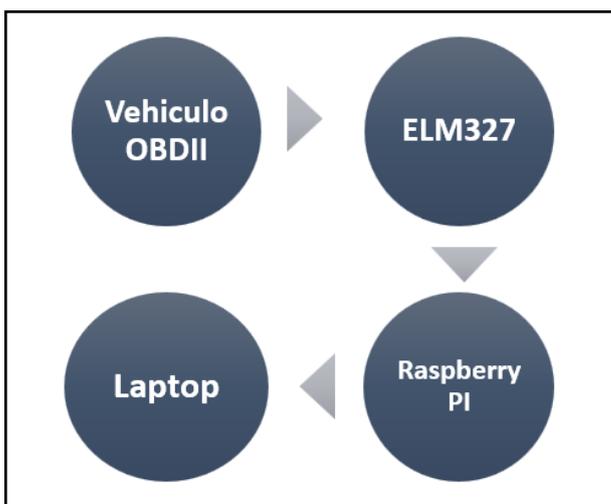


Nota. Permite ver lo que el auto está haciendo en el momento, obtener los códigos de error del auto, controlar cómo funciona el auto y ver información de los sensores, tomado de <https://www.escaner-automotriz.com>

### 3.6 CONEXIÓN RASPBERRY PI CON EL PUERTO OBDII

**Figura 25**

*Diagrama de conexión*



El puerto OBDII nos permite conectarnos a la computadora del automóvil para obtener información, como velocidad, RPM, torque, temperatura, códigos de error, etc.

Lo primero que se necesita hacer es conectar el escáner automotriz ELM327 al puerto OBDII de tal manera que podamos comunicarnos hacia este con la Raspberry pi.

### Figura 26

*Conexión del escáner hacia el puerto OBDII*



Con el escáner conectado, ahora podemos conectarle la Raspberry Pi que tiene bluetooth integrado, por lo que no necesito ningún otro adaptador. La conexión bluetooth requiere que se digite los siguientes comandos.

### Figura 27

*Conexión bluetooth del escáner con la Raspberry Pi*

```
power on      # ensures bluetooth is on
power on      # ensures bluetooth is onble
agent on      # makes pairing persistent
default-agent
scan on       # scans for bluetooth devices
              # the OBDII adapter should read something
              # like this - 00:00:00:00:00:00 Name: OBDII
              # If it asks for a pin, the default pin is 1234
scan off      #turn off scanning once your adapter has been found
pair <adapter mac address> #pair to your adapters mac address
trust <adapter mac address> #keeps pairing even after reboot
quit         #exits out of bluetoothctl
```

Para la extracción de datos se necesita ingresar los códigos OBD-II PIDs dependiendo al dato que se quiera obtener. El comando consiste en dos valores hexadecimales. La fig. 28 se observa las diferentes pautas de valores para los primeros dos dígitos.

## Figura 28

### Códigos PID, primeros dígitos

Modes [ edit ]

There are 10 modes of operation described in the latest OBD-II standard SAE J1979. They are as follows:

Mode (hex)	Description
01	Show current data
02	Show freeze frame data
03	Show stored Diagnostic Trouble Codes
04	Clear Diagnostic Trouble Codes and stored values
05	Test results, oxygen sensor monitoring (non CAN only)
06	Test results, other component/system monitoring (Test results, oxygen sensor monitoring for CAN only)
07	Show pending Diagnostic Trouble Codes (detected during current or last driving cycle)
08	Control operation of on-board component/system
09	Request vehicle information
0A	Permanent Diagnostic Trouble Codes (DTCs) (Cleared DTCs)

Vehicle manufacturers are not required to support all modes. Each manufacturer may define additional modes above #9 (e.g. n Ford/GM, mode 21 for Toyota) for other information e.g. the voltage of the traction battery in a hybrid electric vehicle (HEV).<sup>[2]</sup>

Standard PIDs [ edit ]

Nota. La figura representa los códigos PID, primeros dígitos.

La fig. 29 se observa los diferentes tipos de valores para los dos últimos dígitos.

## Figura 29

### Códigos PID, últimos dígitos

08	8	1	Short term fuel trim—Bank 2
09	9	1	Long term fuel trim—Bank 2
0A	10	1	Fuel pressure (gauge pressure)
0B	11	1	Intake manifold absolute pressure
0C	12	2	Engine RPM
0D	13	1	Vehicle speed
0E	14	1	Timing advance
0F	15	1	Intake air temperature
10	16	2	MAF air flow rate

Nota. La figura representa los códigos PID, últimos dígitos.

Así que por ejemplo si quiero conseguir los datos en tiempo real del sensor de velocidad, necesito ingresar el código 010D. Para obtener los datos del sensor MAF/MAP se necesita el código 0110.

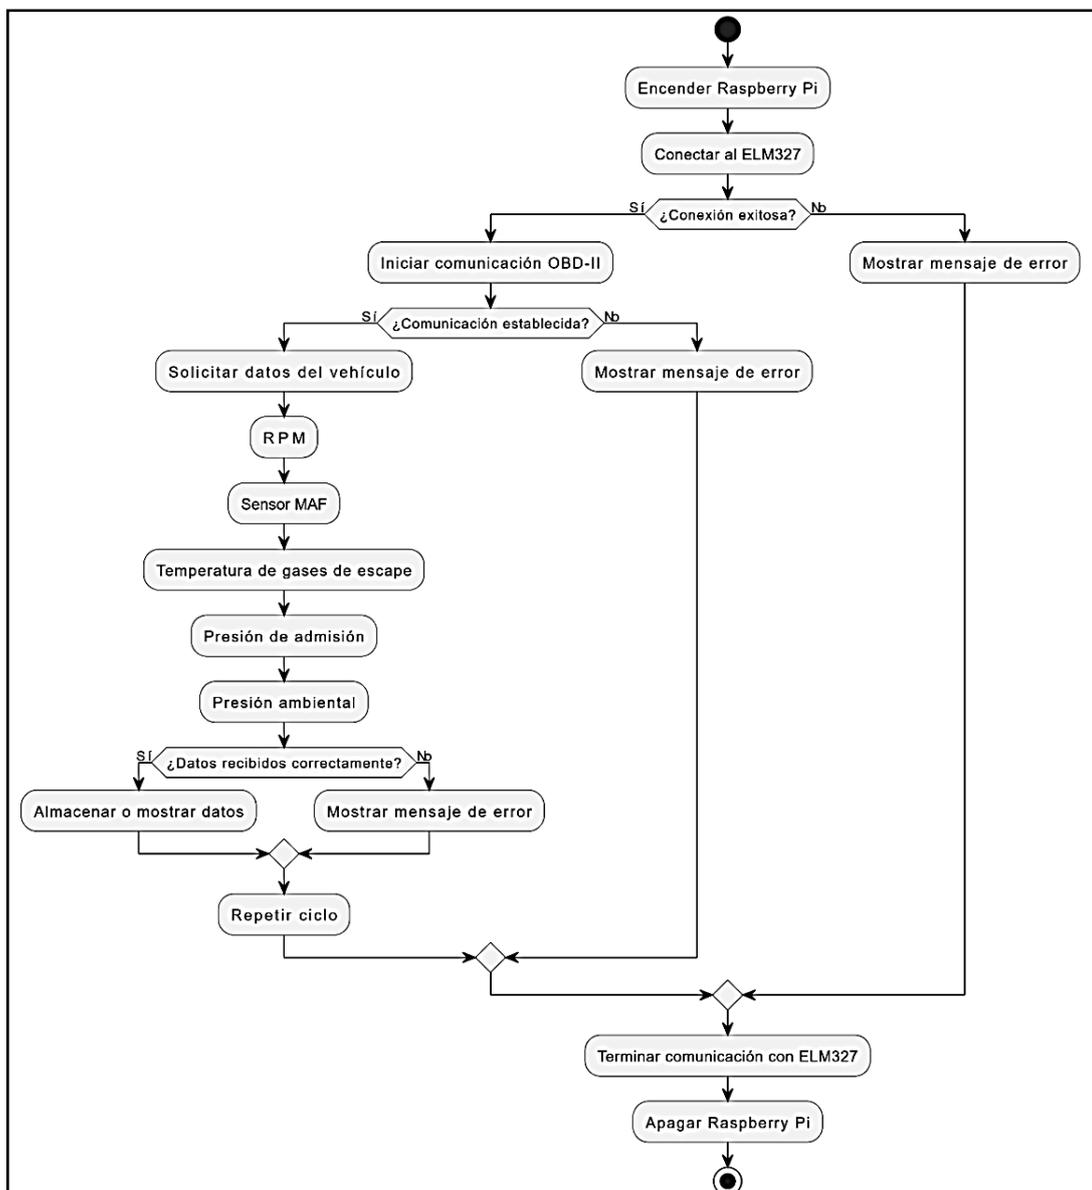
Al ingresar el código se obtiene un código hexadecimal por ejemplo 41 0D 32 11.

- 41: La respuesta al comando 01.
- 0D: La respuesta al comando OD.
- 32: La velocidad en hexadecimal.
- 11: Byte de datos no utilizados.

Así que si se convierte 32 hexadecimal a km/hr se obtiene 50 km/hr.

**Figura 30**

*Diagrama de Flujo de obtención de datos*



## 3.7 SELECCIÓN DE DATOS DE MUESTRA

### 3.7.1 Adquisición de Muestras

Mediante el análisis del sistema de admisión del motor, se enumeran los parámetros que influyen al MAP: velocidad del motor, temperatura de escape, presión de admisión, cantidad de inyección de combustible en ciclo, presión ambiental y presión de admisión.

El estudio se realizó en un motor a gasolina de 4 cilindros, controlado electrónicamente (Carrabs Gonçalves, 2022).

La presión de admisión se adquirió en condiciones dinámicas. Cuando el motor estaba en diferentes operaciones. El conductor debía accionar el grado de apertura del acelerador a diferentes velocidades.

La siguiente fig. 31 muestra los datos recogidos por los diferentes sensores, se tiene 36068 muestras.

**Figura 31**

*Datos obtenidos*

tiempo	MAP	MAF	velocidad_motor	posicion_acelerador	masa_combustible_inyectado
0.000000	0.054752	0.007331	123.216611	7.247208	0.001153
0.050013	0.053873	0.007622	126.347235	7.814976	0.001098
0.100013	0.052701	0.007974	129.435445	7.779490	0.001078
0.150161	0.051822	0.008096	132.390455	7.744005	0.001078
0.200415	0.052408	0.008470	134.832297	8.702114	0.001067
...	...	...	...	...	...
1803.244160	0.023309	0.002194	91.468948	2.172777	0.000404
1803.294055	0.023992	0.002203	91.644391	2.137291	0.000404
1803.344241	0.023114	0.002200	91.594958	2.172777	0.000404
1803.394400	0.024383	0.002203	91.629690	2.137291	0.000403
1803.444057	0.023114	0.002197	91.551578	2.208262	0.000403

36068 rows x 5 columns

La siguiente figura 32 se demuestra una vista más detallada de los valores obtenidos.

### Figura 32

*Datos obtenidos de los sensores*

```
<class 'pandas.core.frame.DataFrame'>
Float64Index: 36068 entries, 0.0 to 1803.444057
Data columns (total 5 columns):
#   Column                                Non-Null Count  Dtype
---  ---                                -
0   MAP                                    36068 non-null  float64
1   MAF                                    36068 non-null  float64
2   velocidad_motor                       36068 non-null  float64
3   posicion_acelerador                   36068 non-null  float64
4   masa_combustible_inyectado            36068 non-null  float64
dtypes: float64(5)
memory usage: 1.7 MB
```

Según Booster (2010), nos indica que se deben seguir estos pasos para tomar las muestras:

1. Los datos de muestra deben ser medidos a diferentes velocidades del motor, que van desde 800 a 2500 r/min.
2. La velocidad del motor debe cambiar a diferentes tasas, incluyendo el cambio constante, lento y rápido. El punto del pedal del acelerador se sitúa entre el 0 a 100%.
3. El motor deberá ser operador en diferentes presiones ambientales.
4. os datos singulares deben ser eliminados para mejorar la precisión.

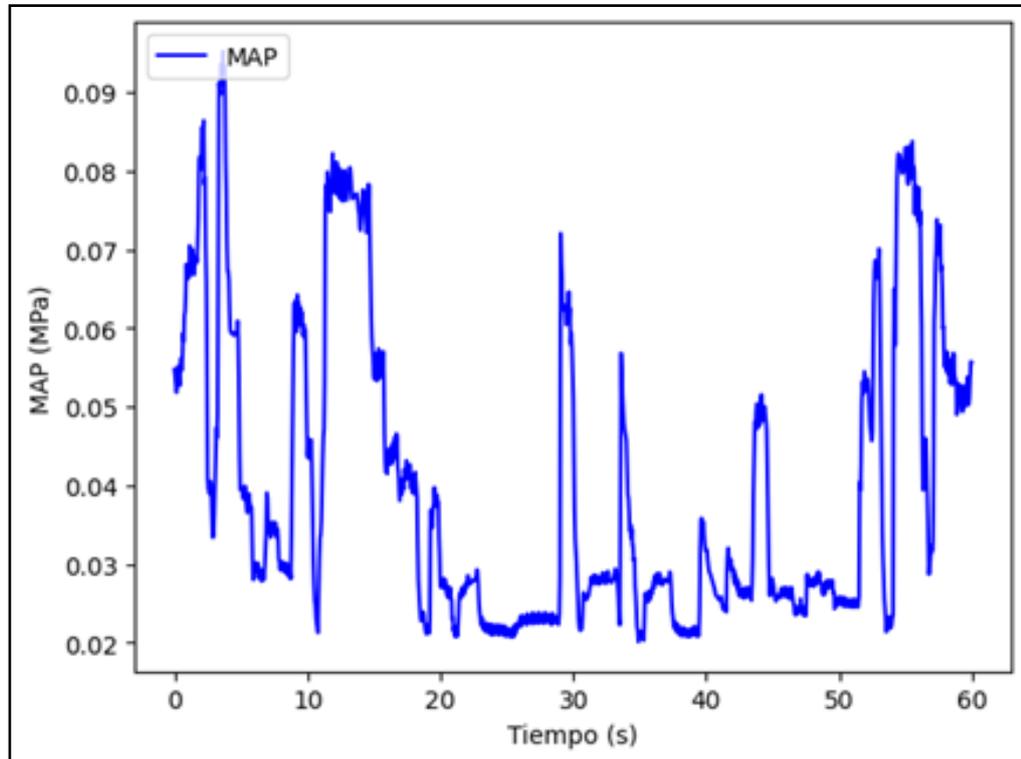
Se tienen 36068 grupos de datos, el tiempo de muestreo de cada grupo es de 0.05s. Las muestras obtenidas a través del experimento se indican en las siguientes figuras.

La fig. 33 muestra el gráfico del sensor MAP (Manifold Absolute Pressure) en función del tiempo, reflejando cómo varía la presión en la cámara de admisión de un motor.

Las oscilaciones en la presión indican cambios en la carga del motor y en el régimen de revoluciones (RPM). Los rangos de presión registrados (0.02 MPa a 0.09 MPa) son normales, con periodos de estabilidad que podrían reflejar un régimen de operación constante. Los aumentos de velocidad y disminuciones pueden estar relacionados con puntos máximos y descensos. El sensor MAP es crucial para afinar el rendimiento del motor, suministrando datos esenciales a la ECU.

### Figura 33

*Diagrama en función del tiempo del sensor MAP*



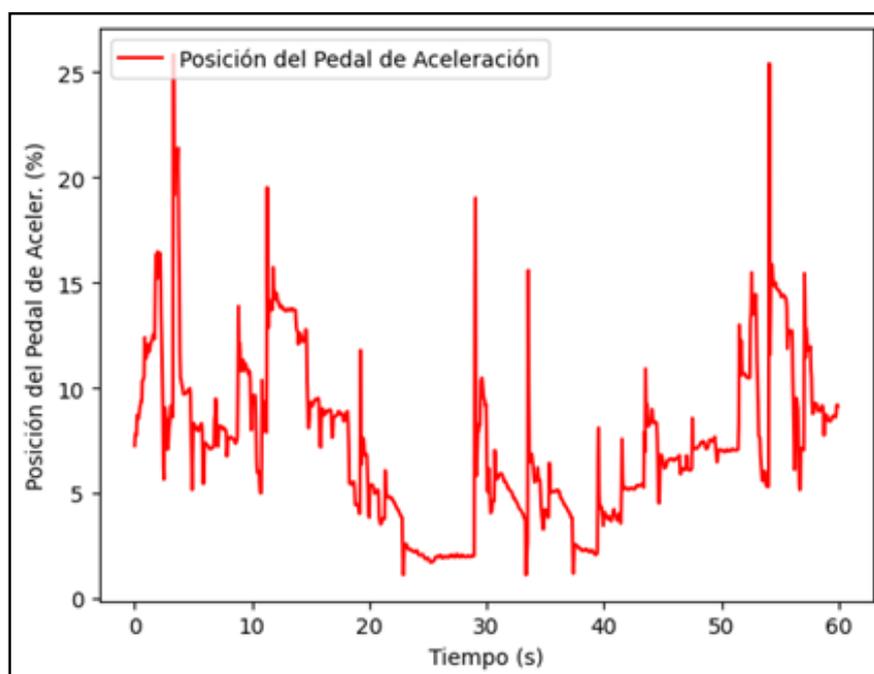
La fig. 34 presenta la diversidad en la ubicación del pedal de acelerador a lo largo de un lapso de 60 segundos, con cambios que representan la comunicación en movimiento entre el conductor y el automóvil. Los datos indican que el procedimiento se lleva a cabo mayormente en intervalos con velocidades moderadas, con ciertos puntos máximos que llegan al 25%, lo que insinúa momentos de mayor necesidad de energía.

Este comportamiento es crucial para el desarrollo de una red neuronal que anticipe el comportamiento del sensor MAP, ya que permite captar la correlación directa entre el control del acelerador y la presión del colector de admisión.

La red neuronal utilizará las características para aprender y anticipar cómo las modificaciones en la posición del pedal del acelerador impactan en las lecturas del sensor MAP en tiempo real, incrementando de esta forma su habilidad para prever de qué manera actuará el motor en distintas situaciones de conducción.

### Figura 34

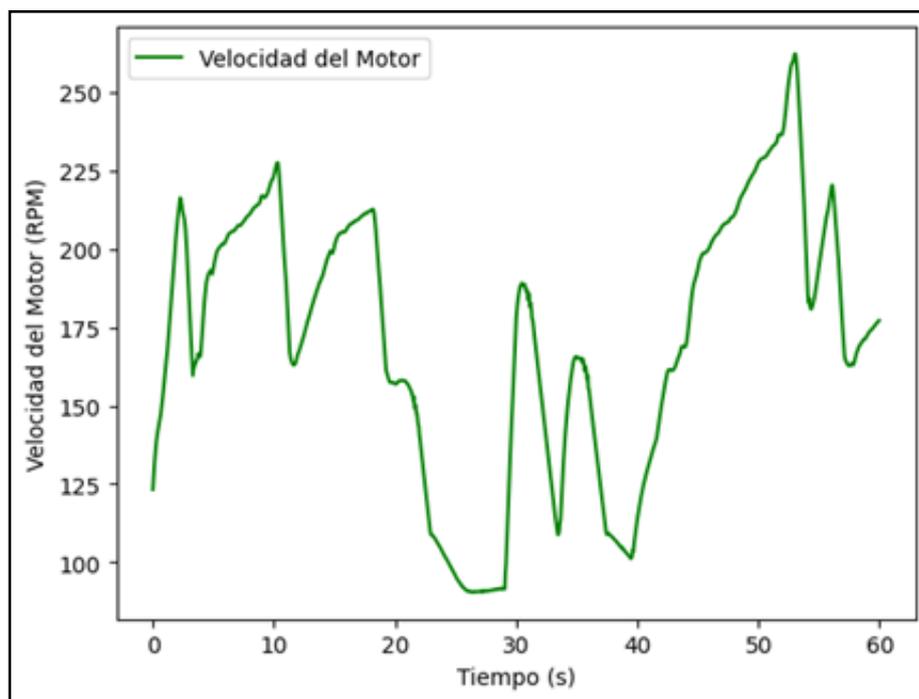
*Diagrama del sensor del Pedal del acelerador en función del tiempo*



La fig. 35 ilustra la variación de la aceleración del motor en RPM a lo largo de un lapso de 60 segundos. Las RPM del motor se muestran en el eje vertical, también se muestra el tiempo transcurrido en segundos en el eje horizontal. Se puede observar que la velocidad del motor exhibe fluctuaciones a lo largo del período de tiempo registrado. Los picos más altos de RPM indican momentos de mayor aceleración del motor, mientras que las caídas representan periodos de desaceleración o menor actividad del motor. Esta variabilidad es típica en pruebas de motores en condiciones dinámicas, donde se somete al motor a diferentes niveles de demanda para evaluar su respuesta y comportamiento.

### Figura 35

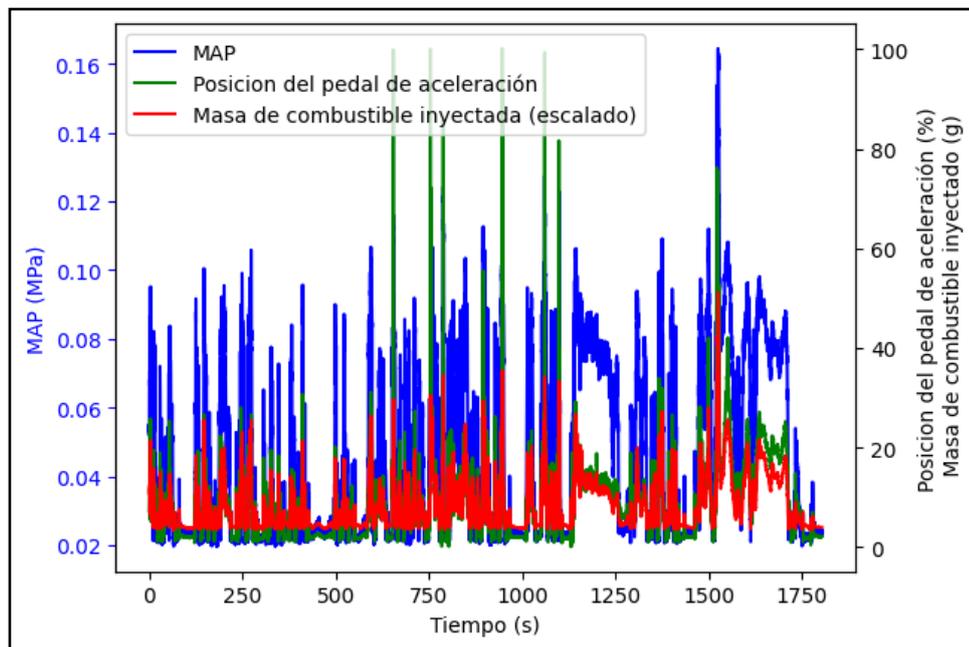
*Diagrama del sensor de velocidad en función del tiempo*



La fig. 36 presenta la relación dinámica entre la presión absoluta del múltiple de admisión (MAP) en megapascales (MPa), la posición del pedal de aceleración en porcentaje (%), y la masa de combustible inyectada en gramos (g), todo ello registrado en función del tiempo en segundos.

**Figura 36**

*Diagrama de relación entre sensores a través del tiempo*



- **Curva azul (MAP):** Esta curva ilustra las variaciones en la presión MAP, que es esencial para controlar la combinación de aire y combustible del motor. Los cambios en la presión MAP reflejan directamente la variación en la carga del motor, que esta influenciada por la demanda de potencia.
- **Curva verde (Posición del pedal de aceleración):** Representa la posición del pedal de aceleración, un indicador de la demanda de potencia del motor. Los picos en esta curva corresponden a momentos en los que el conductor demanda más potencia, esto ocasiona un aumento en la presión MAP y en la cantidad de combustible inyectado.
- **Curva roja (Masa de combustible inyectada):** Esta curva, escalada para mejor visualización, muestra cómo el porcentaje de gasolina inyectado se ajusta en respuesta a la demanda del motor y la presión medida por el sensor MAP.

La fig. 36 es esencial para desarrollar modelos de redes neuronales para predecir el comportamiento del sensor MAP, específicamente las Redes Neuronales Recurrentes (RNR) y sus variantes LSTM, se usan para poder modelar y predecir la presión MAP en función de varias variables de entrada, tales como la posición del pedal de acelerador y la proporción de combustible que se ha inyectado.

La finalidad es que la red neuronal aprenda a predecir cómo cambiara la presión MAP en función de las condiciones dinámicas del motor reflejadas en las otras dos curvas. La detección de tendencias desde la información de entrada (posiciones del pedal y cantidad de combustible) permite que la red neuronal pueda hacer generalizaciones y predicciones precisas de la presión MAP en diversas circunstancias operativas del motor.

La conexión entre estas tres variables es esencial para idear el modelo de red neuronal, el cual requiere entender las interacciones complicadas entre la demanda de potencia (expresada por la posición del acelerador), la respuesta del sistema de inyección de gasolina y la presión producida en el múltiple de admisión (MAP). Adicionalmente a asistir en la predicción del comportamiento del sensor MAP, el modelo concluyente también puede contribuir a mejorar el control del motor, mejorar la forma en que se quema el combustible para contaminar menos el aire.

### **3.7.2 Selección de muestras**

Es fundamental elegir adecuadamente las muestras para garantizar la autenticidad y la efectividad del modelo de red neuronal recurrente (RNN) al pronosticar la productividad del sensor MAP. Para este estudio, cuidadosamente

se seleccionaron cuatro conjuntos de datos que de forma precisa representan y posibilitan el análisis del desempeño del modelo en diversas circunstancias operativas del motor. Estos grupos fueron elegidos para capturar una variedad de escenarios que reflejan la dinámica del motor bajo diversas demandas.

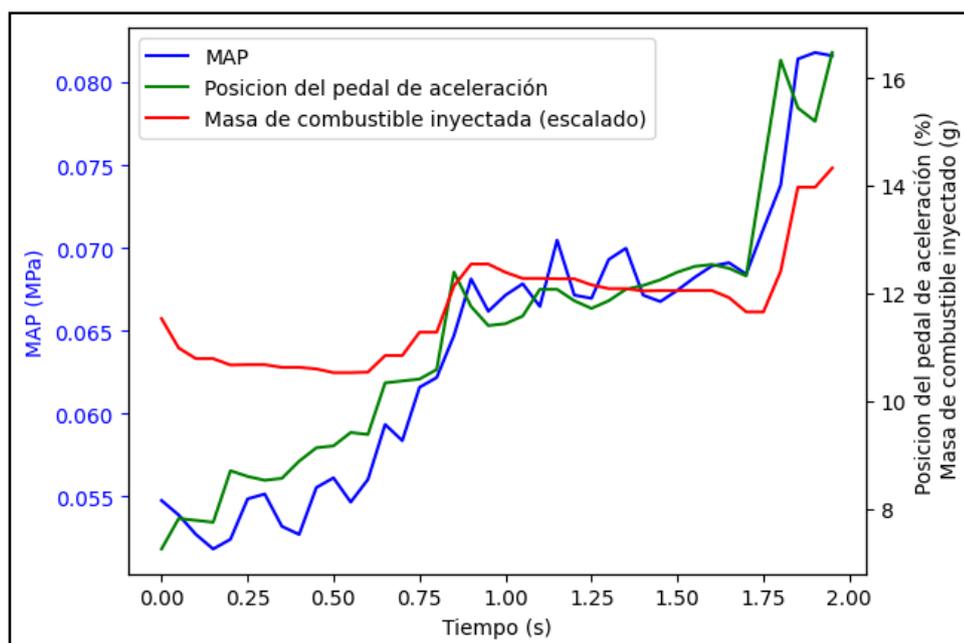
### Muestra 1: Aceleración gradual con carga baja

En este caso, es posible notar cómo el motor reacciona cuando el conductor aplasta suavemente el pedal del acelerador, incrementando gradualmente la velocidad. Durante esta operación, el motor funciona con menos carga, lo que se refleja en la cantidad de combustible inyectado, que es relativamente baja.

La fig. 37 ilustra cómo reacciona la presión en el MAP a una aceleración gradual. La línea azul de la curva de presión MAP indica aumentos graduales y constantes, en concordancia con la evolución de la posición del pedal de aceleración representada por la línea verde.

**Figura 37**

*Datos de la Muestra 1*



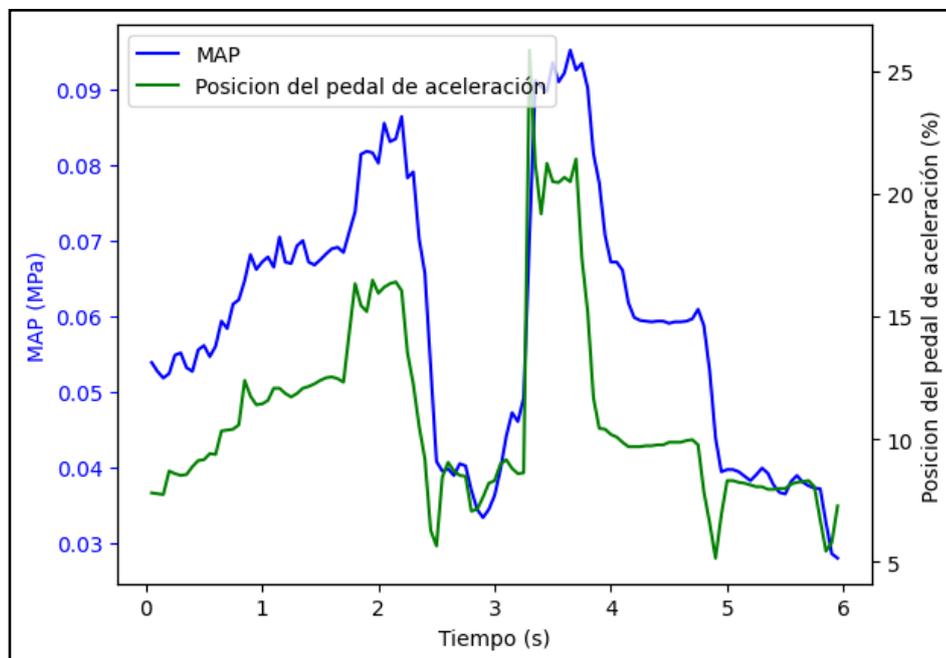
El modelo puede aprender cómo reacciona la presión en el MAP a ligeras variaciones en la demanda del motor gracias a esta muestra, que es representativa de condiciones de conducción moderadas donde no se requiere una aceleración repentina.

### Muestra 2: Variación rápida en la aceleración

Esta muestra es una situación en la que el conductor acelera rápidamente mientras aplica más fuerza al pedal del acelerador en un breve período de tiempo. La fig. 38 adjunta muestra un aumento rápido e inesperado en la presión MAP (línea azul) y la posición del pedal del acelerador (línea verde), esto señala la petición repentina de potencia.

**Figura 38**

*Datos de la Muestra 2*



Este tipo de comportamiento es típico en posiciones en las que se necesita una solución motora rápida, como al realizar una maniobra de adelantamiento.

Es fundamental que la red neuronal tenga la suficiencia de prever cómo cambia la presión MAP en reacción a estos impactos repentinos.

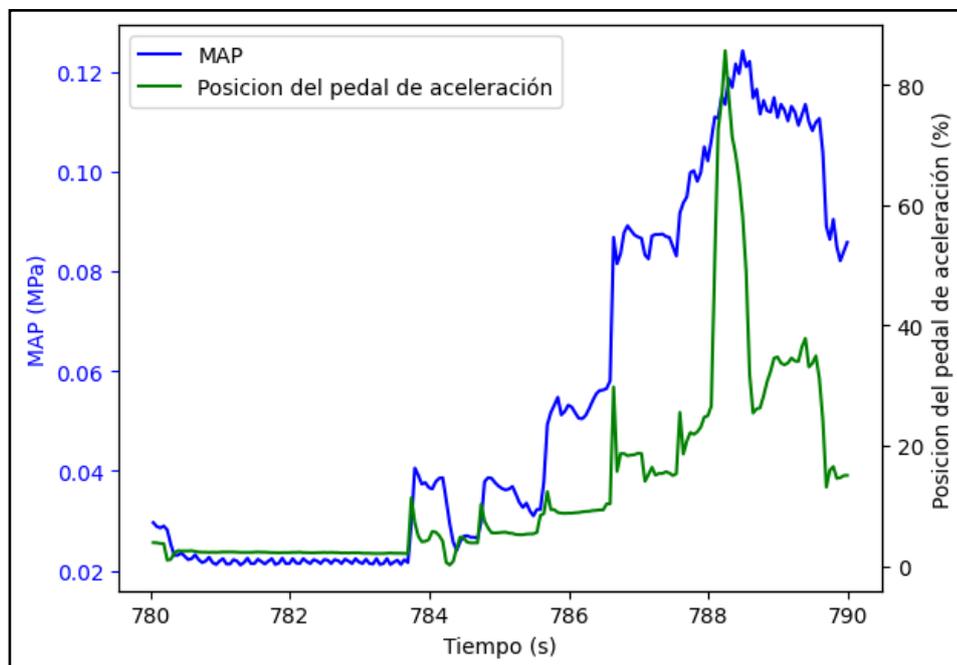
### Muestra 3: Aceleración máxima

En esta compilación de información, el operador presiona el pedal del acelerador al máximo, lo que resulta en que el motor alcance su velocidad más alta.

La fig. 39 muestra picos notables en la presión MAP (indicados por la línea azul) y también en la posición del pedal del acelerador (presentados por la línea verde), lo que indica que el motor está operando en su máxima capacidad.

### Figura 39

*Datos de la Muestra 3*



Esta muestra es fundamental para que el modelo aprenda a gestionar condiciones de funcionamiento extremas, cuando se necesita mucha energía. Es

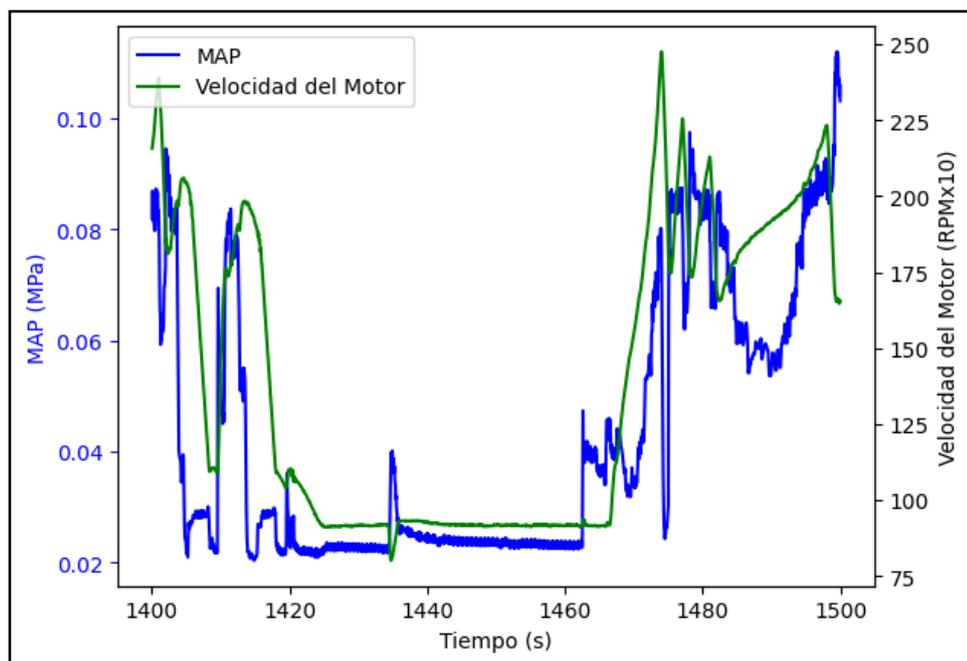
fundamental en estas situaciones asegurarse de que la predicción del sensor MAP sea exacta para garantizar que el rendimiento del motor sea adecuado y sin riesgos.

#### Muestra 4: Respuesta dinámica a alta velocidad

En este ensayo, el motor opera a una alta velocidad, sosteniendo el pedal del acelerador en una posición de apertura mayor al 80% la mayor parte del tiempo. La figura 40 muestra cómo la presión MAP (línea azul) se mantiene relativamente alta y estable, mientras que el grado de apertura del acelerador es amplio (barra verde), lo que señala un funcionamiento persistente a alta velocidad.

Figura 40

*Datos de la muestra 4*



Este grupo de datos es característico de la conducción a alta velocidad a largo plazo, como la que se experimenta en las autopistas. El modelo tiene que ser capaz de prever con precisión el comportamiento del sensor MAP cuando el motor funciona en condiciones exigentes durante un largo período de tiempo.



## **Importancia de la Selección de Muestras:**

La decisión de utilizar estos cuatro escenarios particulares permite probar la red neuronal en diferentes situaciones para ver cómo funciona en cada una, garantizando que el modelo sea preciso no solo en condiciones normales de operación, sino también frente a circunstancias extremas o variables. La variedad de las muestras seleccionadas posibilita que la red neuronal aprenda patrones complicados y generalice correctamente cuando se encuentra con información nueva o no antes vista.

## **3.8 ARQUITECTURA DE LA RED NEURONAL**

### **3.8.1 Tipo de red neuronal**

Vamos a usar un modelo llamado perceptrón multicapa (MLP) en lugar de una sola neurona. Este modelo matemático es más fácil de entender y utilizar. Una neurona es una célula especial en nuestro cuerpo que tiene partes en forma de ramas para recibir información (llamadas dendritas) y una parte larga para enviar información (llamada axón). Las dendritas son como antenas que reciben información de una zona y la envían hacia el cuerpo de la célula nerviosa. Luego, la célula reacciona y envía una señal al cerebro a través de una conexión llamada sinapsis.

En la proposición de red neuronal, se localizan 4 nodos de ingreso y 1 nodo de salida. Los puntos de entrada son la rapidez del motor, masa de combustible inyectada, cantidad de masa de aire aspirada, posición del acelerador, mientras que la presión de entrada representa el vector de salida de la red neuronal. El trabajo principal es decidir la cantidad de nodos en la capa oculta. En este proyecto, la cuantía de nodos en la capa oculta sigue el teorema de Kolmogorov,

es decir, que la cantidad de nodos en la capa oculta es al menos  $2n + 1$ , donde  $n$  es el número de nodos en la capa de entrada.

La función MSE (Error cuadrático medio) se utiliza como función de error.

$$E_{mse} = \frac{1}{mn} \sum_{i=1}^n \sum_{j=1}^m (t_{ij} - y_{ij})^2$$

Donde  $m$  es la cantidad de nodos de entrada,  $n$  es el número de ejemplos de entrenamiento,  $t_{ij}$  es la salida esperada,  $y_{ij}$  es la salida actual.

La siguiente tabla presenta los parámetros de configuración de la red neuronal artificial.

**Tabla 5**

*Parámetros de la red neuronal*

<b>Tipo de Función</b>	<b>RNA</b>
Nodos de entrada	4
Numero de capas ocultas	2
Nodos en la primera capa	32
Nodos en la segunda capa	64
Nodos de salida	1
Función de transferencia	Relu, Lineal
Función de error	MSE

Nota. Esta tabla muestra los parámetros de la red neuronal artificial.

### 3.8.2 Ingreso de datos

En este proyecto, se ha establecido una serie de datos de entrada y salida para el entrenamiento de una red neuronal destinada a predecir el comportamiento del sensor MAP en un motor de combustión interna. Seguidamente, se describen las matrices involucradas:

## 1. Carga de Datos

En la fig. 41 se observa cómo se cargan los datos desde un archivo Excel (data\_01.xlsx) utilizando la biblioteca pandas. En este conjunto de datos, las columnas representan diferentes variables clave para el modelo, incluyendo el tiempo, la presión MAP, El sensor MAF es un dispositivo que sirve para medir cuánto aire entra al motor, la velocidad del motor, la ubicación del acelerador y la masa de combustible que se ha inyectado.

### Figura 41

*Datos de entrada y salida de la red neuronal*

```
# Cargar datos
data = pd.read_excel('./data_01.xlsx', index_col=0)
data
```

tiempo	MAP	MAF	velocidad_motor	posicion_acelerador	masa_combustible_inyectado
0.000000	0.054752	0.007331	123.216611	7.247208	0.001153
0.050013	0.053873	0.007622	126.347235	7.814976	0.001098
0.100013	0.052701	0.007974	129.435445	7.779490	0.001078
0.150161	0.051822	0.008096	132.390455	7.744005	0.001078
0.200415	0.052408	0.008470	134.832297	8.702114	0.001067
...	...	...	...	...	...

El resultado es un DataFrame de pandas que organiza las variables de interés en columnas, con el tiempo como índice. Este DataFrame sirve como la base de datos a partir de la cual se puede extraer las matrices de entrada y salida.

### Variables Clave:

- MAP: Presión absoluta en el múltiple de admisión.
- MAF: Flujo de masa de aire.
- Velocidad del Motor: Medida en RPM.
- Posición del Acelerador: Indicada en porcentaje (%).

- Masa de Combustible Inyectada: Cantidad de combustible que se suministra por ciclo del motor.

## 2. Definición de las Matrices de Entrada y Salida

La figura 42 ilustra las matrices de ingreso y salida para la red neuronal:

**Figura 42**

*Matriz de entrada y salida de la red neuronal*

```
# Definir entradas y salidas de la red neuronal
input_cols = ['MAF', 'velocidad_motor', 'masa_combustible_inyectado']
output_cols = ['MAP']
X = data[input_cols].values
y = data[output_cols].values
print("Matriz de entradas")
print(X)
print("Matriz de salidas")
print(y)

Matriz de entradas
[[7.33128500e-03 1.23216611e+02 1.15281531e-03]
 [7.62232100e-03 1.26347235e+02 1.09817295e-03]
 [7.97412700e-03 1.29435445e+02 1.07848028e-03]
 ...
 [2.19977700e-03 9.15949580e+01 4.03882043e-04]
 [2.20303200e-03 9.16296899e+01 4.03463356e-04]
 [2.19673100e-03 9.15515783e+01 4.03463356e-04]]
Matriz de salidas
[[0.05475185]
 [0.053873 ]
 [0.05270122]
 ...
 [0.02311352]
 [0.02438295]
 [0.02311352]]
```

**Matriz de Entradas (X):** Está compuesta por las variables que servirán como entradas a la representación de una red neuronal. En esta situación, las entradas seleccionadas son MAF, velocidad del motor y masa combustible inyectado.

La matriz X cuenta con tantas filas como muestras disponibles de datos, y tantas columnas como variables de entrada (en este caso, 3). Cada fila de la matriz representa un conjunto de mediciones sincronizadas para un momento específico en el tiempo.



**Matriz de Salidas (y):** Está formada por la variable que deseamos predecir, en este caso, la presión (MAP). Esta es la salida que la red neuronal intentará predecir basándose en las entradas.

La matriz  $y$  tiene una única columna y tantas filas como muestras, correspondiendo cada valor al valor de la presión MAP en un momento determinado.

### **Significado y Uso:**

**Matriz de Entradas (X):** Se refiere a las cualidades o factores independientes que el modelo empleará para adquirir conocimiento y realizar pronósticos. Cada fila en la tabla de información representa la situación del sistema (motor) en un instante específico, teniendo en cuenta la ventilación, la rapidez del motor y la medida de gasolina suministrada.

**Matriz de Salidas (y):** Esta es la variable dependiente que se pretende predecir, es decir, la presión en el colector de admisión (MAP). A través del entrenamiento de la red neural, la finalidad es que el modelo pueda hacer predicciones utilizando los datos de  $X$  como base.

El objetivo es garantizar que la red neuronal entienda los complicados enlaces entre las entradas y salidas, permitiendo la capacidad de prever o anticipar el rendimiento de la presión MAP en diferentes situaciones de funcionamiento del motor. La precisión de estas predicciones es esencial para las aplicaciones prácticas en la optimización del funcionamiento del motor y la reducción de gases contaminantes hacia el medio ambiente.

### 3. Normalización de datos

Normalizar los datos con MinMaxScaler es esencial para asegurar que todas las variables de entrada y salida funcionen en un rango similar, permitiendo así el ensayo de la red neuronal. Este método escala las variables para que sus valores estén comprendidos entre 0 y 1.

#### Figura 43

*Normalización de datos*

```
# Normalizar los datos
scaler_X = MinMaxScaler()
scaler_y = MinMaxScaler()

X_scaled = scaler_X.fit_transform(X)
y_scaled = scaler_y.fit_transform(y)

X_train, X_test, y_train, y_test = train_test_split(X_scaled, y_scaled, test_size=0.2, random_state=42)
```

**Normalización de X:** Se normaliza la matriz de entrada X de manera que cada variable independiente se encuentre en el intervalo [0, 1].

**Normalización de y:** De manera similar, la matriz de salida y es normalizada para asegurar que la variable dependiente también se encuentre en el rango [0, 1].

### 4. División en Conjuntos de Entrenamiento y Prueba

Posteriormente, usando la función `train_test_split` con un `test_size` del 20%, se separan los datos normalizados en grupos de prueba y entrenamiento, En decir, el 80% de la información se emplea para instruir el modelo y el 20% para su evaluación. Este paso es fundamental para evaluar la habilidad del modelo puede funcionar bien con datos que no ha visto antes, para ver si puede resolver problemas nuevos.

### 3.8.3 Red neuronal

La siguiente línea de este código define cómo la red neuronal está organizada, dicha arquitectura indica que se ingresa una matriz X de dimensión (28854,4) lo cual indica que son 28854 muestras con 4 valores de entrada. Se incorpora una capa escondida inicial de 64 neuronas y una segunda capa escondida de 32 neuronas y al final como salida se tiene una neurona.

#### Figura 44

*Código de la red neuronal*

```
# Crear el modelo de red neuronal
model = models.Sequential()
model.add(layers.Dense(64, activation='relu', input_shape=(X_train.shape[1],)))
model.add(layers.Dense(32, activation='relu'))
model.add(layers.Dense(1, activation='linear'))

model.compile(optimizer='adam', loss='mean_squared_error')
```

La compilación de la red se realiza a través del optimizador Adam, reconocido por su efectividad en la convergencia del modelo, y la función de pérdida de error medio cuadrático (MSE), la cual resulta apropiada para problemas de regresión.

Antes del entrenamiento, los datos fueron normalizados para mejorar la eficiencia del modelo. Luego, se dividieron en grupos de entrenamiento y evaluación para medir su habilidad para generalizar.

### 3.8.4 Entrenamiento

La parte de entrenamiento consiste en comparar la salida deseada contra el valor real e iterar este proceso hasta que el error sea mínimo. A continuación, se detalla la manera en que se realizó este entrenamiento y los logros alcanzados.



Se hizo un entrenamiento del modelo empleando el método fit de Keras, el cual modifica los pesos de la red neuronal para disminuir la función de pérdida, en este caso, el error medio cuadrático (`mean_squared_error`). Durante el entrenamiento, el modelo fue entrenado con un grupo de información de entrada (`X_train`) y sus correspondientes valores de salida (`y_train`).

- **Épocas:** El entrenamiento se realizó durante 100 épocas, esto expresa que el modelo pasó por el conjunto de datos completos 100 veces para ajustar sus pesos.
- **Batch Size:** Se empleó una dimensión de lote de 16, lo que señala que el modelo ha actualizado sus pesos tras el procesamiento de cada grupo de 16 muestras.
- **Datos de Validación:** En el entrenamiento, se empleó un conjunto de validación (`X_test`, `y_test`) para valorar la eficacia del modelo en datos que no había observado durante la formación. Esto permite monitorear si el modelo está aprendiendo de manera adecuada o si se está modificando la información de entrenamiento.

Durante el entrenamiento, se guardó el historial del proceso, que incluye las pérdidas calculadas en cada época para los conjuntos de formación y aprobación.

- **Pérdida en Entrenamiento (loss):** Se refiere al promedio de error de tamaño en cada etapa de entrenamiento. Si hay menos errores con el tiempo, el modelo está aprendiendo de manera correcta.
- **Pérdida en Validación (val\_loss):** Es el error cuadrático medio calculado sobre el conjunto de validación. Es crucial que esta pérdida también disminuya para asegurarse de que el modelo no esté sobre ajustando.

## Figura 45

*Código para el entrenamiento de la red neuronal*

```
# Entrenar el modelo y guardar el historial de entrenamiento
history = model.fit(X_train, y_train, epochs=100, batch_size=16, validation_data=(X_test, y_test))

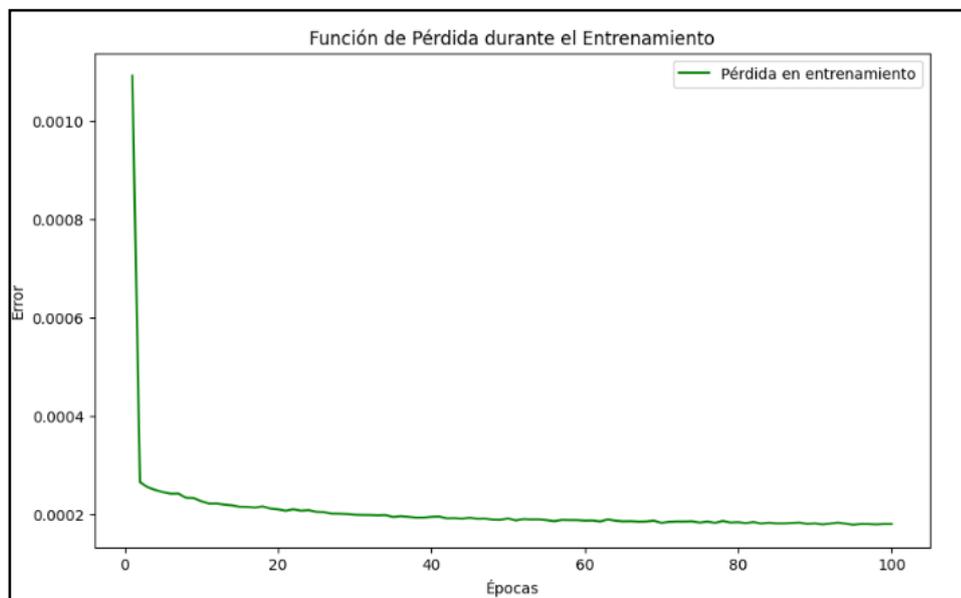
# Obtener la pérdida en el conjunto de entrenamiento y prueba
loss_train = history.history['loss']
loss_val = history.history['val_loss']
```

## Gráfico de la función de Pérdida

El gráfico muestra que la pérdida en el grupo de entrenamiento disminuye a medida que se avanza en las 100 épocas de formación.

## Figura 46

*Función de pérdida*



- **Error en el eje Y:** Se indica el valor del error cuadrático medio de la función de pérdida en cada una de las épocas.
- **Eje X (Épocas):** Muestra cuántas épocas han pasado en el proceso de entrenamiento.



- **Comportamiento de la Curva:** Se puede observar una disminución rápida de la pérdida al comienzo, seguida de una estabilización en niveles bajos a medida que avanza el entrenamiento. Este comportamiento es característico de un modelo que efectivamente está aprendiendo y alcanzando la convergencia.

La fig. 46 sugiere que el modelo funciona bien con los datos, porque la pérdida disminuye y se estabiliza en un valor mínimo. Esto significa que la red neuronal ha desarrollado la suficiencia de predecir la presión MAP con alta exactitud en los datos de entrenamiento y la rentabilidad en el grupo de validación también sugiere que no hay signos significativos de sobreajuste.



## CAPÍTULO IV

### RESULTADOS Y DISCUSIÓN

#### 4.1 ANÁLISIS DESCRIPTIVO DE LOS DATOS OBTENIDOS

##### 4.1.1 Descripción General de las Muestras y Condiciones Experimentales

El estudio se realizó utilizando un motor de cuatro cilindros de combustión interna, centrándose en predecir el funcionamiento del Sensor de Presión Absoluta del Múltiple de Admisión (MAP). se obtuvo información de 36.068 grupos de datos bajo variadas situaciones de operación del motor, incluyendo aceleración lenta y máxima, con un tiempo de muestra de 0,05 segundos.

Se realizaron evaluaciones o pruebas en diferentes entornos y niveles de carga del motor, replicando situaciones reales de conducción. Esta muestra es fundamental para que el modelo aprenda a gestionar condiciones de funcionamiento extremas cuando la demanda de energía es máxima.

La información se obtuvo en directo empleando una Raspberry Pi conectada al conector OBD II del coche y se analizó con programas como Python, y se aplicó para desarrollar un sistema de previsión que utiliza redes neuronales perceptrón multicapa (MLP), con la finalidad de mejorar la supervisión y la eficiencia del motor.

##### 4.1.2 Comportamiento del Sensor MAP en diferentes escenarios de operación

El rendimiento del sensor MAP fue analizado en distintas situaciones que reflejan el funcionamiento del motor.



- **Aceleración Gradual con Carga Baja:** El sensor MAP indicaba un aumento suave y escalonado de la presión como reacción a una aceleración lenta, habitual en condiciones de conducción moderadas.
- **Variación Rápida en la Aceleración:** Se notó una reacción rápida y evidente del sensor MAP frente a aceleraciones rápidas, mostrando un aumento repentino en la presión del colector de admisión, crucial para situaciones de alto rendimiento como rebases.
- **Aceleración Máxima:** Mientras el motor funcionaba a máxima capacidad, se detectaron picos de presión por el sensor MAP, los cuales son fundamentales para analizar el desempeño del motor en situaciones extremas.
- **Operación a Alta Velocidad:** En situaciones continuas de gran velocidad, el sensor MAP sostuvo una presión alta y constante, señalando una consistencia en la operación del motor.

Estos comportamientos fueron cruciales para desarrollar un modelo predictivo basado en redes neuronales, lo que permitió mejorar el control motor y optimizar la eficiencia.

#### 4.1.3 Análisis Estadístico de las variables recolectadas

Dentro de las variables obtenidas se incluyen la presión absoluta del colector de admisión (MAP), las RPM que indican la rapidez del motor, la cantidad de combustible inyectado por cada ciclo y la posición del acelerador. Estas variables fueron seleccionadas debido a su relevancia en la determinación del desempeño del motor y su influencia en el funcionamiento del sensor MAP.

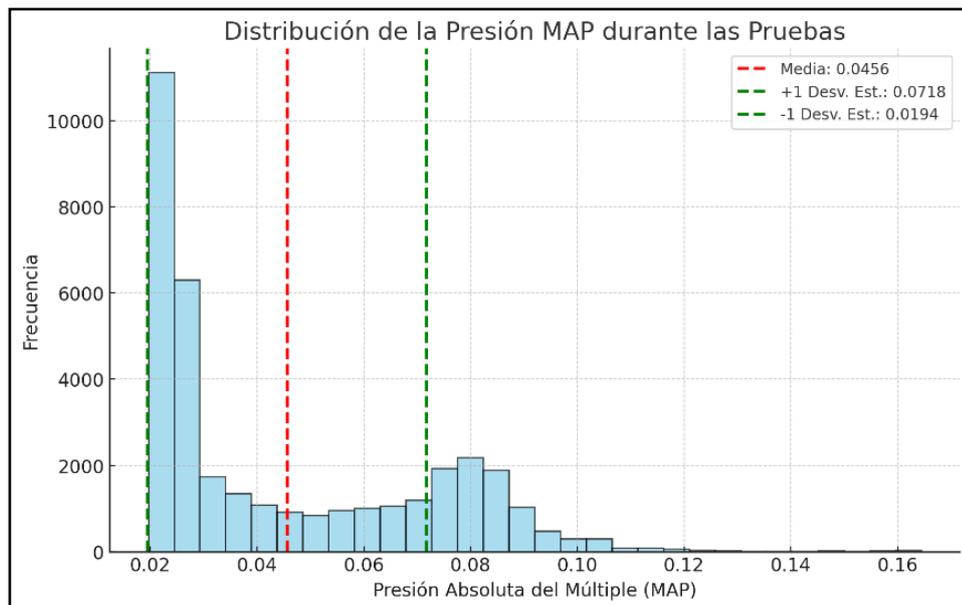
#### Análisis Descriptivo

Se realizaron análisis descriptivos básicos, como el cálculo de medias, medianas, desviaciones estándar y rangos intercuartílicos para cada una de las variables clave. Esta investigación preliminar permitió identificar la variabilidad y las tendencias generales de las mediciones obtenidas.

Presión del Múltiple de Admisión (MAP): El promedio de la presión MAP se encontró en un intervalo común para motores de explosión interna bajo las condiciones experimentales aplicadas, con una desviación estándar que muestra una moderada variación en los resultados, demostrando alteraciones en la carga del motor.

**Figura 47**

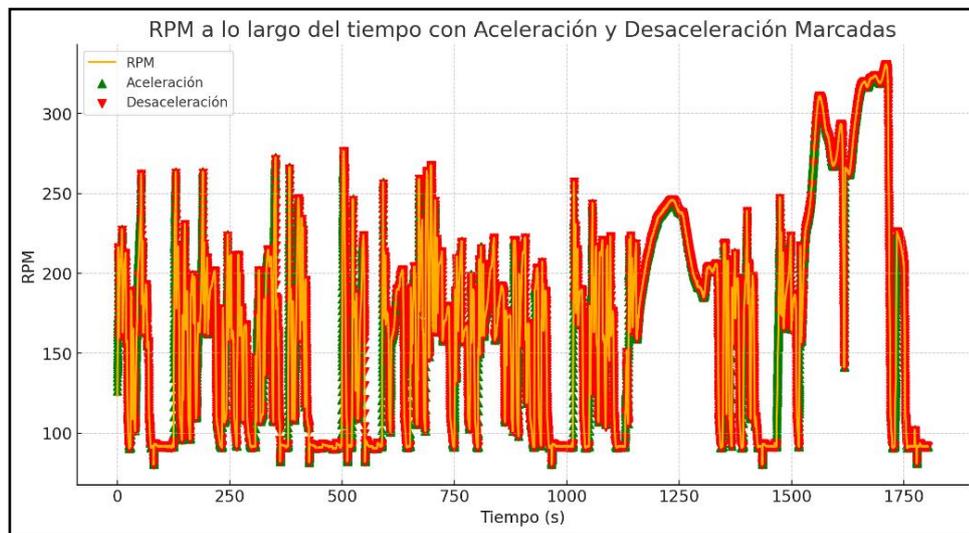
*Histograma del sensor MAP*



Velocidad del Motor (RPM): La distribución de las RPM mostró picos que coincidían con varias etapas de aceleración y desaceleración, un patrón que se alinea con las diversas situaciones operativas reproducidas en los experimentos.

**Figura 48**

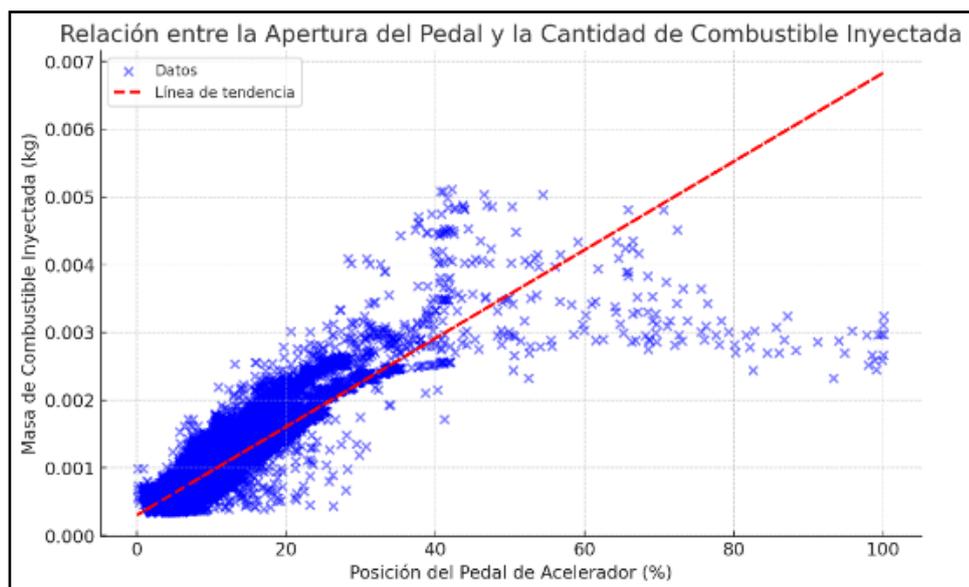
*Velocidad del motor*



Los datos de masa de combustible inyectado mostraron una asociación positiva con la ubicación del acelerador, validando la conexión directa entre la necesidad de energía y el suministro de combustible.

**Figura 49**

*Relación entre el pedal del acelerador y la cantidad de combustible*





En la fig. 49 los puntos azules representan los datos individuales, mientras que la línea de tendencia roja discontinua subraya la correlación positiva entre ambas variables.

Como se puede observar, conforme se incrementa la apertura del pedal, también tiende a aumentar la cantidad de combustible inyectada, lo que es un comportamiento esperado en un motor a combustión.

### **Correlaciones y Relación entre Variables**

Se realizó un estudio de correlación entre las variables para entender las interacciones más significativas que podrían influir en el comportamiento del sensor MAP.

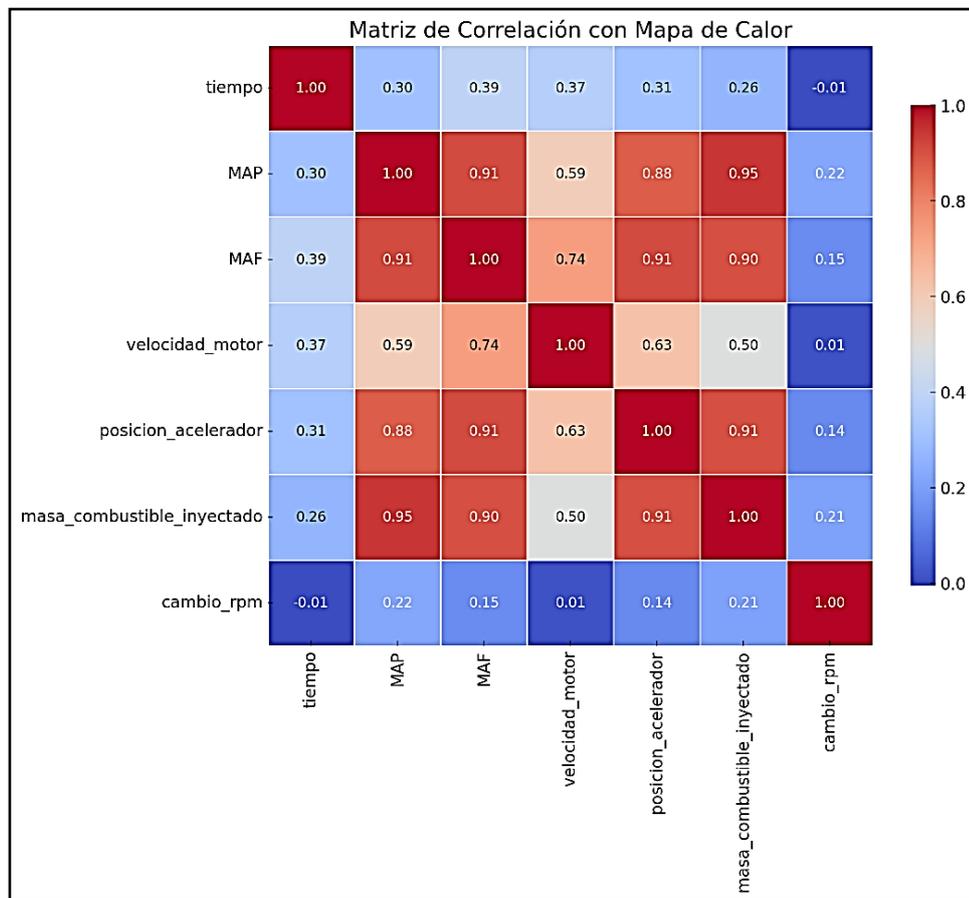
Las correlaciones más destacadas incluyeron:

MAP y RPM: Se detectó una correlación positiva entre la presión MAP y la velocidad del motor, lo que sugiere que aumentos en las RPM tienden a elevar la presión en el múltiple de admisión.

Posición del Pedal y Masa de Combustible: La posición del pedal de aceleración mostró una correlación significativa con la masa de combustible inyectada, lo cual es consistente con la lógica operativa del motor, donde mayor apertura del pedal implica mayor inyección de combustible.

**Figura 50**

*Gráfica de correlación de variables*



## 4.2 RESULTADOS DEL MODELO DE PREDICCIÓN BASADO EN REDES NEURONALES

### 4.2.1 Configuración y Entrenamiento del Modelo Predictivo

El modelo predictivo desarrollado se basa en una red neuronal artificial configurada con 4 nodos de entrada, dos capas intermedias (64 y 32 neuronas, respectivamente), y un nodo de salida para hacer la predicción de la presión del múltiple de admisión (MAP). La función de activación ReLU y el Error Cuadrático Medio (MSE) se emplearon para medir la pérdida.

Los datos fueron normalizados y divididos en un 80% para entrenamiento y 20% para pruebas. El modelo se entrenó durante 100 épocas con un tamaño de lote de 16, lo que facilitó la modificación de los pesos de la red para reducir el error. El proceso de entrenamiento mostró una disminución constante en la pérdida, indicando un aprendizaje efectivo sin sobreajuste. Al analizar el modelo con el conjunto de prueba, se demostró su capacidad para predecir con alta precisión el comportamiento del sensor MAP, validando su aplicación para mejorar el desempeño del motor y disminuir las emisiones.

#### 4.2.2 Evaluación de la Precisión y Confiabilidad del Modelo

Se evaluó la precisión y confiabilidad del modelo predictivo usando el Error Porcentual Absoluto Medio (MAPE). Este indicador se determina para calcular la desviación media entre los valores reales de la presión del múltiple de admisión (MAP) y los valores estimados por el modelo, expresado como un porcentaje.

##### Cálculo del MAPE

El MAPE fue calculado utilizando la siguiente fórmula:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100$$

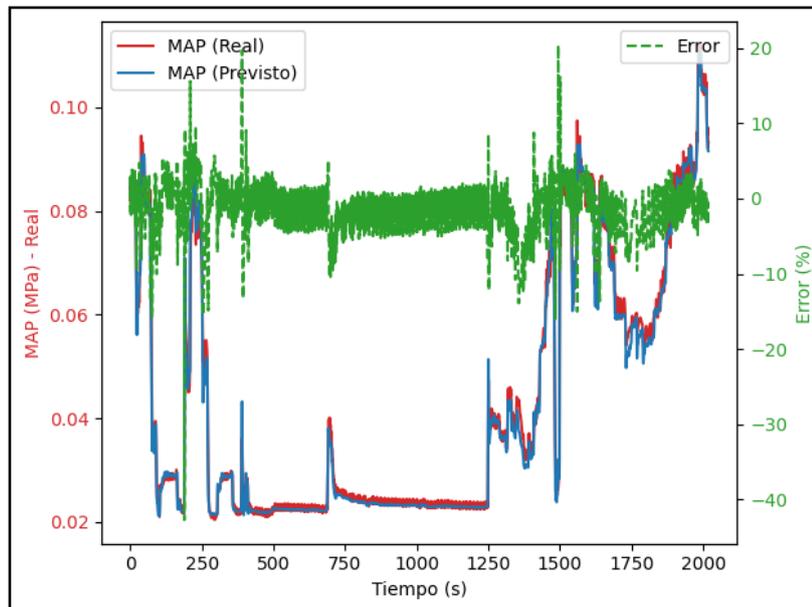
El resultado obtenido fue un MAPE del 2.79%, lo que indica una elevada exactitud del modelo en la proyección de la presión MAP. Un MAPE inferior al 5% generalmente se considera un buen indicador de precisión, lo que sugiere que el modelo es confiable para aplicaciones prácticas.

##### Análisis del Error a lo Largo del Tiempo

Además del cálculo del MAPE, se generó una gráfica que muestra el error en cada instante de tiempo durante el conjunto de pruebas ver figura 51.

**Figura 51**

*MAPE a través del tiempo*



Nota. La figura representa el MAP (Real) que muestra los valores reales de la presión MAP, el MAP (Previsto) muestra los valores pronosticados por el modelo y el Error que muestra la diferencia porcentual entre los valores reales y predichos en cada instante del tiempo.

La fig. 51 revela que, aunque el modelo conserva una precisión elevada en la mayoría de las situaciones, existen fluctuaciones en el error, especialmente en situaciones de transición rápida en las condiciones del motor. Estos picos de error podrían estar asociados a cambios abruptos en la demanda del motor, donde el modelo podría necesitar ajustes adicionales para mejorar la precisión en estas condiciones.

### **Conclusiones sobre la Confiabilidad del Modelo**

El bajo MAPE y el comportamiento del error a lo largo del tiempo indican que el modelo de pronóstico es muy confiable para la mayoría de las circunstancias en las que el motor está en funcionamiento. Sin embargo, hay áreas



donde la predicción puede ser mejorada en contextos de transformaciones rápidas, lo que sugiere la posibilidad de ajustar la configuración del modelo o incluir técnicas adicionales para capturar de forma más efectiva estos cambios dinámicos.

### **4.3 DISCUSIÓN DE RESULTADOS**

Durante esta sección, los descubrimientos adquiridos durante la investigación son presentados y analizados, contrastándolos con las suposiciones propuestas y los resultados de estudios anteriores en el área. La conversación se enfoca en analizar la exactitud y fiabilidad del modelo de predicción creado para el sensor de MAP, además de detectar las zonas para mejorar y las implicaciones de los hallazgos en el área de operación y mantenimiento de motores de combustión interna.

#### **4.3.1 Precisión del Modelo Predictivo**

Los datos conseguidos, mostrados en un promedio de error porcentual absoluto (MAPE) del 2.79%, indican que el modelo de predicción que utiliza redes neuronales es muy preciso al predecir el desempeño del sensor MAP en diversas situaciones operativas del motor. Un error medio absoluto porcentual (MAPE) inferior al 5% se suele considerar excelente en predicciones, lo cual sugiere que el modelo desarrollado es robusto y puede generalizar de manera adecuada a datos nuevos que no fueron vistos durante el entrenamiento.

El bajo valor de MAPE sugiere que las variables escogidas (ritmo del motor, cantidad de combustible inyectado y posición del pedal de aceleración) son apropiadas para registrar las interacciones del sistema de entrada de aire en el motor. Además, la normalización de los datos y la arquitectura de la red neuronal contribuyeron significativamente a disminuir los errores y mejorar la precisión predictiva.

### 4.3.2 Análisis del Comportamiento del Error

El análisis gráfico del error en función del tiempo reveló que, a pesar de que el modelo es normalmente exacto, hay algunos puntos máximos de error relacionados con cambios repentinos en las circunstancias de funcionamiento del motor, como variaciones bruscas en la ubicación del pedal de aceleración. Estos picos sugieren que el modelo puede no estar captando plenamente algunas de las dinámicas más complejas del sistema en estas condiciones extremas.

Este comportamiento es comprensible, teniendo en cuenta que las transiciones rápidas pueden introducir no linealidades difíciles de modelar con la arquitectura de red neuronal utilizada. No obstante, este descubrimiento también presenta oportunidades para mejoras, como agregar mayores niveles en el modelo de inteligencia artificial, o utilizar técnicas avanzadas de preparación de datos que podrían ayudar a suavizar estas transiciones en la información de entrada.

### 4.3.3 Comparación con Estudios Anteriores

Estudios parecidos que se realizaron han demostrado que las redes neuronales pueden predecir aspectos importantes en motores de combustión interna. Por ejemplo, estudios anteriores han documentado equivocaciones parecidas o superiores en la estimación de factores como la inyección de carburante o la presión de la cámara de combustión. La demostración de la eficacia de este modelo para alcanzar un MAPE tan reducido valida la teoría de que las redes neuronales, al ser ajustadas y preparadas correctamente, son recursos sumamente eficaces para ser utilizados en situaciones de control y supervisión en tiempo real en motores.

Contreras et al., (2018), utilizaron una Red Neuronal Artificial Recurrente (RNAR) para determinar la presión máxima de compresión en un motor de

encendido provocado. Su metodología se basó en el análisis de las curvas de consumo de amperaje del motor de arranque y logró una precisión impresionante con un error absoluto menor al 2%.

Escandon (2024), ha desarrollado un sistema inteligente en Android para diagnosticar fallas mecánicas en motores de encendido provocado utilizando el sensor MAP y técnicas de Machine Learning. Su sistema, validado mediante análisis estadístico ANOVA, demostró una alta confiabilidad en la detección de fallas, ofreciendo una herramienta valiosa para técnicos e ingenieros automotrices.

Namigtle Jiménez (2018), propuso un esquema de detección y diagnóstico de fallas en inyectores de motores de combustión interna mediante redes neuronales artificiales. Este esquema, implementado en un FPGA, clasifica las fallas en el sistema de inyección de combustible electrónico, utilizando tres redes neuronales tipo perceptrón y el algoritmo Levenberg-Marquardt para el aprendizaje.

A. Cabrera (2018), crearon un algoritmo de aprendizaje automático para la detección temprana de fallas en vehículos M1 con motores de encendido provocado. Emplearon Máquinas de Soporte Vectorial (SVM) y Matlab, analizaron datos del sistema para identificar fallas, buscando mejorar el mantenimiento, restando el consumo de combustible y los gases contaminantes.

#### **4.3.4 Implicaciones Prácticas y Futuras Aplicaciones**

La precisión elevada de la modelo implica que podría ser utilizado en sistemas de control dentro de los vehículos para mejorar el funcionamiento del motor y reducir las emisiones. Además, el modelo puede adaptarse a diferentes situaciones en las que funciona el motor, lo que lo hace útil para controlar



continuamente su estado. Esto ayuda a hacer cambios rápidos para que el motor funcione mejor.

Sin embargo, se aconseja que investigaciones futuras consideren la inclusión de una mayor cantidad de variables de entrada, como la temperatura del motor o la presión atmosférica, lo cual podría aumentar la exactitud del modelo de manera adicional. De igual manera, la utilización de estructuras más sofisticadas, como las redes neuronales profundas (Deep Learning).

### **Conclusión de la Discusión**

Finalmente, los resultados de esta investigación respaldan la afirmación de que las redes neuronales artificiales pueden predecir con gran precisión el rendimiento de un sensor MAP en un motor de gasolina.

Se reconoce la eficacia de las redes neuronales en la predicción de parámetros del motor y el diagnóstico de fallas.

Contreras et al., (2018), resaltan el potencial de las redes neuronales para mejorar la confiabilidad operativa de los motores a gasolina y diésel, así como su papel en la mitigación de la contaminación atmosférica.

Carrabs Gonçalves (2022), argumenta que las redes neuronales ofrecen una alternativa eficiente y menos costosa a los modelos tradicionales basados en dinámica de fluidos computacional (CFD) para predecir parámetros cruciales del proceso de combustión.

Hurtado Cortés et al., (2016), mencionan que los sensores MAP modernos incorporan funciones de autodiagnóstico que permiten a la ECM detectar y diagnosticar problemas, lo que facilita el uso de redes neuronales para análisis predictivo.



## V. CONCLUSIONES

- Se logró describir detalladamente el sistema de admisión de un motor a combustión y la función crucial que desempeña el sensor MAP en este sistema. Esta descripción abarcó desde los principios básicos de rendimiento del motor de encendido provocado (MEP) hasta los aspectos específicos de la formación de la combinación de aire-combustible. Se explicó cómo el sensor MAP mide la presión absoluta en el múltiple de admisión, información esencial para que la Unidad de Control del Motor (ECM) ajuste la cantidad de combustible inyectado y optimice la combustión.
- Se implementó exitosamente un sistema de adquisición de datos en tiempo real utilizando una Raspberry Pi conectada al puerto OBDII del vehículo de prueba. Este sistema permitió recopilar información precisa de diversos sensores del motor, incluyendo el sensor MAP, también se desarrolló un programa en Python para la extracción, procesamiento y análisis de los datos obtenidos a través del sistema de adquisición. Este programa permitió visualizar y analizar las variables relevantes para el estudio, como la presión del múltiple de admisión, la velocidad del motor, la masa de combustible inyectada y la posición del acelerador.
- Los resultados mostraron que el modelo predictivo alcanzó una exactitud en la predicción del comportamiento del sensor MAP, con un MAPE del 2.79%. Este bajo valor de MAPE demuestra la eficacia del modelo para anticipar la presión del múltiple de admisión en diferentes escenarios operativos.



## VI. RECOMENDACIONES

- Se sugiere realizar investigaciones futuras centrándose en incorporar variables adicionales, como la temperatura del motor o la presión atmosférica, y en evaluar arquitecturas más complejas, como las redes neuronales profundas, Para mejorar el modelo y hacerlo más preciso y resistente, especialmente en situaciones extremas.
- Se recomienda aumentar el número de capas de la red neuronal puede mejorar la capacidad del modelo para captar relaciones más complejas en los datos, aunque esto podría conllevar un mayor tiempo de entrenamiento. Una red más profunda podría resultar especialmente beneficiosa para detectar las dinámicas no lineales que se producen durante las transiciones rápidas en el funcionamiento del motor.
- Es recomendable tener mucha información para entrenar el modelo predictivo. La disponibilidad de más datos permitirá al modelo aprender de una mayor variedad de escenarios operativos, lo que podría resultar en una mejor generalización y mayor precisión en las predicciones bajo condiciones diversas.



## VII. REFERENCIAS BIBLIOGRÁFICAS

- a. cabrera, b. c. (2018). *desarrollo de un algoritmo mediante análisis de aprendizaje automático para la detección de fallos en vehículos m1 con motores de encendido provocado*. 22–134.  
<http://dspace.ups.edu.ec/handle/123456789/16584>
- aldo calsin, r. r. (2015). “*análisis y diseño de un modulo de control electrónico (ecm) para la optimización de la potencia de un motor de combustión interna toyota 4afe.*”
- b. ramirez, m. t. (2020). *reconocimiento automático de placas de rodaje utilizando una red neuronal convolucional para el ingreso de vehículos en la universidad ricardo*. n<sup>o</sup>, 15, 169–177. <https://hdl.handle.net/20.500.14138/4972>
- booster, b. (2010). *los orígenes del diagnóstico con escaner* (p. 182).
- carrabs gonçalves, l. a. (2022). *análisis de un sistema de combustión alimentado con combustibles sostenibles (e-fuels) usando redes neuronales*.  
<https://riunet.upv.es:443/handle/10251/184203>
- chafuel, a. (2022). *diseño y construcción de un sistema de simulación de circuitos para pruebas en banco de sensores y actuadores del sistema de gestión electrónica del motor de combustión interna*. 16–31. [chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://repositorio.unesum.edu.ec/bitstream/53000/2681/1/garcia\\_parrales\\_katherin\\_jhosia.pdf](chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://repositorio.unesum.edu.ec/bitstream/53000/2681/1/garcia_parrales_katherin_jhosia.pdf)
- contreras, w., arichávala, m., & jérez, c. (2018). *determinación de la presión máxima de compresión de un motor de encendido provocado basado en una red neuronal artificial recurrente determination of the maximum compression pressure of an engine provoked ignition based on a recurrent artificial neural ne*. 9–18.
- escandon christian. (2024). *desarrollo de un sistema inteligente de diagnóstico de fallas mecánicas en motores de encendido provocado a través del sensor map para dispositivos móviles en plataforma android*. cuenca.
- garcía-basurto, a., saucedo-dorantes, j. j., pérez-cruz, á., & osornio-río, r. a. (2021). *análisis de falla de encendido en motores de combustión utilizando señales de*



- vibración basado en el cálculo y reducción de indicadores estadísticos. científica, 25(1), 83–95. <https://doi.org/10.46842/ipn.cien.v25n1a07>*
- garzón, g., & urdiales, m. (2017). *diseño e implementación de un sistema para determinar fallas mecánicas en motores de encendido provocado mediante redes neuronales artificiales.*
- hurtado-cortés, l. l., villarreal-lópez, e., & villarreal-lópez, l. (2016). *detección y diagnóstico de fallas mediante técnicas de inteligencia artificial, un estado del arte. dyna (colombia), 83(199), 19–28. <https://doi.org/10.15446/dyna.v83n199.55612>*
- lopez aldea, e. (2017). *raspberry pi: fundamentos y aplicaciones. <https://elibro.net/es/lc/utpbiblio/titulos/106504>*
- maldonado, r. l. j. (2018). *identificación de patrones de fallas mecánicas mediante redes neuronales artificiales para el diagnóstico de motores de encendido provocado. <https://dspace.ups.edu.ec/handle/123456789/23640%0ahttp://dspace.ups.edu.ec/handle/123456789/16161>*
- manchado, m. c. (2018). *predicción demanda eléctrica española. implementación de redes neuronales recurrentes.*
- montero, s., & ponce, r. (2022). *sistema de monitoreo para la detección automática de placas de vehículos en lima metropolitana utilizando redes neuronales. <http://hdl.handle.net/10757/660720>*
- montesinos, a. (2017). *propuesta de metodología para el análisis exergético de un motor de encendido por chispa. 88. [http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/9874/torres\\_po rtilla\\_a\\_proposito\\_del\\_principio\\_de\\_gradualidad\\_analisis\\_del\\_proceso\\_de\\_ad ecuacion\\_de\\_los\\_estandares\\_nacionales.pdf?sequence=1&isallowed=y](http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/9874/torres_po rtilla_a_proposito_del_principio_de_gradualidad_analisis_del_proceso_de_ad ecuacion_de_los_estandares_nacionales.pdf?sequence=1&isallowed=y)*
- moreno, n. (2016). *identificación y diagnóstico de los mcia mediante protocolos can-obdii.*
- morillo tarapués, d. f. (2020). *modelo para el pronóstico de la demanda de energía eléctrica de emelnorte s.a. - ibarra aplicando redes neuronales artificiales. 136.*



*[http://repositorio.utn.edu.ec/bitstream/123456789/10658/2/04\\_ind\\_271\\_trabajo\\_grado.pdf](http://repositorio.utn.edu.ec/bitstream/123456789/10658/2/04_ind_271_trabajo_grado.pdf)*

namigtle jiménez, a. (2018). *diagnóstico de fallas en un riel de inyectores*.

*[https://www.cenidet.edu.mx/archivos/electronica/tesis/2018/389mc\\_anj.pdf](https://www.cenidet.edu.mx/archivos/electronica/tesis/2018/389mc_anj.pdf)*

nevot, j. (1999). *diseño de un controlador avanzado basado en redes neuronales para la gestión de la mezcla aire-gasolina en un motor alternativo*.

oquendo, v. m. (2011). *redes neuronales artificiales en las ciencias económicas*. *ssrn electronic journal*, 1–25. *<https://doi.org/10.2139/ssrn.2194966>*

rodriguez, a. d. s., & castellanos, c. j. u. (2020). *sensor maf en vehículos utilitarios - posibles fallas un estado del arte*. *universidad cooperativa de colombia*, 1–12. *<https://repository.ucc.edu.co/handle/20.500.12494/28308>*

sinaluisa lozano, i. f. (2017). *aplicación de la red neuronal artificial feedforward backpropagation para la predicción de demanda de energía eléctrica en la empresa eléctrica riobamba s.a.* 1–115.

*<http://dspace.esPOCH.edu.ec/bitstream/123456789/7606/1/20t00925.pdf>*

w. contreras, j. maldonado, r. l. (2019). *aplicación de una red neuronal feed-diagnóstico de fallas mecánicas en forward backpropagation para el motores de encendido provocado*. 1–12.



## ANEXOS

### ANEXO 1: Código Python para la inspección de datos

```
1 import pandas as pd
2 import numpy as np
3 import matplotlib.pyplot as plt
4
5 data = pd.read_excel('./data_01.xlsx', index_col=0)
6 data
7
8 # Filtrar los datos para incluir solo los primeros 60 segundos
9 data_subset = data[data.index <= 60]
10
11 # Crear la figura y los ejes
12 fig, ax = plt.subplots()
13
14 # Graficar solo la variable MAP en el eje Y izquierdo
15 ax.plot(data_subset.index, data_subset['MAP'], color='blue',
16 label='MAP')
17 ax.set_xlabel('Tiempo (s)')
18 ax.set_ylabel('MAP (MPa)')
19
20 # Añadir leyenda
21 ax.legend(loc='upper left')
22
23 # Mostrar la gráfica
24 plt.show()
25
26 # Filtrar los datos para incluir solo los primeros 60 segundos
27 data_subset = data
28
29 # Crear la figura y los ejes
30 fig, ax = plt.subplots()
31
32 # Graficar solo la variable velocidad_motor en el eje Y izquierdo
33 ax.plot(data_subset.index, data_subset['velocidad_motor'],
34 color='green', label='Velocidad del Motor')
35 ax.set_xlabel('Tiempo (s)')
36 ax.set_ylabel('Velocidad del Motor (RPM)')
37
38 # Añadir leyenda
39 ax.legend(loc='upper left')
40
41 # Mostrar la gráfica
42 plt.show()
43
44 # Filtrar los datos para incluir solo los primeros 60 segundos
45 data_subset = data[data.index <= 60]
46
47 # Crear la figura y los ejes
48 fig, ax = plt.subplots()
49
50 # Graficar solo la variable posicion_acelerador en el eje Y derecho
```



```
51 ax.plot(data_subset.index, data_subset['posicion_acelerador'],
52 color='red', label='Posición del Pedal de Aceleración')
53 ax.set_ylabel('Posición del Pedal de Aceler. (%)')
54 ax.set_xlabel('Tiempo (s)')
55
56 # Añadir leyenda
57 ax.legend(loc='upper left')
58
59 # Mostrar la gráfica
60 plt.show()
61
62 # Crear la figura y los ejes
63 fig, ax1 = plt.subplots()
64
65 # Graficar MAP en el eje Y izquierdo
66 ax1.plot(data.index, data['MAP'], color='blue', label='MAP')
67 ax1.set_xlabel('Tiempo (s)')
68 ax1.set_ylabel('MAP (MPa)', color='blue')
69 ax1.tick_params('y', colors='blue')
70
71 # Crear un segundo eje Y para posicion_acelerador y
72 masa_combustible_inyectado
73 ax2 = ax1.twinx()
74
75 # Escalar los valores de injected_fuel_mass para ajustar la escala
76 scaling_factor = 10000 # Ajusta este valor según tu preferencia
77 ax2.plot(data.index, data['posicion_acelerador'], color='green',
78 label='Posicion del pedal de aceleración')
79 ax2.plot(data.index, data['masa_combustible_inyectado'] *
80 scaling_factor, color='red', label='Masa de combustible inyectada
81 (escalado)')
82 ax2.set_ylabel('Posicion del pedal de aceleración (%) \n Masa de
83 combustible inyectado (g)', color='black')
84 ax2.tick_params('y', colors='black')
85
86 # Añadir leyenda
87 lines, labels = ax1.get_legend_handles_labels()
88 lines2, labels2 = ax2.get_legend_handles_labels()
89 ax2.legend(lines + lines2, labels + labels2, loc='upper left')
90
91 # Mostrar la gráfica
92 plt.show()
93
94 # Filtrar los datos para incluir solo los primeros 120 segundos
95 data_subset = data[data.index <= 2]
96
97 # Crear la figura y los ejes
98 fig, ax1 = plt.subplots()
99
100 # Graficar MAP en el eje Y izquierdo
101 ax1.plot(data_subset.index, data_subset['MAP'], color='blue',
102 label='MAP')
103 ax1.set_xlabel('Tiempo (s)')
104 ax1.set_ylabel('MAP (MPa)', color='blue')
105 ax1.tick_params('y', colors='blue')
106
107 # Crear un segundo eje Y para throttle_position e injected_fuel_mass
```



```
108 ax2 = ax1.twinx()
109
110 # Escalar los valores de injected_fuel_mass para ajustar la escala
111 scaling_factor = 10000 # Ajusta este valor según tu preferencia
112 ax2.plot(data_subset.index, data_subset['posicion_acelerador'],
113 color='green', label='Posicion del pedal de aceleración')
114 ax2.plot(data_subset.index,
           data_subset['masa_combustible_inyectado'] * scaling_factor,
           color='red', label='Masa de combustible inyectada (escalado)')
ax2.set_ylabel('Posicion del pedal de aceleración (%) \n Masa de
combustible inyectado (g)', color='black')
ax2.tick_params('y', colors='black')

# Añadir leyenda
lines, labels = ax1.get_legend_handles_labels()
lines2, labels2 = ax2.get_legend_handles_labels()
ax2.legend(lines + lines2, labels + labels2, loc='upper left')

# Mostrar la gráfica
plt.show()
```

## ANEXO 2: Código Python para la implementación de la red neuronal

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
import tensorflow as tf
from tensorflow.keras import layers, models

# Cargar datos
data = pd.read_excel('./data_01.xlsx', index_col=0)
data

# Definir entradas y salidas de la red neuronal
input_cols = ['MAF', 'velocidad_motor', 'masa_combustible_inyectado']
output_cols = ['MAP']
X = data[input_cols].values
y = data[output_cols].values
print("Matriz de entradas")
print(X)
print("Matriz de salidas")
print(y)

# Normalizar los datos
scaler_X = MinMaxScaler()
scaler_y = MinMaxScaler()

X_scaled = scaler_X.fit_transform(X)
y_scaled = scaler_y.fit_transform(y)

X_train, X_test, y_train, y_test = train_test_split(X_scaled,
y_scaled, test_size=0.2, random_state=42)

# Crear el modelo de red neuronal
model = models.Sequential()
model.add(layers.Dense(64, activation='relu',
input_shape=(X_train.shape[1],)))
model.add(layers.Dense(32, activation='relu'))
model.add(layers.Dense(1, activation='linear'))

model.compile(optimizer='adam', loss='mean_squared_error')

# Entrenar el modelo y guardar el historial de entrenamiento
history = model.fit(X_train, y_train, epochs=100, batch_size=16,
validation_data=(X_test, y_test))

# Obtener la pérdida en el conjunto de entrenamiento y prueba
loss_train = history.history['loss']
loss_val = history.history['val_loss']

# Crear la gráfica de la función de pérdida
epochs = range(1, len(loss_train) + 1)

plt.figure(figsize=(10, 6))
plt.plot(epochs, loss_train, 'g', label='Pérdida en entrenamiento')
```

```
plt.title('Función de Pérdida durante el Entrenamiento')  
plt.xlabel('Épocas')  
plt.ylabel('Error')  
plt.legend()  
plt.show()  
  
# Evaluar el modelo  
loss = model.evaluate(X_test, y_test)  
print(f'Loss en conjunto de prueba: {loss}')  
# Guardar el modelo  
model.save("modelo_entrenado.h5")
```

### ANEXO 3: Panel fotográfico

FOTO N° 01.	FOTO N° 02.
	
<p>Se realizo el proceso de escaneo en el laboratorio diésel en la ciudad de Juliaca.</p>	<p>Pruebas de escaneo realizadas a diferentes velocidades del vehículo.</p>



## ANEXO 4: Declaración jurada de autenticidad de tesis



Universidad Nacional  
del Altiplano Puno



Vicerrectorado  
de Investigación



Repositorio  
Institucional

### DECLARACIÓN JURADA DE AUTENTICIDAD DE TESIS

Por el presente documento, Yo BELISARIO CALLASACA QUILCA,  
identificado con DNI 71055289 en mi condición de egresado de:

Escuela Profesional,  Programa de Segunda Especialidad,  Programa de Maestría o Doctorado  
INGENIERÍA MECÁNICA ELÉCTRICA

informo que he elaborado el/la  Tesis o  Trabajo de Investigación denominada:  
" PREDICCIÓN DEL COMPORTAMIENTO DEL SENSOR DE PRESIÓN  
ABSOLUTA DEL MÚLTIPLE DE ADMISIÓN DE UN MOTOR A  
COMBUSTIÓN MEDIANTE REDES NEURONALES ARTIFICIALES "

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, me someto a las disposiciones legales vigentes y a las sanciones correspondientes de igual forma me someto a las sanciones establecidas en las Directivas y otras normas internas, así como las que me alcancen del Código Civil y Normas Legales conexas por el incumplimiento del presente compromiso

Puno 11 de DICIEMBRE del 2024

FIRMA (obligatoria)



Huella



## ANEXO 5: Autorización para el depósito de tesis de investigación en el repositorio institucional



Universidad Nacional  
del Altiplano Puno



Vicerrectorado  
de Investigación



Repositorio  
Institucional

### AUTORIZACIÓN PARA EL DEPÓSITO DE TESIS O TRABAJO DE INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL

Por el presente documento, Yo BELISARIO CALLASACA QUILCA identificado con DNI 71055289 en mi condición de egresado de:

Escuela Profesional,  Programa de Segunda Especialidad,  Programa de Maestría o Doctorado

INGENIERÍA MECÁNICA ELÉCTRICA

informo que he elaborado el/la  Tesis o  Trabajo de Investigación denominada:

“PREDICCIÓN DEL COMPORTAMIENTO DEL SENSOR DE PRESIÓN ABSOLUTA DEL MÚLTIPLE DE ADMISIÓN DE UN MOTOR A COMBUSTIÓN MEDIANTE REDES NEURONALES ARTIFICIALES”

para la obtención de  Grado,  Título Profesional o  Segunda Especialidad.

Por medio del presente documento, afirmo y garantizo ser el legítimo, único y exclusivo titular de todos los derechos de propiedad intelectual sobre los documentos arriba mencionados, las obras, los contenidos, los productos y/o las creaciones en general (en adelante, los “Contenidos”) que serán incluidos en el repositorio institucional de la Universidad Nacional del Altiplano de Puno.

También, doy seguridad de que los contenidos entregados se encuentran libres de toda contraseña, restricción o medida tecnológica de protección, con la finalidad de permitir que se puedan leer, descargar, reproducir, distribuir, imprimir, buscar y enlazar los textos completos, sin limitación alguna.

Autorizo a la Universidad Nacional del Altiplano de Puno a publicar los Contenidos en el Repositorio Institucional y, en consecuencia, en el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto, sobre la base de lo establecido en la Ley N° 30035, sus normas reglamentarias, modificatorias, sustitutorias y conexas, y de acuerdo con las políticas de acceso abierto que la Universidad aplique en relación con sus Repositorios Institucionales. Autorizo expresamente toda consulta y uso de los Contenidos, por parte de cualquier persona, por el tiempo de duración de los derechos patrimoniales de autor y derechos conexos, a título gratuito y a nivel mundial.

En consecuencia, la Universidad tendrá la posibilidad de divulgar y difundir los Contenidos, de manera total o parcial, sin limitación alguna y sin derecho a pago de contraprestación, remuneración ni regalía alguna a favor mío; en los medios, canales y plataformas que la Universidad y/o el Estado de la República del Perú determinen, a nivel mundial, sin restricción geográfica alguna y de manera indefinida, pudiendo crear y/o extraer los metadatos sobre los Contenidos, e incluir los Contenidos en los índices y buscadores que estimen necesarios para promover su difusión.

Autorizo que los Contenidos sean puestos a disposición del público a través de la siguiente licencia:

Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional. Para ver una copia de esta licencia, visita: <https://creativecommons.org/licenses/by-nc-sa/4.0/>

En señal de conformidad, suscribo el presente documento.

Puno 11 de DICIEMBRE del 2024

FIRMA (obligatoria)



Huella