



# **UNIVERSIDAD TÉCNICA DEL NORTE**

## **FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS CARRERA DE INGENIERÍA AUTOMOTRIZ**

### **TRABAJO DE GRADO PREVIO A LA OBTENCIÓN DEL TÍTULO DE INGENIERO AUTOMOTRIZ**

#### **TEMA:**

**PROPUESTA TÉCNICA DE UN SISTEMA PARA EL DIAGNÓSTICO PREDICTIVO DE  
UN MOTOR DIÉSEL EN BASE A GASES DE ESCAPE**

#### **AUTORES:**

**MEDINA YÁNEZ JOSUE ISMAEL**

**LÓPEZ GUAMIALAMAG JORGE ELÍAS**

**DIRECTOR: ING. MAFLA YÉPEZ CARLOS NOLASCO MSC.**

**IBARRA, ENERO 2024**

## **CERTIFICADO**

### **ACEPTACIÓN DEL TUTOR**

En mi calidad de director del plan de trabajo de grado, previo a la obtención del título de Ingeniería Automotriz, nombrado por el Honorable Consejo Directivo de la Facultad de Ingeniería en Ciencias Aplicadas.

### **CERTIFICO**

Que una vez analizado el plan de grado cuyo título es "PROPUESTA TÉCNICA DE UN SISTEMA PARA EL DIAGNÓSTICO PREDICTIVO DE UN MOTOR DIÉSEL EN BASE A GASES DE ESCAPE" presentado por los señores: Medina Yáñez Josue Ismael con número de cédula 1004396634 y López Guamialamag Jorge Elías con número de cédula 1005024607, doy fe que dicho trabajo reúne los requisitos y méritos suficientes para ser sometido a presentación pública y evaluación por parte de los señores integrantes del jurado examinador que se designe.

En la ciudad de Ibarra, a los 29 días del mes de enero del 2024

Atentamente



Ing. Carlos Mafla, MSc.

**DIRECTOR DEL TRABAJO DE GRADO**



# UNIVERSIDAD TÉCNICA DEL NORTE

## BIBLIOTECA UNIVERSITARIA

### AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

#### 1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
<b>CÉDULA DE IDENTIDAD:</b>	100439663-4		
<b>APELLIDOS Y NOMBRES:</b>	Medina Yánez Josue Ismael		
<b>DIRECCIÓN:</b>	Antonio Cordero 3-45 Toro Moreno		
<b>EMAIL:</b>	jimedinay@utn.edu.ec		
<b>TELÉFONO FIJO:</b>	062-958-758	<b>TELÉFONO MÓVIL:</b>	0993102350

DATOS DE CONTACTO	
<b>CÉDULA DE IDENTIDAD:</b>	100502460-7
<b>APELLIDOS Y NOMBRES:</b>	López Guamialamag Jorge Elías
<b>DIRECCIÓN:</b>	Ibarra, Riobamba 8-31 y Zamora
<b>EMAIL:</b>	jelopezg@utn.edu.ec
<b>TELÉFONO MÓVIL:</b>	0969097963

DATOS DE LA OBRA	
<b>TÍTULO:</b>	<b>Propuesta técnica de un sistema para el diagnóstico predictivo de un motor diésel en base a gases de escape.</b>
<b>AUTORES:</b>	Medina Yánez Josue Ismael López Guamialamag Jorge Elías
<b>FECHA:</b>	29 - 01 - 2014
<b>PROGRAMA:</b>	<input checked="" type="checkbox"/> <b>PREGRADO</b> <input type="checkbox"/> <b>POSGRADO</b>
<b>TITULO POR EL QUE OPTA:</b>	INGENIERO AUTOMOTRIZ
<b>DIRECTOR:</b>	Ing. Carlos Nolasco Mafla Yépez, MSc.

## 2. CONSTANCIAS

El autor (es) manifiesta (n) que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es (son) el (los) titular (es) de los derechos patrimoniales, por lo que asume (n) la responsabilidad sobre el contenido de la misma y saldrá (n) en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 29 días del mes de enero del 2024

### AUTORES:



.....  
Medina Yáñez Josue Ismael  
100439663-4



.....  
López Guamialamag Jorge Elías  
100502460-7

## DEDICATORIA

Con el corazón lleno de gratitud y amor, dedico este significativo logro a Dios, quien ha sido mi luz y guía en cada paso de este viaje. Es Él quien me brindó la fuerza y la sabiduría para superar cada desafío.

Mis amados padres, Irma Yáñez y Rene Medina, son el pilar de mi vida, su amor y sacrificio son la razón de mi perseverancia. Sin su apoyo y fe inquebrantable en mí, nada de esto sería posible.

Igualmente, a mis queridos hermanos, Gabriela, Gloria y Darwin, gracias por ser mi soporte constante, mi red de seguridad y fuente de risas inagotables. Su presencia en mi vida es un regalo que atesoro cada día. Mis preciosas sobrinas, April y Sofia, ustedes embellecen nuestros días con alegría y maravilla. Son la personificación de la esperanza y la felicidad, y una inspiración constante para seguir adelante.

Y a mi gran amigo Jorge López, compañero de innumerables aventuras y confidente, gracias por estar siempre allí, en los momentos de alegría y en los desafíos. Tu amistad es un tesoro que valoro profundamente.

Cada uno de ustedes ha contribuido una parte esencial en la historia de mi vida, llenándola de color, amor y significado. Este logro no es solo mío, sino un reflejo de todo el amor, apoyo y sabiduría que cada uno de ustedes ha aportado en mí. Gracias por ser parte de mi viaje, por caminar conmigo y por ser mi mayor bendición.

**Josue Ismael Medina Yáñez.**

## **AGRADECIMIENTO**

"En este momento de logros y reflexión, mi corazón rebosa de gratitud. Agradezco inmensamente a Dios, mi fuente de fortaleza y guía, cuya presencia constante infundió fe y determinación para superar los desafíos.

Mi reconocimiento se extiende a la Universidad Técnica del Norte, que más que un centro de aprendizaje ha sido un espacio de crecimiento y éxito. Cada rincón de esta institución me brindó la oportunidad de enriquecer mi conocimiento y mis ambiciones.

Agradezco al Ing. Mafla Yépez Carlos Nolasco MSc, cuya guía y sabiduría han sido esenciales en mi formación. Su dedicación y compromiso con la excelencia son fuentes de inspiración.

A mis padres, pilar de mi existencia, les debo mi ser. Su amor sin condiciones, apoyo incesante y sabiduría han iluminado cada paso que he dado, siendo mi roca y mayor motivación para lograr mis objetivos.

Cada enseñanza, cada palabra de aliento y cada gesto de soporte de ustedes ha sido crucial en mi recorrido. Este triunfo también es suyo, y mi gratitud hacia ustedes es infinita."

**Con cariño,**  
***Josue Ismael Medina Yáñez.***

## DEDICATORIA

"Con el corazón rebosante de gratitud, alegría y una dulce nostalgia, dedico este significativo logro y victoria a mi padre celestial, Dios, quien me ha dotado de energía, fortaleza, sabiduría, salud y fe inquebrantable en cada etapa de mi vida. Su presencia constante ha sido mi guía a través de los desafíos y caminos de la vida, siendo una inagotable fuente de amor y respeto eterno.

A mis amados padres, Mercedes Guamialamag y Jorge Ulpiano López, cuyo amor incondicional, paciencia infinita, sabiduría profunda y esfuerzo incansable, han sido el pilar de mi formación académica. En cada adversidad, supieron brindarme todo lo necesario, enseñándome con humildad y sencillez el verdadero valor de la vida y el significado del trabajo duro. Este logro es suyo, amados padres, reflejo de su dedicación y amor. Gracias por siempre creer en mí.

A mis hermanos, Roberto, Ruth, Yajaira, y Adriana cuya compañía, consejos sabios y amor fraternal, han llenado mi vida de inmensa felicidad. Me siento inmensamente afortunado de contar con su apoyo y presencia. Este logro también es de ustedes, mi amada familia.

Finalmente, a mi gran amigo, Josué Medina, con quien, desde el primer día en nuestra vida académica, compartimos sueños y desafíos. Hoy, al culminar esta etapa juntos, quiero expresar mi más profundo agradecimiento. Gracias, querido amigo, por tus consejos, tu apoyo incondicional y la más sincera amistad que valoro y atesoro en mi corazón."

*Jorge Elías López Guamialamag*

## AGRADECIMIENTO

"Extiendo mi más eterna gratitud a Dios, quien me ha bendecido con la vida y me ha otorgado la sabiduría necesaria para alcanzar cada una de mis metas y sueños. Su guía divina ha sido mi faro en el camino hacia el éxito y la realización personal.

A mi hogar académico, la Universidad Técnica del Norte. Este venerable recinto no solo me ha brindado las herramientas esenciales para mi desarrollo personal y profesional, sino que también se ha convertido en mi segundo hogar. Llevo conmigo los más gratos recuerdos de mi vida universitaria, atesorando cada momento vivido en sus aulas, pasillos y espacios, donde he forjado recuerdos inolvidables y aprendizajes vitales.

Mi sincero agradecimiento al Ing. Carlos Mafla MSc, cuya influencia ha sido fundamental en mi desarrollo académico y en la culminación exitosa de mi trabajo de titulación. Su profundo conocimiento y sabiduría han sido esenciales, guiándome paso a paso en este proyecto que hoy ve sus frutos.

A mis queridos padres y familia, ustedes son la columna vertebral de mi vida, la fuente de mi fuerza y mi inspiración más grande. Su amor incondicional y apoyo constante han sido cruciales para continuar cosechando logros y éxitos.

Finalmente, a mis invaluable amigos Josue, Javier, Alejandro, Anthony, Santiago, Luis, y Mateo, compañeros de innumerables alegrías y experiencias. Su presencia en mi vida universitaria ha hecho cada momento más significativo. Agradezco profundamente sus consejos, su apoyo y las memorias compartidas que siempre llevaré conmigo."

**Con amor,**  
***Jorge Elías López Guamialamag.***



# ÍNDICE DE CONTENIDOS

INTRODUCCIÓN .....	1
CAPÍTULO I .....	3
1. REVISIÓN BIBLIOGRÁFICA.....	3
1.1. ANTECEDENTES.....	3
1.2. PLANTEAMIENTO DEL PROBLEMA.....	4
1.3. OBJETIVOS .....	5
1.3.1. OBJETIVO GENERAL.....	5
1.3.2. OBJETIVOS ESPECÍFICOS.....	6
1.4. JUSTIFICACIÓN .....	6
1.5. ALCANCE.....	7
MARCO TEÓRICO.....	8
1.6. MOTORES DIÉSEL .....	8
1.6.1. Concepto.....	8
1.6.2. Funcionamiento.....	9
1.6.3. Fallas de los motores diésel .....	9
1.7. AVANCES TECNOLÓGICOS EN MOTORES DIÉSEL.....	11
1.8. EMISIONES DE UN VEHÍCULO DIÉSEL.....	12
1.9. TIPOS DE GASES DE ESCAPE .....	14
1.9.1. Dióxido de carbono (CO <sub>2</sub> ).....	15
1.9.2. Oxígeno (O <sub>2</sub> ).....	15
1.9.3. Compuestos orgánicos volátiles (COV) .....	16
1.9.4. Hidrocarburos (HC).....	17
1.9.5. Monóxido de carbono (CO).....	18
1.9.6. Óxidos de nitrógenos (NOX).....	19
1.9.7. Material particulado (PM).....	20

1.9.8. Emisiones de azufre (SOX) y plomo (PB).....	22
1.10. NORMATIVAS EN BASE A GASES DE ESCAPE.....	23
1.10.1. Normativas internacionales .....	23
1.10.2. Normativa ecuatoriana en base a gases contaminantes .....	26
1.10.3. Normativa chilena en base a gases contaminantes.....	27
1.10.4. Normativa mexicana en base a gases contaminantes .....	29
1.11. DIAGNÓSTICO PREDICTIVO .....	30
1.11.1. Análisis en base al aceite del motor.....	31
1.11.2. Análisis en base a vibraciones .....	32
1.11.3. Análisis en base a la acústica.....	32
1.12. APRENDIZAJE AUTÓNOMO .....	33
1.12.1. Clasificación del aprendizaje autónomo.....	34
1.12.2. Algoritmos del ““machine learning”” .....	34
1.13. REVISIÓN DE LAS MEDIDAS ESTADÍSTICAS .....	36
1.13.1. Medidas de tendencia central.....	37
1.13.2. Medidas de dispersión.....	38
1.13.3. Medidas de forma.....	39
CAPÍTULO II .....	41
2. MÉTODO Y MATERIALES .....	41
2.1. METODOLOGÍA GENERAL DEL ESTUDIO .....	41
2.2. DETERMINACIÓN DE LOS GASES EN EL ESTUDIO.....	42
2.2.1. Matriz de decisión de gases de escape para diagnóstico predictivo.....	42
2.3. SELECCIÓN DEL VEHÍCULO Y MATERIALES .....	46
2.3.1. Motor – Mazda BT-50 .....	46
2.3.2. Analizador de gases.....	47
2.3.3. Bosch FSA 740 .....	47
2.3.4. Dispositivo simulador de fallas .....	48

2.3.5. Software KANE LIVE .....	49
2.3.6. Software MATLAB®.....	49
2.4. DETERMINACIÓN DE LOS ESTADOS DE FALLA SIMULAR EN EL MOTOR.....	50
2.4.1. Estados de falla .....	50
2.4.2. Resultados de la selección de los estados de falla .....	53
2.5. PROCEDIMIENTO DE RECOPIACIÓN DE DATOS.....	54
2.5.1. Proceso de toma de datos.....	54
2.5.2. Pasos para la recopilación y toma de datos .....	54
2.5.3. Proceso de simulación de fallas y condiciones del motor.....	56
2.6. DETERMINACIÓN DE LAS MEDIDAS ESTADÍSTICAS DEL ESTUDIO.....	60
2.6.1. Medidas estadísticas seleccionadas .....	60
2.6.2. Prueba piloto para la determinación de las variables estadísticas .....	61
2.7. OBTENCIÓN Y TRATAMIENTO DE LA BASE DE DATOS .....	62
2.7.1. Elaboración de la base de datos inicial .....	62
2.7.2. Obtención de la base de datos simplificada.....	64
2.8. APLICACIÓN DE “MACHINE LEARNING” POR CLASIFICACIÓN .....	65
2.8.1. Esquema de validación.....	66
2.8.2. Selección del árbol de decisión.....	67
2.8.3. Obtención de la ecuación de predicción .....	68
2.9. MODIFICACIÓN DE LA FUNCIÓN DE CLASIFICACIÓN PARA EL SISTEMA .....	70
CAPÍTULO III.....	71
3. ANÁLISIS Y RESULTADOS .....	71
3.1. PRUEBA PILOTO PARA LA SELECCIÓN DE LAS VARIABLES ESTADÍSTICAS .....	71
3.2 BASE DE DATOS PROCESADA.....	72
3.2.1 Oxígeno (O <sub>2</sub> ).....	73
3.2.2 Óxidos de nitrógeno (NOX).....	73
3.2.3 Monóxido de carbono (CO).....	74

3.2.4	<i>Dióxido de carbono (CO<sub>2</sub>)</i> .....	75
3.3	ENTRENAMIENTO DE CADA GAS POR ALGORITMO DE CLASIFICACIÓN .....	75
3.3.1	<i>Entrenamiento basado en emisiones de O<sub>2</sub></i> .....	75
3.3.2	<i>Entrenamiento basado en emisiones de NOX</i> .....	76
3.3.3	<i>Entrenamiento basado en emisiones de CO<sub>2</sub></i> .....	80
3.3.4	<i>Entrenamiento de un modelo integral de emisiones</i> .....	82
3.3.5	<i>Determinación de la variable estadística clave para el entrenamiento integral</i> .....	82
3.4	SELECCIÓN DE LOS MODELOS PARA EL SISTEMA DE MACHINE LEARNING .....	85
3.4.1	<i>Función de predicción del modelo basado en emisiones de NOX</i> .....	86
3.4.2	<i>Función de predicción del modelo integral de emisiones</i> .....	87
3.5	VALIDACIÓN DEL SISTEMA DE DIAGNÓSTICO PREDICTIVO .....	89
3.5.1	<i>Modelo basado en emisiones de NOX</i> .....	89
3.5.2	<i>Modelo integral de emisiones</i> .....	90
CAPÍTULO IV .....		92
4.	CONCLUSIONES Y RECOMENDACIONES .....	92
4.1.	CONCLUSIONES .....	92
4.2.	RECOMENDACIONES .....	94
5.	REFERENCIAS BIBLIOGRÁFICAS.....	95
6.	ANEXOS .....	107

## ÍNDICE DE TABLAS

Tabla 1.1 Estándares de emisión para vehículos diésel desde el 2014 hasta el 2019 .....	23
Tabla 1.2 Normativas sobre emisiones de vehículos en países de América .....	25
Tabla 1.3 Límites máximos de emisiones de fuentes móviles diésel prueba estática.....	26
Tabla 1.4 Límites de emisiones diésel en pruebas dinámicas europeas. ....	27
Tabla 1.5 Límites de emisiones para vehículos livianos a compresión. ....	27
Tabla 1.6 Limite permisibles en pruebas estática en base a la opacidad .....	28
Tabla 1.7 Límites máximos de gases contaminantes de vehículos diésel en México.....	29
Tabla 1.8 Límites de opacidad para vehículos diésel de 400 a 3857 kg.....	30
Tabla 2.1 Matriz cualitativa para datos de gases de escape estudiados en capítulo I.....	42
Tabla 2.2 Cuantificación de datos cualitativos en la matriz de decisión de gases de escape. .	45
Tabla 2.3 Ficha técnica de Mazda BT-50 .....	46
Tabla 2.4 Características técnicas del analizador de gases KANE AUTOplus 5-2.....	47
Tabla 2.5 Datos técnicos del FSA 740.....	47
Tabla 2.6 Fallas mecánicas y eléctricas en los inyectores .....	50
Tabla 2.7 Fallas mecánicas y eléctricas en el sensor de flujo de aire .....	51
Tabla 2.8 Fallas mecánicas y eléctricas en la válvula ZME para la investigación.. ..	53
Tabla 2.9 Resumen de las condiciones de falla seleccionadas. ....	53
Tabla 2.10 Nomenclatura de los estados del motor.. ..	55
Tabla 2.11 Definición de la codificación de los estados del motor.. ..	55
Tabla 2.12 Medidas estadísticas y sus comandos en MATLAB®. ....	61
Tabla 3.1 Eficiencia del entrenamiento de cada variable estadística.....	71
Tabla 3.2 Eficiencia del entrenamiento de cada variable estadística.....	86
Tabla 3.3 Eficiencia del entrenamiento en todos los modelos de predicción .....	88
Tabla 3.4 Eficiencia del entrenamiento en el modelo de predicción basado en NOx. ....	92
Tabla 3.5 Eficiencia de entrenamiento del modelo integral de emisiones.....	93

## ÍNDICE DE FIGURAS

Figura 1.1 Combustión Estequiométrica del Combustible .....	13
Figura 1.2 Composición aproximada de los gases de escape de un vehículo diésel .....	14
Figura 1.3 Composición del material particulado de un vehículo diésel.....	21
Figura 2.1 Flujograma de la metodología del estudio.....	40
Figura 2.2 Dispositivo variador de voltaje para el sensor MAF .....	49
Figura 2.3 Esquema eléctrico del dispositivo simulador de fallas.....	57
Figura 2.4 Dispositivo conectado al socket del sensor MAF.....	57
Figura 2.5 Diagrama de la simulación de la válvula "ZME" .....	57
Figura 2.6 Derecha ZME mal estado, izquierda ZME nueva .....	58
Figura 2.7 Diagrama simulación de inyectores.....	58
Figura 2.8 Estructura inicial de la base de datos de emisiones.....	61
Figura 2.9 Distribución de la base de datos inicial. ....	63
Figura 2.10 Sección de MATLAB® para importar archivos y datos.....	64
Figura 2.11 Opciones de importación en MATLAB®. ....	65
Figura 2.12 Código en MATLAB® para simplificar datos de una muestra.....	65
Figura 2.13 Preparación de los datos para el aprendizaje autónomo supervisado.....	66
Figura 2.14 Selección del esquema de validación del modelo. ....	67
Figura 2.15 Tipos de árbol de decisión que el programa ofrece.....	66
Figura 2.16 Opciones de exportación en la aplicación "Classification Learner". ....	67
Figura 2.17. Ecuación generada por la exportación del modelo.....	68
Figura 2.18 Resultado del uso de la ecuación con nuevos datos. ....	69
Figura 3.1 Resultados del entrenamiento de la prueba piloto basado en emisiones de NOx. .	73
Figura 3.2 Selección del árbol de decisión para la prueba O2.....	77
Figura 3.3 Resultados del entrenamiento basado en emisiones de O <sub>2</sub> .....	78
Figura 3.4 Selección del árbol de decisión para la prueba NOx.....	79
Figura 3.5 Resultados del entrenamiento basado en emisiones de NOx. ....	80
Figura 3.6 Selección del árbol de decisión para la prueba de CO .....	81
Figura 3.7 Resultados del entrenamiento basado en emisiones de CO.....	82
Figura 3.8 Selección del árbol de decisión para la prueba con CO <sub>2</sub> . ....	83
Figura 3.9 Resultados del entrenamiento basado en emisiones de CO <sub>2</sub> . ....	84
Figura 3.10 Resultados del entrenamiento integral.....	87

Figura 3.11 Respuesta del software al exportar el modelo de NOx.....	89
Figura 3.12 Código para obtener la tabla de datos “T” para el modelo basado en NOx .....	90
Figura 3.13 Respuesta del software al exportar el modelo integral.....	90
Figura 3.14 Código para obtener la tabla de datos “T” para el modelo integral.....	91

## ÍNDICE DE ECUACIONES

Ecuación (1) Media aritmética .....	36
Ecuación_(2) Mediana .....	36
Ecuación_(3) Moda .....	37
Ecuación_(4) Rango .....	37
Ecuación_(5) Varianza .....	38
Ecuación_(6) Desviación estándar .....	38
Ecuación_(7) Coeficiente de variación .....	38
Ecuación_(8) Asimetría .....	39
Ecuación_(9) Curtosis .....	39
Ecuación_(10) Modelo NOx .....	89
Ecuación_(11) Modelo integral .....	90



## ÍNDICE DE ANEXOS

Anexo 1. Flujograma de la metodología general del estudio.....	107
Anexo 2. Flujograma de la recopilación de datos y análisis de datos.....	108
Anexo 3. Formato de las tablas del aprendizaje autónomo por clasificación. ....	110
Anexo 4. Comprobaciones de fluidos del motor.....	111
Anexo 5. Elementos del analizador de gases .....	111
Anexo 6. Conexión del analizador al tubo de escape.....	111
Anexo 7. Interfaz software KANE AUTOPLUS.....	112
Anexo 8. Recolección de datos mediante el software KANE LIVE.....	112
Anexo 9. Información eléctrica del sensor MAF.....	112
Anexo 10. Datos estadísticos de los gases para el machine learning.....	113
Anexo 11. Código del sistema basado en emisiones de NOx.....	119
Anexo 12. Código del sistema integral de emisiones. ....	122

## RESUMEN

Este estudio se centra en el uso del aprendizaje autónomo para el mantenimiento predictivo de vehículos diésel, desarrollando un sistema de diagnóstico predictivo basado en la detección de fallas mediante el análisis de emisiones de gases. La metodología incluye un análisis detallado de los gases de escape de un vehículo diésel, de los componentes que intervienen en la formación de los gases, en las pruebas experimentales realizadas para obtener los datos necesarios para el estudio y el procesamiento de datos por medio del aprendizaje autónomo en el software MATLAB. Los resultados enfatizan la relevancia de gases específicos (NO<sub>x</sub>, CO, CO<sub>2</sub>, O<sub>2</sub>) en el diagnóstico de fallos y en la eficiencia de la combustión, también se destaca la influencia directa de componentes como inyectores, válvula dosificadora y sensor MAF en las emisiones. El estudio revela variaciones en el porcentaje de precisión utilizando diferentes modelos de aprendizaje autónomo, resaltando la importancia de extensas bases de datos para la validación en contextos reales y el uso de las variables estadísticas. Se destaca la eficiencia y precisión de ciertos modelos, identificando áreas de mejora en la detección de fallos específicos.

**PALABRAS CLAVE:** Vehículos diésel, mantenimiento predictivo, diagnóstico predictivo, “machine learning”, análisis de emisiones, aprendizaje autónomo.

## ABSTRACT

This study focuses on using autonomous learning for predictive maintenance of diesel vehicles, developing a predictive diagnostic system based on fault detection through gas emission analysis. The methodology includes detailed analysis of diesel vehicle exhaust gases, components involved in gas formation, experimental tests to obtain necessary data, and data processing using autonomous learning in MATLAB software. The results highlight the importance of specific gases (NO<sub>x</sub>, CO, CO<sub>2</sub>, O<sub>2</sub>) in fault diagnosis and combustion efficiency, also noting the direct influence of components such as injectors, dosing valve, and MAF sensor on emissions. The study reveals variations in accuracy using different autonomous learning models, emphasizing the importance of extensive databases for real-world validation and the use of statistical variables. The high efficiency and precision of certain models are highlighted, identifying areas for improvement in the detection of specific faults.

**KEYWORDS:** Diesel vehicles, predictive maintenance, predictive diagnosis, “machine learning”, emission analysis, autonomous learning.

# INTRODUCCIÓN

El diagnóstico predictivo es crucial en el mantenimiento de maquinaria, especialmente en la industria automotriz. Este enfoque permite detectar fallos antes de que ocurran. El diagnóstico predictivo también promueve el mantenimiento preventivo en lugar del correctivo. Esto reduce significativamente los costos y el tiempo de inactividad no programado. El diagnóstico predictivo previene la pérdida innecesaria de tiempo y recursos, alentando un mantenimiento oportuno y adecuado.

El diagnóstico predictivo, en la actualidad, se centra en el análisis de gases de escape con aprendizaje autónomo. Esta técnica identifica problemas en componentes críticos del motor. El diagnóstico predictivo mejora la eficiencia del motor y reduce las emisiones contaminantes. Esto es fundamental en un contexto de preocupación medioambiental.

El primer capítulo del proyecto aborda la revisión bibliográfica sobre el motor diésel. Este capítulo analiza las emisiones y las normativas internacionales de gases de escape. Además, profundiza en las emisiones del tubo de escape y su relación con la combustión. El capítulo también explora el diagnóstico predictivo mediante aprendizaje autónomo.

El segundo capítulo describe el proceso del sistema de diagnóstico predictivo para un motor Mazda BT 50 propiedad de la Universidad Técnica del Norte. Este proceso se centra en la metodología de diagnóstico. El capítulo también detalla la simulación de fallas en el motor y la creación de bases de datos. El aprendizaje autónomo se utiliza en este proceso.

El tercer capítulo se enfoca en la creación y procesamiento de la base de datos del estudio. Este capítulo utiliza MATLAB® para analizar gases de escape de motores diésel. Presenta cinco modelos de aprendizaje autónomo para diferentes gases. El capítulo ayuda a identificar las características de los gases en relación con los estados del motor.

El cuarto capítulo destaca los hallazgos principales del estudio. Se centra en el proceso experimental y la gestión eficaz de los datos. El capítulo enfatiza la eficacia de los modelos de aprendizaje autónomo. También aborda las limitaciones y desafíos de la investigación. Concluye con recomendaciones para futuras investigaciones, subrayando la importancia y el potencial de expansión en este campo.

# CAPÍTULO I

## 1. REVISIÓN BIBLIOGRÁFICA

### 1.1. ANTECEDENTES

Uno de los medios de transporte más utilizados hoy en día son los automóviles, aparatos que en su mayoría trabajan mediante combustión interna. Un vehículo por sí solo no podría generar mucha contaminación, pero como se trata de cadenas de vehículos que circulan en cada momento, las emisiones que se generan en conjunto son mucho más grandes, es así como se considera a la industria automotriz responsable del 9 % de las emisiones globales de gases de efecto invernadero (Greenpeace, 2019).

Los vehículos MEC generan dos tipos de emisiones contaminantes: las emisiones evaporativas y las emitidas por el tubo de escape (Riveros, Cabrera, & Enrique, 2021). Las emisiones evaporativas se refieren a los vapores del combustible, aspecto que es independiente de los procesos de combustión, por otro lado, tenemos a las emisiones que son expulsadas por el tubo de escape, estas son provocadas por la reacción química que ocurre en el proceso de combustión (Gómez, Franco, Allen, Tejeda, & Aguilar, 2009).

Las emisiones generadas por la combustión son las más contaminantes para el entorno, este tipo de emisión afecta al cambio climático y a la salud de las personas, según Farrow, Miller, Rolle, Céspedes, y Anhaeuser (2021) la contaminación vehicular se encuentra ligada a enfermedades tales como: el cáncer al pulmón, el asma, la EPOC, infecciones de vías respiratorias, asimismo se asocia a la diabetes tipo II, al accidente cerebrovascular, la cardiopatía isquémica, entre otras.

Se puede denotar que las emisiones contaminantes que produce el vehículo diésel están ligadas a la calidad del combustible (cantidad de azufre), la combustión del motor y el

desarrollo tecnológico que los vehículos posean (U.S. Environmental Protection Agency, 2020), en este sentido, según Bitta (2022) un mantenimiento regular recomendado por los fabricantes permite mejorar el sistema de emisiones del motor, además también explica que en muchos casos los mecánicos informales pueden afectar la calidad de reparación, así como el funcionamiento de los catalizadores y por ende afectan a las emisiones del vehículo.

En la mayoría de los casos las personas realizan un mantenimiento correctivo, es decir, es la respuesta debido a la falla en el equipo (Deighton, 2016), se considera que este tipo de mantenimiento es poco confiable y puede provocar excesivos gastos e incertidumbre al momento de reparar los daños, por otro lado, se explica que un mantenimiento periódico puede ser la solución a los problemas de averías grandes en vehículos ya que se reducen el riesgo de fallo antes de que desencadene en una vería mayor (Mital, Subramanian, & Mital, 2014), no obstante, a pesar de que reduce el riesgo de que el carro falle en funcionamiento genera costos grandes y la vida útil de los componentes del vehículo no está asegurada y la falla tiene probabilidad de no repararse con exactitud ya que los intervalos de reparación pueden no ser los correctos(Apolon, 2021).

En relación con esto, según el estudio realizado por Simões, Torres y Fonseca (2020) un diagnóstico basado en algoritmos que pueda predecir fallos puede mejorar el desempeño de los motores diésel, maximizar el tiempo para cada mantenimiento y aumentar los niveles de confiabilidad, este análisis puede ser realizado en base a diferentes variables del motor tales como la temperatura, humedad, gases de escape, ruido, etcétera.

## **1.2. PLANTEAMIENTO DEL PROBLEMA**

La contaminación ambiental es un problema latente en la actualidad, debido a que provoca efectos negativos como el calentamiento global y el cambio climático, esta contaminación es el resultado de la actividad humana. En este sentido, según Greenpeace

(2019) la industria automotriz es responsable del 9 % de las emisiones globales de gases de efecto invernadero, en este punto destacan las industrias productoras y las cadenas de vehículos que circulan en cada momento, la combustión interna de los vehículos genera gases y residuos contaminantes para su funcionamiento, dicha contaminación vehicular se vincula a enfermedades como el cáncer de pulmón, el asma, la EPOC, infecciones de vías respiratorias, asimismo se asocia a la diabetes tipo II, al accidente cerebrovascular, la cardiopatía isquémica, entre otras (Farrow, Miller, Rolle, Céspedes, & Anhaeuser, 2021).

Por otro lado, algunos factores como el combustible y el estado de los motores influyen directamente en la emisión de gases, en el caso de Ecuador contamos con deficientes combustibles tanto en gasolina y diésel, que a nivel internacional apenas alcanzamos a la normativa Euro 3 que a estándares internacionales es de una calidad regular, ya que poseen bajo octanaje y en el caso del diésel un alto contenido del nivel de azufre que provocan una mala combustión dentro de los motores y generando así una mayor cantidad de gases contaminantes, otro punto es la cultura general que posee nuestra sociedad actual ecuatoriana, misma que despreocupa el mantenimiento de los vehículos, realizando siempre un mantenimiento correctivo, aspecto que provoca mayores gastos y que el vehículo no esté en funcionamiento los 365 días del año, además si se usa motores que se encuentran en mal estado se provoca mayores emisiones contaminantes y mayor consumo de combustible.

### **1.3. OBJETIVOS**

#### ***1.3.1. OBJETIVO GENERAL***

Desarrollar una propuesta técnica de un sistema de diagnóstico predictivo de averías de un vehículo diésel electrónico en base a datos de gases de escape a través de aprendizaje autónomo.



### **1.3.2. OBJETIVOS ESPECÍFICOS**

- Caracterización de los parámetros de gases a utilizar en el estudio mediante un análisis bibliográfico acerca de las emisiones de escape de los motores diésel.
- Determinar los elementos que intervienen en la generación de averías en el vehículo y que tienen relación con la emisión de gases de escape en el motor diésel.
- Obtener datos referenciales de los gases de escape de un motor diésel en buen estado para el análisis comparativo del sistema a desarrollar a través del analizador de gases.
- Establecer las variables estadísticas a utilizar en el estudio a través de una prueba piloto que tenga una base de datos mínima para verificar que variables son necesarias en el estudio.
- Crear una base de datos de los gases de escape del motor diésel en diferentes estados y condiciones de falla del motor a través de pruebas experimentales con el analizador de gases y un dispositivo que permita simular averías.
- Procesar los datos adquiridos en el programa de cómputo mediante la generación de aprendizaje autónomo que sirva para el diagnóstico predictivo del motor diésel.
- Realizar un análisis de validación del sistema de diagnóstico predictivo a través de pruebas en el motor empleado para determinar la eficiencia de su análisis.

### **1.4. JUSTIFICACIÓN**

Es un hecho que hoy en día los vehículos son el medio de transporte más importante en el mundo, no obstante, estos automotores emplean en su mayoría combustibles a base de petróleo, generando así gases contaminantes para lograr su funcionamiento y provocando que el medio ambiente se vea afectado, en este sentido, las industrias automotrices han mejorado en gran medida su tecnología reduciendo las emisiones de gases contaminantes que se generan

en el proceso de combustión, sin embargo, si estos componentes no se encuentran en óptimas condiciones las emisiones generadas continuarán perjudicando al planeta.

Con todo lo mencionado anteriormente, se destaca la importancia de realizar este proyecto ya que ayuda directamente a la reducción de gases contaminantes mediante el mantenimiento preventivo de los componentes que influyen en el proceso de combustión en los motores diésel, cabe recalcar que el cuidado de los diferentes sistemas encargados de dosificar el combustible y el aire en la cámara de combustión garantiza el éxito en la reducción de los gases contaminantes, aspecto clave que afecta directamente al cuidado del medio ambiente, en este sentido el estudio se alinea con el objetivo 12 del Plan de Creación de Oportunidades 2021 – 2025 establecido en Ecuador, donde se destaca la importancia de desarrollar modelos que sean sostenibles y se adapten a la situación actual del Ecuador y del mundo, buscando reducir así el cambio climático y la contaminación.

Es así que el tema planteado se alinea directamente con la política 12.3 del objetivo antes mencionado, donde se habla acerca de la importancia de implementar métodos ambientales, que a través de la innovación tecnológica concientice a la población y genere prácticas sostenibles, es decir, se quiere impulsar modelos que tengan como finalidad la eficiencia en los recursos y que perduren con el tiempo sin afectar al medio ambiente, siguiendo esta línea, la investigación planteada busca que los motores diésel tengan la durabilidad que les corresponde y trabajen de manera correcta la mayor parte de su vida útil a través de un diagnóstico predictivo.

## **1.5. ALCANCE**

El presente proyecto establecerá un sistema predictivo de diagnóstico en motores diésel, mismo que sirva para poder predecir futuras fallas y prevenir daños considerables en los automotores, evitando así el mantenimiento correctivo, en el estudio únicamente trabajará con

datos de gases de escape tales como: el oxígeno, esto es debido a que es un reactivo importante en la reacción química que se produce dentro de la cámara de combustión; también se usará el gas de CO<sub>2</sub> ya que es un producto que determinará si existe una buena combustión; y por último se usarán datos de NO<sub>x</sub> debido a que está relacionado con la presión y temperatura que existe durante la combustión.

Para la toma de datos el estudio se basará en motores diésel electrónicos de 4 cilindros con inyector de válvula solenoide, se usarán 2 motores para realizar las pruebas, uno para obtener datos y el otro para la validación de estos, a su vez, luego de haber establecido el sistema se lo utilizará para realizar pruebas en campos de aplicación para otros motores diésel con el fin de obtener así una verificación del estudio.

Por último, en el estudio se simularán fallas únicamente en el sistema de inyección, específicamente en componentes como el riel, los inyectores y las unidades dosificadoras (ZME y DRV), las cuales intervienen directamente en la combustión interna del motor.

## **MARCO TEÓRICO**

### **1.6. MOTORES DIÉSEL**

#### ***1.6.1. Concepto***

El motor diésel es una máquina térmica que convierte la energía contenida en la mezcla aire-combustible en energía mecánica usando grandes temperaturas y presiones. No obstante, el motor diésel se diferencia de otros motores de combustión interna debido a que no hace uso de la chispa para generar la combustión (Moreno, Pineda, & Santos, 2022).

### ***1.6.2. Funcionamiento***

De acuerdo con Morocho y Nagua (2019), el ciclo termodinámico de los motores diésel se compone de cuatro tiempos. Primero, se encuentra el proceso de admisión, en el cual el aire llena el cilindro gracias a la apertura de la válvula de admisión. Seguidamente, se da el tiempo de compresión; en este momento, la válvula de admisión se cierra y el pistón comienza a subir, comprimiendo el aire en el cilindro. Luego, sigue el tiempo de combustión. Aquí, el pistón alcanza el punto muerto superior (PMS) y se inyecta combustible pulverizado en la cámara de combustión. Esto provoca la combustión debido al calor presente en la cámara.

Finalmente, ocurre el proceso de escape, donde el pistón desciende impulsado por la energía generada en la inflamación del combustible, y se liberan los gases resultantes de la combustión.

### ***1.6.3. Fallas de los motores diésel***

En esta investigación sobre motores diésel, se hace un énfasis particular en el análisis de fallas en componentes clave como los inyectores, el sensor MAF y el ZME. Estos componentes son cruciales para el funcionamiento óptimo y la eficiencia del motor, ya que influyen directamente en la entrega y medición del combustible, así como en la regulación del flujo de aire. Reconociendo la importancia de estos elementos, el estudio se centra en identificar, analizar y comprender las fallas comunes que pueden afectarlos, subrayando su papel esencial en la salud y el rendimiento general de los motores diésel.

#### **A. Fallas en los inyectores**

Los inyectores de un motor diésel, conectados al riel común, son esenciales para inyectar el combustible necesario para la combustión. Según Bosch (2022), fallas en los inyectores pueden causar problemas de arranque, bajo rendimiento, ralentí irregular, humo

negro y misfire, debido a fugas, obstrucciones, fallos eléctricos o mecánicos y errores en las señales de la ECU. Además, problemas como obstrucciones en filtros de combustible o fallas en la bomba de alta presión pueden afectar la entrega de combustible a los inyectores (Gaskell, 2023). Lowe, Wu y Tan (2011) indican que es posible simular fallas en inyectores mediante métodos como la interrupción de la inyección, uso de inyectores defectuosos, obstrucción de orificios o modificación de la presión de descarga, lo cual es relevante para esta investigación.

### **B. Fallas en el sensor de masa de aire “MAF”**

El sensor de masa de aire es clave para controlar la combustión en motores, determinando el flujo masico de aire. Parker (2017) señala que fallas comunes en este sensor provocan rendimiento lento del motor, problemas de encendido, mezcla deficiente de combustión, humo negro en el escape y aceleración deficiente. Además, un mal funcionamiento del sensor puede causar inestabilidad en el ralentí, ruidos en el motor y paradas inesperadas, a menudo debido a la acumulación de material contaminante que provoca lecturas incorrectas y señales inválidas. Estos problemas pueden ser causados por un sensor MAF sucio o dañado, así como por conexiones eléctricas deficientes o problemas en el sistema de admisión de aire del vehículo.

### **C. Fallas en la válvula reguladora de caudal (ZME)**

En los motores diésel equipados con sistemas CRDI, la regulación precisa de la presión y el caudal del combustible es fundamental para una combustión a presión constante y eficiente. La válvula reguladora de caudal (ZME) desempeña un papel crucial en este proceso, al suministrar combustible a través del conducto común y mantener la presión requerida. Esto permite una inyección homogénea y ajustes en tiempo real, esenciales para el funcionamiento óptimo del motor (Coral F, 2013).

Las fallas comunes en la válvula ZME, como obstrucciones, atascamientos o fugas, pueden provocar problemas de arranque del motor, exceso de combustible que lleva al ahogamiento del motor, ralentí inestable y aceleraciones irregulares. Estos problemas, estrechamente vinculados con la presión y el caudal del combustible, afectan directamente la combustión y la composición de los gases de escape.

## **1.7. AVANCES TECNOLÓGICOS EN MOTORES DIÉSEL**

Para analizar los avances tecnológicos en sistemas diésel, el informe de Bosch (2022) es una referencia clave. Este informe aborda la evolución de componentes desde 2017 hasta 2021. En 2017, se produjo un avance significativo con el cambio del Sistema Common Rail (CRS) de CRS2 a CRS3. Este cambio incrementó la presión en el circuito de alta presión de 2200 a 2700 bares, mejorando notablemente el rendimiento.

Los nuevos sistemas CRS3 introdujeron inyectores piezoeléctricos. Estos inyectores reemplazaron a los de válvula solenoide y ofrecieron muchos beneficios. Por ejemplo, los inyectores piezoeléctricos mejoraron los tiempos de retraso, apertura y el caudal entregado (Koten, Can, & Guner, 2018). Adicionalmente, estos sistemas lograron una mezcla más eficiente y proporcionaron un mayor control en las múltiples inyecciones.

En 2018, Bosch evolucionó estos sistemas con la incorporación de la bomba de alta presión modelo CPN6 para vehículos comerciales. Esta bomba modular genera presiones de 1800 a 2500 bares, favoreciendo la combustión y los sistemas de inyección. La bomba CPN6 permite al motor alcanzar potencias de hasta 850 kW, ideal para trabajos pesados (Bosch, 2022).

Aunque no hay avances significativos en los inyectores, el sistema Common Rail sigue empleando inyectores piezoeléctricos controlados por la computadora del motor. En 2021, esta tecnología se extendió a vehículos comerciales, destacando por permitir una inyección múltiple

y controlada, lo que optimiza la combustión en cada cilindro. Esto se traduce en un aumento de rendimiento y eficiencia del motor (Bosch, 2022).

Por otro lado, un avance importante en los sistemas de inyección se observa en la aparición del dispositivo Denoxtronic. Desarrollados desde 2004 para vehículos diésel, estos dispositivos han evolucionado significativamente. En 2018, se lanzó el Denoxtronic 6-HD para vehículos comerciales, seguido por el Denoxtronic 5.3 para vehículos de pasajeros en 2019. Estos sistemas operan en sinergia con el catalizador SCR, reduciendo las emisiones de óxidos de nitrógeno.

El AdBlue, una solución acuosa, juega un papel crucial en este proceso. Mediante termólisis e hidrólisis, descompone los óxidos de nitrógeno en agua y nitrógeno. Según BESKO (2019), este proceso reduce las emisiones de óxidos de nitrógeno en hasta un 85%.


Los dispositivos Denoxtronic recientes ofrecen una variedad de dosificaciones. Utilizan diferentes módulos que varían las soluciones de AdBlue inyectadas según el tipo de refrigeración. Esto, como indican Raff, Weingarten, & Muslija (2019), es clave para facilitar la reacción química deseada.

## **1.8. EMISIONES DE UN VEHÍCULO DIÉSEL**

Los vehículos MEC generan dos tipos de emisiones contaminantes: las emisiones evaporativas y las emitidas por el tubo de escape (Riveros, Cabrera, & Enrique, 2021). Es importante mencionar que según la OECD (2020) existe otro tipo de contaminación que emiten todos los vehículos que se encuentran circulando actualmente, y se trata de las emisiones de polvo por transporte de carretera. Este tipo de emisiones son generadas debido al desgaste de elementos como los frenos y los neumáticos del automóvil, o también por el deterioro de la superficie de la carretera y la elevación del polvo.

Primero que todo las emisiones evaporativas se refieren a los vapores o gases que el vehículo emite cuando el combustible se evapora debido a su volatilidad y la influencia de la presión y temperatura dentro del tanque de combustible, dichas emisiones son independientes de los procesos de combustión (Frosina et al., 2018).

En la Figura 1.1. se puede observar, las emisiones que son expulsadas a través del tubo de escape del vehículo son generadas por el proceso de combustión. En dicho proceso el combustible (reactivo) reacciona con el aire (oxidante) a través de un proceso químico que ocurre dentro de la cámara de combustión, allí se libera calor y se forma productos de combustión (Reisel, 2021).



**Figura 1.1.** Combustión estequiométrica del combustible

Lo mostrado anteriormente se trata de una combustión estequiométrica o también llamada combustión completa. En este proceso, todos los reactivos reaccionan con la cantidad total de oxidante (Fernández, Pérez, & Renedo, 2022). Sin embargo, la consecución de una combustión completa puede verse afectada por diversas variables. Factores como la manera de la combustión, la relación aire-combustible, y la concentración de compuestos en la mezcla son cruciales. Además, la temperatura y presión dentro de la cámara de combustión, junto con la presencia de turbulencias y el punto de inflamación, influyen en este proceso (Aslan, Altinisik, & Keskin, 2015).




Durante el proceso de combustión, no siempre se logra la oxidación completa del combustible. Esto puede resultar en la generación de productos como los compuestos orgánicos volátiles (COV), monóxido de carbono (CO), óxidos de nitrógeno (NOx) y material particulado (PM). Además, en las emisiones del tubo de escape se pueden encontrar dióxido de azufre (SO<sub>2</sub>) y plomo (Pb), dependiendo del contenido de estos elementos en el combustible (DCCEEW, 2023).

A pesar de que los motores diésel emiten más PM y NOx que los motores de encendido por chispa, poseen ventajas significativas. Su alta eficiencia térmica y estabilidad han impulsado su uso en sectores como el transporte pesado y marítimo, centrales eléctricas y en un 42% de los vehículos de turismo en la Unión Europea (Hunicz et al., 2021). Estos motores, a pesar de sus emisiones, siguen siendo una opción predominante en varios sectores clave.

## 1.9. TIPOS DE GASES DE ESCAPE

Autores como Silveira, Molinar, Silveira, & Schlosser (2023) determinan en su escrito que los gases contaminantes principales de un vehículo diésel son los: HC, PM, NOx, SO<sub>2</sub> y CO. En la Figura 1.2 se puede observar las concentraciones porcentuales de cada gas en las emisiones del vehículo diésel.



**Figura 1.2.** Composición aproximada de los gases de escape de un vehículo diésel

Se observa que las emisiones no relacionadas con la combustión completa del motor son inferiores al 1%. Al analizar la composición de estos gases contaminantes, los NOx representan el 50% de este porcentaje, seguidos por las emisiones de PM (Aslan, Altinisik, & Keskin, 2015). Es importante destacar que la concentración de CO y HC es reducida. Esto se debe al funcionamiento de los motores diésel, que operan con una combustión pobre (Adams, 2021).

No obstante, Sharma y Maréchal (2019) señalan que, según la normativa europea de 2012, las emisiones de NOx deben ser de 0.4 g/kWh. Le siguen las de CO con 1.5 g/kWh, los HC con 0.13 g/kWh y, finalmente, las PM con 0.01 g/kWh. Estos datos resaltan la importancia de regulaciones específicas para controlar la contaminación vehicular.

### ***1.9.1. Dióxido de carbono (CO<sub>2</sub>)***

La concentración de CO<sub>2</sub> que emite el vehículo diésel está directamente relacionada con el consumo de combustible (Dobrzyńska et al., 2020). Es así como la formación de este compuesto se encuentra influenciado por los átomos de carbono que contiene el combustible (calidad del combustible). Por otro lado, cabe recalcar que en el proceso de combustión cuando se oxida el combustible primero se forma el CO, y si existe una cantidad de O<sub>2</sub> adecuada y una alta temperatura dentro del cilindro se puede oxidar el CO a CO<sub>2</sub> (Pham et al., 2022).

### ***1.9.2. Oxígeno (O<sub>2</sub>)***

Durante el proceso de combustión se busca conseguir que todo el combustible que es inyectado en la cámara de combustión se oxide con todo el O<sub>2</sub> presente en el aire. En los vehículos de inyección directa para obtener una buena calidad en la combustión influyen principalmente dos factores: la atomización y la inyección del combustible (Wei et al., 2014).

El O<sub>2</sub> en la combustión también influye en la formación de HC y CO en el tubo de escape. Estos gases se forman cuando existe una mala combustión porque se trabaja con una mezcla rica en combustible. Es por ello por lo que se debe encontrar las suficientes moléculas de oxígeno para que todos los componentes reaccionen adecuadamente y permitan reducir las emisiones de HC y CO (Jeevahan et al., 2017).

Por otro lado, cuando existe gran cantidad de O<sub>2</sub> se incrementan aspectos como la velocidad de combustión y la temperatura del cilindro, lo cual genera que existan mayores emisiones de NO<sub>x</sub>. Dicho compuesto se genera cuando la temperatura está entre 2500 a 3000 K (Jeevahan, Poovannan, Raj, Maghwaran, & Britto, 2017). No obstante, otros autores afirman que los gases de NO<sub>x</sub> se forman a temperaturas de 2673 a 2773 K (Vijay et al., 2022).

El estudio de Kozak y Merkisz en 2022 se enfoca en el impacto de los combustibles diésel oxigenados en las emisiones de partículas PM. Este estudio demuestra que los combustibles oxigenados contribuyen significativamente a la reducción de emisiones de material particulado. Concretamente, se logra una disminución de hasta el 32% en las emisiones de PM. La presencia de oxígeno durante la combustión juega un papel crucial en esta reducción (Kozak & Merkisz, 2022).

Por último, es importante mencionar que los motores diésel operan con una mezcla pobre para la combustión. Esta operación resulta en altas concentraciones de O<sub>2</sub> en los gases de escape, variando entre 5 y 17% según la carga del motor (Adams, 2021).

### ***1.9.3. Compuestos orgánicos volátiles (COV)***

Se entiende por COV a los hidrocarburos que se encuentran en estado gaseoso bajo condiciones normales. Dichos compuestos son bastante volátiles a temperatura ambiente y presión atmosférica (Costa, 2015).

Por lo tanto, estos hidrocarburos se encuentran presentes en la atmósfera solo unos minutos o en algunos casos permanecen meses. Además, las emisiones de los COV a la atmósfera provienen de manera significativa de los carros diésel, no obstante, dichas emisiones pueden variar dependiendo del tipo de conductor, la tecnología que tiene el vehículo y la calidad del combustible (Osugwu, 2020).

#### **1.9.4. Hidrocarburos (HC)**

Para que se produzcan hidrocarburos (HC) en un motor diésel debe existir una combustión incompleta de la mezcla, aspecto que afecta en gran medida al rendimiento del motor e influye en el consumo de combustible (Laskowski et al., 2019).

El aumento de las emisiones de HC y CO está relacionado con los defectos en el motor. Estos defectos pueden ser daños o deterioros de los componentes internos del motor. Por ejemplo, un daño en las bujías puede provocar fallas en el encendido y aumentar así las emisiones de estos gases. Asimismo, una mala conducción o daños en el catalizador también puede generar incrementos de HC y CO (ACEA et al., 2019).

Los hidrocarburos (HC) emitidos por el tubo de escape pueden originarse de una oxidación parcial del combustible. Esta oxidación parcial otorga un lugar a compuestos carbonílicos. Además, los HC pueden transformarse en diferentes compuestos debido a las reacciones de la combustión. Entre estos compuestos se encuentran las olefinas (como el etileno y el 1,3-butadieno), los alquinos (como el acetileno) y compuestos aromáticos (como el tolueno y el benceno). Así, la emisión de HC por el tubo de escape refleja una variedad de procesos químicos relacionados con la combustión incompleta (Wang, 2019).

Es importante mencionar que las propiedades del combustible también pueden afectar el incremento de emisiones de hidrocarburos en el vehículo. Propiedades como un número alto

de cetanos, baja densidad e inferior valor calorífico ayuda a incrementar la volatilidad del carburante, aspecto que provoca mayores emisiones de HC (Wei et al., 2022).

#### **1.9.5. Monóxido de carbono (CO)**

El CO es un gas que se produce debido a que no existe la cantidad adecuada de oxígeno durante el proceso de combustión, es así, que la variación de dicha emisión depende en gran medida de la relación aire-combustible que tiene la mezcla durante el proceso de combustión (Rojas, Romero, & Pancha, 2020). De esta manera el enriquecimiento del combustible con oxígeno puede generar mayores oxidaciones del CO en CO<sub>2</sub>.

Aslan, Altinisik y Keskin (2015) explican que, en una mezcla rica dentro del motor, no todo el carbono del combustible se oxida, aumentando la concentración de CO en las emisiones. Esto ocurre principalmente al arrancar el vehículo o durante aceleraciones repentinas. Incluso en mezclas pobres, se puede producir CO en menor cantidad debido a efectos cinéticos químicos en el cilindro. Además, una turbulencia inadecuada en la cámara de combustión puede causar emisiones adicionales de CO, interfiriendo con la combustión eficiente.

Según el escrito de Jääskeläinen (2021) la formación de CO en las emisiones del tubo de escape puede estar relacionada con fallas en la inyección, como suciedad o fugas. Estas fallas afectan la atomización y vaporización dentro de la cámara de combustión, creando zonas ricas en combustible que elevan las emisiones de CO, HC y PM. Además, el uso de inyectores de tamaño incorrecto, obstrucciones o daños en filtros de aire o combustible, problemas de RPM y fallas en el tiempo de inyección también pueden incrementar las emisiones de CO. Estos factores destacan la importancia de un mantenimiento adecuado para minimizar emisiones nocivas.

### **1.9.6. Óxidos de nitrógenos (NOX)**

Los óxidos nitrosos (NO<sub>x</sub>) están conformados principalmente por dos gases: el óxido nítrico (NO) y el dióxido de nitrógeno (NO<sub>2</sub>) (Rojas et al., 2020). Es necesario considerar que las concentraciones de NO en todas las emisiones de NO<sub>x</sub> pueden abarcar porcentajes de 85 hasta 95%. Dicho elemento cuando es expulsado a la atmosfera se convierte progresivamente en NO<sub>2</sub>, siendo este gas cinco veces más toxico que el NO (Istrate et al., 2020). Por otro lado, puede existir el caso donde los NO<sub>x</sub> reaccionen con los gases de COV o el metano (CH<sub>4</sub>), obteniendo como resultado gases de ozono (O<sub>3</sub>) (Cuesta et al., 2018).

En un motor diésel se emplea aire compuesto principalmente por O<sub>2</sub> y N<sub>2</sub> (nitrógeno molecular). A dicho aire que se encuentra a presión y caliente durante el final del proceso de compresión se le inyecta combustible en la parte superior del cilindro para generar la combustión. Durante esta acción no debería reaccionar el N<sub>2</sub> con el O<sub>2</sub>. No obstante, cuando la temperatura excede los 1600 °C estos dos compuestos comienzan a reaccionar y provocan emisiones de NO<sub>x</sub> (Aslan et al., 2015).

Wei et al. (2022) explican que la formación de NO<sub>x</sub> en un motor está influenciada por la concentración de O<sub>2</sub>, la alta temperatura en distintas zonas del cilindro, y el tiempo de retención del gas no quemado en la cámara de combustión. Además, Pham et al. (2022) indican que la tasa de formación de NO<sub>x</sub> aumenta significativamente con el incremento de la temperatura local, especialmente debido a su distribución no uniforme en la cámara de combustión. Asimismo, según Bosch (citado en Aslan et al., 2015), un aumento de 100 °C en la temperatura de la cámara de combustión puede triplicar los niveles de NO<sub>x</sub>, destacando la relación directa entre la temperatura y la formación de NO<sub>x</sub>.

La composición del combustible también juega un papel fundamental en las emisiones de NO<sub>x</sub>. En la investigación de Wei et al. (2022) se evidencia que cuando se añaden

hidrocarburos como la tetralina y el heptano se mejora la combustión del motor. Este hecho hace que la presión y la temperatura de las zonas donde se quema el combustible incrementen, generando altas emisiones de NOx.

Las emisiones de NOx varían por varios factores. Uno de estos es la velocidad de combustión. Con mayor velocidad, las emisiones de NOx disminuyen ya que el combustible pasa menos tiempo a alta temperatura en el cilindro. Otro factor es la carga del motor. Al aumentar la carga, se inyecta más combustible, elevando las temperaturas y las emisiones de NOx. Además, la baja presión de inyección y la mala atomización del combustible incrementan las emisiones de NOx por los largos tiempos de retardo y altas temperaturas (Sun et al., 2017). También, fallas en componentes como el intercooler y la válvula EGR, daños en el sistema de postratamiento o un mal ajuste del tiempo de inyección pueden aumentar las emisiones de NOx (Jääskeläinen, 2021).


#### **1.9.7. Material particulado (PM)**

Este tipo de emisión ocurre cuando existe una combustión incompleta del combustible o del aceite lubricante, es causado por la acumulación de las partículas de combustible no consumidas totalmente, aceite de lubricación carbonizado o parcialmente quemado, presencia de cenizas, sulfatos y moléculas de agua (Prasad & Sharma, 2020).

Según Khobragade et al. (2019), entre el 0.2 y el 0.5% de la masa de combustible que se ingresa al motor se emite como material particulado. La formación de PM se debe a la existencia de regiones con poco oxígeno en la cámara de combustión, lo que impide que las gotas vaporizadas de combustible reaccionen adecuadamente y provoca que el combustible no se quemara completamente. La temperatura en el proceso de combustión también es importante, ya que una temperatura inferior a 500-550 °C aumenta las probabilidades de que se produzcan emisiones de PM.

Asimismo, existen otros factores para que ocurra la formación de PM como es el caso de la calidad del combustible, en dicho aspecto se toman en cuenta variables como el contenido de azufre y cenizas, además, otro aspecto para la formación de esta emisión puede ser la calidad que tiene el lubricante que se emplea en el motor. Cabe recalcar que las partículas que se generan en el motor tienen un diámetro entre 15 a 40 nm, donde el 90 % es debido a partículas inferiores a 1  $\mu\text{m}$  (Aslan, Altinisik, & Keskin, 2015)

La composición del Material Particulado (PM) se compone de dos partes principales. La primera parte incluye componentes no volátiles e insolubles. Estos componentes están formados por compuestos orgánicos como carbono, sulfato y nitrato. La segunda parte del PM consta de compuestos volátiles y solubles. Estos están elaborados por fracciones carbonosas, ceniza y otros elementos (Guo & Ha, 2020). De acuerdo con el estudio experimental de Kittelson (1998), la composición del PM se muestra en la Figura 1.3.



**Figura 1.3.** Composición del material particulado de un vehículo diésel.

Por otro lado, Sun et al. (2017) realizaron una investigación sobre las características de la combustión y las emisiones de NO<sub>x</sub> y PM en vehículos pesados diésel. En su estudio determinaron que el PM aumenta con el incremento de la carga del motor. Este incremento se



debe a que una carga elevada conlleva un mayor suministro de combustible, aspecto que empeora la uniformidad de la mezcla y genera altas temperaturas en el cilindro incrementando así la formación de PM en las emisiones.

En situaciones de falla, como un desajuste entre el turbocompresor y el inyector, desgaste del inyector, obstrucción del filtro de aire o problemas en el rpm del motor, las emisiones de material particulado pueden incrementarse considerablemente (Jääskeläinen, 2021).

#### **1.9.8. Emisiones de azufre (SOx) y plomo (PB)**

La presencia de azufre (S) y plomo (Pb) en el combustible puede resultar en la emisión de compuestos que contengan dichos elementos como son los óxidos de azufre (Pb) y óxidos de plomo (PbOx). Sin embargo, estos gases pueden ser reducidos significativamente en su contenido en las emisiones de los vehículos cuando se realiza el proceso de refinamiento del combustible, según señala Rentar Environmental Solutions (2018).

Convendría remarcar que los SOx se generan cuando el azufre presente en el carburante reacciona con el O<sub>2</sub> del aire que ingresa al motor (Ashok et al., 2022). La mayor parte de este elemento presente en el combustible se convierte en SO<sub>2</sub> o es absorbido por las partículas que se producen en el motor. No obstante, cuando los gases de salida del EGR tienen una temperatura muy baja se puede formar ácido sulfúrico (H<sub>2</sub>SO<sub>4</sub>), que es un compuesto muy corrosivo (Xin, 2013).

La presencia de azufre en el combustible juega un papel crucial en la formación de partículas finas, afectando adversamente la longevidad del motor. Esto se debe a que los compuestos con azufre aceleran la corrosión y el desgaste de los componentes internos del motor (ACEA et al., 2019).

## 1.10. NORMATIVAS EN BASE A GASES DE ESCAPE

### 1.10.1. Normativas internacionales

La protección ambiental constituye una cuestión crucial a nivel mundial, impulsada principalmente por los gases contaminantes emitidos por los vehículos. Estas emisiones no solo perjudican el medio ambiente, sino que también afectan la salud humana. Como respuesta, numerosos gobiernos y entidades internacionales han establecido estándares de emisión estrictos para regular y controlar estos gases de escape.

Según Khobragade et al. (2019) los estándares de emisión para la homologación de motores diésel en diversos países tomaron en cuenta los parámetros presentes en la Tabla 1.1.

**Tabla 1.1.** Estándares de emisión para vehículos diésel desde el 2014 hasta el 2019

Países	Tipos de motores	Unidades	Gases			
			CO	HC+NOx	NOx	PM
Unión Europea y Rusia	Coches y camiones ligeros	g/km	0,5	0,17	0,08	0,005
	Camión pesado y autobús	g/kW*h	1,5	0,53	0,4	0,01
	Motores fuera de carretera (Potencia>130 kW)	g/kW*h				
Estados Unidos y Canadá	Coches y camiones ligeros	g/km	5,0	4,7	3,3	0,025
	Camión pesado y autobús	g/kW*h	2,61	0,099		0,0018
	Motores fuera de carretera (Potencia>130 kW)	g/kW*h	20,77		0,0268	0,0134
Japón	Coches y camiones ligeros	g/km	3,5	0,86	0,67	0,03
	Camión pesado y autobús	g/kW*h	0,63	0,174	0,15	0,005
	Motores fuera de carretera (Potencia>130 kW)	g/kW*h	2,22	0,57	0,4	0,01
China	Coches y camiones ligeros	g/km	3,5	0,19	0,4	0,02
	Camión pesado y autobús	g/kW*h	0,5	0,23	0,18	0,0045
	Motores fuera de carretera (Potencia>130 kW)	g/kW*h	4,0	2,55	2,0	0,03

Continua.

<b>Países</b>	<b>Tipos de motores</b>	<b>Unidades</b>	<b>Gases</b>			
<b>India</b>	Coches y camiones ligeros	g/km	<b>CO</b>	<b>HC+NOx</b>	<b>NOx</b>	<b>PM</b>
	Camión pesado y autobús	g/kW*h	0,5	0,23	0,18	0,0045
	Motores fuera de carretera (Potencia>130 kW)	g/kW*h	4,0	2,55	2,0	0,03
<b>Corea del Sur</b>	Coches y camiones ligeros	g/km	3,5	4,0	2,7	0,2
	Camión pesado y autobús	g/kW*h	0,5	0,03	0,02	0,01
	Motores fuera de carretera (Potencia>130 kW)	g/kW*h	4,0	0,62	0,46	0,01
<b>Brasil</b>	Coches y camiones ligeros	g/km	1,3	0,13	0,08	0,025
	Camión pesado y autobús	g/kW*h	4,0	2,55	2,0	0,03
	Motores fuera de carretera (Potencia>130 kW)	g/kW*h	3,5	4,0	2,8	0,2

Fuente: (Khobragade et al., 2019)

La Tabla 1.1 muestra los límites impuestos para emisiones de monóxido de carbono (CO), hidrocarburos (HC), óxidos de nitrógeno (NOx) y material particulado (PM). Para alinearse con estas regulaciones, se han desarrollado tecnologías enfocadas en mejorar la combustión y los sistemas de postratamiento de gases de escape. Un ejemplo notable es el uso de catalizadores oxidantes diésel (DOC), que eficazmente reducen las emisiones de CO y HC. Además, muchos vehículos están equipados con filtros de partículas diésel (DPF), que capturan el PM proveniente de las emisiones de motores diésel (Marques et al., 2022).

En la actualidad, cada nación del continente americano se encuentra en la tarea constante de establecer y perfeccionar sus propias normativas relacionadas con las emisiones vehiculares, la seguridad automotriz y los procesos de homologación de vehículos. Resulta interesante observar que, en su gran mayoría, los países latinoamericanos toman como punto de referencia las normativas adoptadas por la Unión Europea o los Estados Unidos, como se detalla minuciosamente en la Tabla 1.2, evidenciando así la influencia global en la configuración de dichos estándares.

**Tabla 1.2.** Normativas sobre emisiones de vehículos en países de América

<b>País</b>	<b>Normativa interna</b>	<b>Normativa Europea</b>	<b>Normativa Estadounidense</b>
Estados Unidos	Tier 3		
Canadá	Regulaciones elaboradas en base a la Ley de protección ambiental de Canadá de 1999		
México	NOM-044-SEMARNAT-2017	Euro VI	EPA 10
Brasil	PROCONVE PL7 y PL8		
Chile	Decreto 211 y su modificación en el Decreto 41		
Argentina	Ministerio De Ambiente Y Desarrollo Sustentable - Resolución 385/2018		
Chile	Decreto Supremo 211 – 41 por MTT	Euro V	EPA 07
Colombia	Resolución 2254 (2017)		
Perú	Decreto Supremo N° 010-2017-MINAM.	Euro III	EPA 98
Uruguay	Ministerio del ambiente – Decreto 135/021		
Continúa.			
<b>País</b>	<b>Normativa interna</b>	<b>Normativa Europea</b>	<b>Normativa Estadounidense</b>
Ecuador	RTE INEN 017. Normativa INEN 2 207	Euro II - Euro III	EPA 94 - EPA 98
Costa Rica	Norma N° 28280 - MOPT-MINAE-S	Pre-II	EPA 91
Venezuela	Decreto N° 2.673		

Fuente: (Sánchez, Fabela, Flores, Hernández, Vázquez, & Cruz, 2019) (INEN, 2013) (INEN, 2016) (Ministerio del Medio Ambiente de Chile, 2020)

En el presente estudio se analizará más a fondo la normativa vigente en países como Ecuador, Chile y México relacionado a la emisión de gases contaminantes para vehículos diésel. Se tratarán específicamente los apartados que hablan sobre la prueba estática, debido a que el tema de investigación se encuentra enfocado a dicho examen.

### **1.10.2. Normativa ecuatoriana en base a gases contaminantes**

El reglamento RTE INEN 017 es la normativa vigente en Ecuador para el control de emisiones de gases en vehículos. Este reglamento tiene como fin establecer límites permisibles en la emisión de contaminantes de vehículos a gasolina y diésel. Para lograr este objetivo, se implementan diversas pruebas y procedimientos destinados a controlar y reducir las emisiones contaminantes que los vehículos emiten al ambiente.

En Ecuador, para evaluar las emisiones de gases contaminantes en vehículos diésel, se realizan dos ensayos específicos. Estos ensayos están definidos en las normativas NTE INEN 2 202 y NTE INEN 2 207. Estas pruebas son fundamentales para asegurar que los vehículos diésel cumplan con los estándares ambientales establecidos en el país.

El primer ensayo realizado en la revisión técnica vehicular en Ecuador tiene como objetivo evaluar la opacidad de los gases emitidos por vehículos diésel, los límites permisibles se visualizan en la Tabla 1.3. Esta prueba, conocida como "Aceleración Libre", se alinea con las normas internacionales Euro II y EPA 94. Durante la prueba, se incrementan las revoluciones del motor con el vehículo en estado de reposo y en neutro para las transmisiones manuales, hasta alcanzar el máximo de revoluciones permitidas. Para llevar a cabo este ensayo, se utilizan herramientas especializadas como el opacímetro, una unidad de procesamiento de datos y dispositivos de registro e impresión (Instituto Ecuatoriano de Normalización, 2013).

**Tabla 1.3.** Límites máximos de emisiones de fuentes móviles diésel prueba estática

<b>Año modelo</b>	<b>% Opacidad</b>
V. de 1999 y anteriores	60
V. del 2000 y posteriores	50

Fuente: (INEN, 2016)

La prueba dinámica es otro método utilizado en Ecuador para homologar vehículos nuevos, ya sea importados o ensamblados localmente. Esta prueba emplea un dinamómetro y

se realiza según los estándares de las normativas americanas o europeas. Durante el ensayo, se miden emisiones de CO, HC, NOx y PM, como lo establece la normativa INEN de 2016. Cabe destacar que la segunda revisión de la normativa NTE INEN 2207 introdujo nuevos límites para los ciclos de prueba europeos, alineándose con los valores de la normativa Euro III, como se detalla en la Tabla 1.4.

**Tabla 1.4.** Límites de emisiones diésel en pruebas dinámicas europeas

<b>Categoría del vehículo</b>	<b>Peso bruto vehicular (kg)</b>	<b>CO (g/km)</b>	<b>HC (g/km)</b>	<b>HC + Nox (g/km)</b>	<b>Partículas (g/km)</b>	<b>Ciclos de prueba</b>
M1	-	0,64	-	0,5	0,56	0,05
	<=1305	0,64		0,5	0,56	0,05
N1	1350 - 1760	0,8	-	0,65	0,72	0,07
	>1760	0,95		0,78	0,86	0,1
N2, N3,						0,10
M2	>3500	2,1	0,66	5	-	
M3						0,13 (g/kWh)

Fuente: (INEN, 2016)

### ***1.10.3. Normativa chilena en base a gases contaminantes***

Las normativas de emisiones en Chile están regidas principalmente por los Decretos Supremos N°211 de 1991 y N°55 de 1994, que establecen límites de emisiones para vehículos livianos y pesados, respectivamente observados en la Tabla 1.5. Es importante destacar que estos decretos fueron actualizados a lo largo del tiempo. Un ejemplo reciente es el Decreto N°41 de 2020, que impone nuevos límites de emisiones para vehículos livianos, alineándose con los estándares de la normativa Euro 6. Esta actualización incluye límites para gases como el CO<sub>2</sub>, CO, NOx y PM.

**Tabla 1.5.** Límites de emisiones para vehículos livianos a compresión.

Categoría Vehículos Comerciales	Peso Bruto Vh. (Kg)	Masa de referencia (Kg)	CO	NOX	HCT+NOx	PM	NP
			mg/km				#/km
Vehículos livianos	Menor a 2700	Todas	500	80	170	4,5	6x10 <sup>11</sup>
Clase 1	Menor a 2700	≤ 1,305	500	80	170	4,5	6x10 <sup>12</sup>
Clase 2	Menor a 2700	>1,305 y ≤ 1,760	630	105	195	4,5	6x10 <sup>13</sup>
Clase 3	Menor a 2700	> 1,760	740	125	215	4,5	6x10 <sup>14</sup>

Fuente: (Ministerio del Medio Ambiente de Chile, 2020)

Según lo establecido en el Decreto Supremo N°4 y el acuerdo N°7/2016 en Chile, se implementa un control de las emisiones de gases contaminantes en vehículos diésel mediante la ejecución de una prueba estática de aceleración libre. Esta prueba, utiliza el índice de ennegrecimiento o el flujo parcial en opacidad, como objetivo para medir los gases. Los resultados obtenidos deben cumplir con los estándares establecidos por el coeficiente del humo, también conocido como coeficiente de extinción de luz "K", según lo especifica el Consejo de Ministros para la Sustentabilidad de Chile en 2016. La Tabla 1.6 presenta los límites permisibles, donde se detallan los niveles máximos aceptables de densidad del humo en las emisiones, determinados por el coeficiente de humo (K).

En este contexto normativo, se destaca la importancia de estas medidas para garantizar la reducción de emisiones contaminantes provenientes de vehículos diésel, contribuyendo así a la preservación del medio ambiente y a la promoción de prácticas sustentables en el ámbito automotriz. La implementación de estos controles refleja el compromiso de Chile con las regulaciones ambientales y la búsqueda constante de estrategias para mitigar los impactos negativos asociados con las emisiones vehiculares.

**Tabla 1.6.** Limite permisibles en pruebas estáticas

<b>Año del Vehículo</b>	<b>Coeficiente de humo "K en m-1 máximo"</b>
Vehículo motorizados livianos y medianos entre 1999 en inferiores	2,5
Vehículo motorizados livianos y medianos de 2000 y posterior	1
Vehículo motorizados livianos y medianos de 2013 y superiores	0,7

Fuente: (Consejo de ministros para la Sustentabilidad de Chile, 2016)

En Chile, todas las pruebas de emisiones se llevan a cabo por laboratorios acreditados y están bajo la supervisión del Ministerio de Transporte y Telecomunicaciones. Esta entidad es responsable de la homologación de vehículos en el país. De esta forma, se garantiza que los vehículos que circulan cumplan con los estándares de emisiones y seguridad exigidos por la normativa vigente.

#### ***1.10.4. Normativa mexicana en base a gases contaminantes***

En México, se aplican tres regulaciones clave para controlar los límites máximos permitidos de emisiones contaminantes de vehículos. La NOM-041-SEMARNAT está dirigida a los vehículos que ya están en uso. Por otro lado, la NOM-042-SEMARNAT se enfoca en los vehículos nuevos de gasolina. Finalmente, la NOM-044-SEMARNAT se aplica a los vehículos a diésel representado en la Tabla 1.7.

Específicamente, la NOM-044-SEMARNAT establece los límites de emisiones para vehículos diésel con un peso bruto mayor a 3857 kg, según lo indicado en el estudio de Sánchez et al. en 2019.



**Tabla 1.7.** Límites máximos de gases contaminantes de vehículos diésel en México

Tipo de vehículo	Estándar de durabilidad a 100,000 km			
	Gases: g/km			
	CO	HC+NOx	NOx	PM
V. con masa mayor a 1,305kg	0,8	0,162	0,65	0,07

Fuente: (Secretaría de medio ambiente y recursos naturales, 2004)

Según la Secretaría de Medio Ambiente y Recursos Naturales (2014) en México se utiliza la prueba estática únicamente en los vehículos que el fabricante menciona que no pueden ser evaluados con el dinamómetro. El proceso consta de tres fases: una inspección visual del humo, una prueba de marcha a velocidad constante y una prueba de marcha lenta en vacío. Esta prueba es un procedimiento utilizado para medir la emisión de gases provenientes del escape y presenta los siguientes límites para su aprobación:

**Tabla 1.8.** Límites de opacidad para vehículos diésel de 400 a 3857 kg

Año	Coefficiente de absorción "K (m-1) "	Opacidad %
2003 y anteriores	2,00	57,68
2004 y posteriores	1,50	47,53

Fuente: (Secretaría de Medio Ambiente y Recursos Naturales, 2017)

### 1.11. DIAGNÓSTICO PREDICTIVO

El diagnóstico en un automóvil se realiza utilizando herramientas y equipos especializados, como escáneres de diagnóstico, multímetros y osciloscopios. Estos equipos permiten realizar pruebas y mediciones en los sistemas y componentes del vehículo para identificar el problema (Donado, 2020).

El diagnóstico automotriz es un proceso que consiste en identificar y determinar la causa de problemas que provocan un mal funcionamiento y desempeño en el vehículo, en su lugar el diagnóstico predictivo busca predecir futuros problemas para evitar que se produzcan fallas mayores (Torres E ,2017). Este diagnóstico hace uso de un conjunto de técnicas donde

es necesario el monitoreo y el análisis continuo de las variables relacionadas al funcionamiento del vehículo, como la temperatura, la presión, la vibración y el consumo de combustible. Esta información puede ser obtenida utilizando sensores y dispositivos electrónicos.

Según Esic (2022) Estos datos se procesan utilizando algoritmos y modelos matemáticos avanzados, los cuales permiten detectar patrones de comportamiento anormales para realizar posible encontrar los problemas. En el ámbito automotriz el diagnóstico predictivo ayuda a encontrar diversas variables para distintos problemas, por ejemplo, una disminución en la presión del aceite o un aumento en la temperatura del motor pueden indicar la necesidad de realizar un mantenimiento preventivo antes de que se produzcan daños graves.

El diagnóstico predictivo en un motor diésel es importante para la industria del transporte, ya que puede ayudar a prevenir fallas y reducir el tiempo de inactividad de los vehículos, lo que se traduce en mayores eficiencias operativas y menores costos de mantenimiento. Además, también puede contribuir a la mejora de la seguridad y la reducción de emisiones contaminantes (Zambrano & Pérez, 2021).

Hay diversos tipos de análisis que se pueden realizar a un vehículo para realizar el diagnóstico predictivo, como el análisis basado en el aceite del motor, vibraciones, acústica Y aprendizaje autónomo.

### ***1.11.1. Análisis en base al aceite del motor***

El diagnóstico automotriz en base al análisis del aceite del motor es una técnica que ayuda a conocer el estado del motor. Es uno de los métodos usado en mantenimientos predictivos, en este análisis se toma muestras del aceite de motor para realizar pruebas de laboratorio donde se examinan parámetros como: la viscosidad, presencia de partículas, contaminación del aceite.

Primero, se mide la viscosidad para determinar si el aceite ha perdido sus propiedades lubricantes, lo cual puede ser un indicativo de degradación por calor o desgaste. Segundo, la presencia de partículas metálicas en el aceite se analiza para evaluar el desgaste interno del motor y predecir posibles fallos mecánicos. Tercero, la contaminación del aceite se examina detectando elementos foráneos como agua, combustible o suciedad, los cuales pueden alterar la eficiencia del aceite y señalar anomalías en el funcionamiento del motor (Bentancourt & Flores, 2018).

### ***1.11.2. Análisis en base a vibraciones***

El análisis de vibraciones es un método dentro del diagnóstico predictivo que analiza las vibraciones de los elementos mecánicos del automóvil para evaluar el estado de los componentes del vehículo, además de identificar y predecir anomalías que desencadenarían a fallas mecánicas, esto se realiza midiendo las vibraciones producidas por elementos como el motor, la transmisión, los ejes y ruedas (Vega D, 2014).

En el escrito de Erbesd (2021) se afirma que el análisis de vibraciones se realiza utilizando un equipo especializado, éste puede incluir uno o varios acelerómetros y un analizador de vibraciones, ubicados en diferentes puntos del vehículo. Los datos recopilados se analizan para detectar patrones de vibración anormales. Entre las fallas más comunes están: Holguras de los elementos mecánicos, desbalanceo, desalineamiento, entre otras fallas que se pueden encontrar.

### ***1.11.3. Análisis en base a la acústica***

El método de diagnóstico basado en el análisis acústico se enfoca en el estudio de los diferentes sonidos producidos en el vehículo, los cuales pueden ser un indicador de fallas existentes. Estos pueden ser producidos por desgaste y fricción de piezas, la vibración o un mal

ajuste entre componentes, entre diferentes factores que pueden afectar a la existencia de ruidos en el vehículo (Juca K ,2015).

De acuerdo con Méndez & Reyes (2021) este análisis se lo realiza recopilando datos mediante micrófonos o equipos especializados que recopilan la información y luego utilizando un analizador de espectros el cual ayuda a clasificar las diferentes frecuencias de estos sonidos, con el fin de utilizar esta información para realizar la búsqueda de ruidos anormales que sean un indicador de problemas existentes en vehículo.

## **1.12. APRENDIZAJE AUTÓNOMO**

En el año 1950, Alan Turing divulgó el artículo "Máquinas de Cómputo e Inteligencia" donde se propuso la actualmente reconocida como "Prueba de Turing". la cual constituye un criterio para evaluar si una máquina puede manifestar un comportamiento inteligente equivalente o indistinguible del de un ser humano, este fue el primer paso para la creación del aprendizaje autónomo. En la actualidad, el aprendizaje autónomo o ““machine learning”” es una de las áreas de mayor crecimiento en el campo de la inteligencia artificial y la ciencia de datos (Gao et al., 2020).

Gracias a los avances en tecnología y la disponibilidad de grandes cantidades de datos, estas técnicas de aprendizaje autónomo se están aplicando en una amplia variedad de campos, incluyendo la industria automotriz. El aprendizaje autónomo es un campo técnico que está creciendo rápidamente y se considera fundamental para el desarrollo de la inteligencia artificial y la ciencia de datos en la actualidad, estos promueven nuevas herramientas, técnicas y métodos científicos para el desarrollo de la industria (Gao et al., 2020).

Según Cangás Ortega, (2021) En el campo del diagnóstico automotriz, el aprendizaje autónomo se utiliza para desarrollar modelos predictivos que pueden predecir problemas en los

componentes del vehículo antes de que ocurran, lo que ayuda a prevenir fallas y reducir el tiempo de inactividad del vehículo.

### ***1.12.1. Clasificación del aprendizaje autónomo***

El autor Simeone, (2018) menciona que existen tres tipos principales de aprendizaje autónomo o “machine learning”. El primero es el aprendizaje supervisado. En este enfoque, los modelos se entrenan usando datos que han sido previamente etiquetados. Esto significa que al modelo se le proporcionan ejemplos de entrada junto con las salidas correspondientes. El objetivo es que, después del entrenamiento, el modelo esté capacitado para predecir con precisión la salida para nuevos ejemplos basándose en las asociaciones que ha aprendido.

En contraste, el aprendizaje no supervisado se realiza sin datos etiquetados. Los modelos deben aprender a identificar patrones y estructuras en los datos de entrada por su cuenta. No se proporciona al modelo una solución correcta, sino que su objetivo es descubrir por sí mismo la organización subyacente de los datos, agrupándolos en categorías basadas en sus características.

Finalmente, el aprendizaje por refuerzo se basa en un proceso de retroalimentación iterativa y dinámica. Los modelos reciben recompensas o penalizaciones por las acciones que realizan en respuesta a su entorno operativo. Este método les permite aprender de sus éxitos y errores ajustando sus acciones futuras para maximizar las recompensas acumulativas a lo largo del tiempo.

### ***1.12.2. Algoritmos del ““machine learning””***

Según GraphEverywhere (2019), la implementación de algoritmos específicos es crucial en los diferentes tipos de aprendizaje automático, como el supervisado, no

supervisado y por refuerzo. Estos algoritmos se agrupan en varias categorías según su función y aplicación:

Primero, en el campo del aprendizaje supervisado y no supervisado, destacan dos tipos de algoritmos: los de Regresión y Clasificación. Los Algoritmos de Regresión se especializan en predecir valores numéricos continuos, por ejemplo, estimar precios de bienes inmuebles. Por otro lado, los Algoritmos de Clasificación Bayesianos son ideales para categorizar datos en grupos discretos, como determinar si un email es spam

En el contexto del aprendizaje no supervisado, los Algoritmos de Agrupamiento juegan un papel vital en la agrupación de datos basados en características similares, como puede ser el agrupamiento de clientes según sus patrones de compra.

En una categoría más avanzada y a menudo utilizada tanto en aprendizaje supervisado como no supervisado, se encuentran los Algoritmos de Redes Neuronales y Aprendizaje Profundo. Las Redes Neuronales, inspiradas en el cerebro humano, son aplicables a problemas complejos como el reconocimiento de voz o imágenes. Los Algoritmos de Aprendizaje Profundo, una extensión de las redes neuronales, se utilizan para tareas más complejas que requieren la extracción de características de múltiples capas de datos, como en el reconocimiento de objetos en imágenes.

Por último, los Algoritmos de Árboles de Decisión son transversales y pueden aplicarse en varios tipos de aprendizaje automático. Estos algoritmos son útiles para tomar decisiones basadas en múltiples variables y reglas, siendo versátiles en una variedad de aplicaciones.

Cada uno de estos algoritmos se adapta a diferentes aspectos del aprendizaje automático, demostrando la diversidad y la profundidad de esta área tecnológica. Estos diferentes algoritmos son utilizados por el “machine learning” para llevar a cabo las tareas

que estos desempeñan, también es importante destacar que de estos se desprenden gran variedad de algoritmos que son más específicos para cada tarea, entre los cuales encontramos: lineal regression, polynomial regression, support vector regression (SVR), decision tree regression, random forest regression, k-means clustering, hierarchical clustering.

Por otro lado, en el campo del aprendizaje automático, los algoritmos de clasificación se apoyan fuertemente en el uso y análisis de variables estadísticas. Estas variables son los elementos clave que alimentan los modelos, permitiéndoles categorizar y procesar eficientemente los datos. Una adecuada selección y manejo de estas variables es crucial, ya que influyen directamente en la precisión y eficacia del modelo en la identificación de patrones y en la toma de decisiones. Por lo tanto, comprender y tratar correctamente las variables estadísticas es esencial para el éxito de cualquier aplicación de clasificación en el aprendizaje automático.

### **1.13. REVISIÓN DE LAS MEDIDAS ESTADÍSTICAS**

El análisis de datos involucra la aplicación de estadística descriptiva, una herramienta crucial en machine learning. Esta metodología no solo permite describir de manera detallada las características y patrones inherentes a los datos, sino que también es esencial para comprender el comportamiento de los gases seleccionados. Al emplear técnicas de machine learning, se pueden identificar y contrastar de manera más eficiente y precisa los patrones complejos presentes en los datos de cada prueba. Esta integración mejora significativamente la capacidad de análisis, permitiendo una interpretación más profunda y una toma de decisiones basada en evidencias más sólidas.

Para determinar las medidas estadísticas del estudio se analizó el libro de Gabriel Posada sobre la estadística descriptiva para el análisis de datos (2016), aquí se denotaron las siguientes medidas a utilizar:

### **1.13.1. Medidas de tendencia central**

Se refiere al análisis de un conjunto de datos para encontrar valores centrales o típicos dentro de la muestra.

**A. Media aritmética:** es una variable de tendencia central muy utilizada que demuestra el promedio de los datos. Se calcula mediante la ecuación (1):

$$\bar{x} = \sum_{i=1}^n x_i \quad (1)$$

Donde:  $\bar{x}$  =media aritmética,  $x_i$ = valor individual y  $n$ =número de datos.

**B. Mediana:** es el valor central que se ubica justo en la mitad de la muestra de datos. Como el número total de datos es un número par se usa la ecuación (2) para determinar la posición de la mediana (Me):

$$i = \frac{X_n + X_{n+1}}{2} \quad (2)$$

Donde:  $X$ =Representación de un valor individual dentro de la base de datos y  $n$ =número de datos.

**C. Moda:** la ecuación (3) describe el método para calcular la moda, que representa el valor que aparece con mayor frecuencia en la base de datos.

$$Mo = l_i + \left( \frac{\Delta_1}{\Delta_1 + \Delta_2} \right) * C \quad (3)$$



En la fórmula presentada, “ $Mo$ ” representa la Moda. “ $l_i$ ” es el valor más bajo en el intervalo con la frecuencia más alta absoluta. “ $\Delta_1$ ” es la resta entre la frecuencia más alta y la frecuencia previa. “ $\Delta_2$ ” es la resta entre esa frecuencia más alta y la que le sigue. Finalmente, “ $C$ ” representa la longitud de ese intervalo con la frecuencia más alta absoluta.

### 1.13.2. Medidas de dispersión

Busca determinar la variación y el comportamiento que tienen los datos en relación con los valores centrales.

**A. Rango:** ya que es una medida que emplea únicamente el valor máximo y mínimo, no tiene mucha información sobre la variabilidad de los datos, pero puede ser un complemento de las otras medidas de dispersión. Se calcula utilizando la siguiente ecuación (4):

$$Rango = X_{m\acute{a}x} - X_{m\acute{i}n} \quad (4)$$

Donde:  $X_{m\acute{a}x}$ = Valor máximo y  $X_{m\acute{i}n}$ = Valor mínimo.

Es importante considerar que el valor máximo y mínimo son medidas para tomar en cuenta dentro del estudio, ya que permite reconocer el intervalo en donde se encuentra dicha emisión, por tal motivo, estas dos medidas estadísticas, junto con la medida de rango se emplearan en el análisis estadístico.

**B. Varianza:** es el valor obtenido por la diferencia de cada dato con respecto con el promedio total de datos, es decir, representa la desviación en relación con la media aritmética. La varianza se determina por la siguiente ecuación (5):

$$Varianza = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} \quad (5)$$

Donde:  $n$ =número de datos,  $x_i$ =Valor individual y  $\bar{x}$  =media aritmética.

**C. Desviación estándar:** considerada una medida muy importante debido a que representa el nivel de dispersión de los datos respecto al promedio. Un valor bajo cercano al promedio representa que los datos están cerca de la media, en contraste con un valor alto cercano al promedio representa mayor dispersión de datos. Se calcula con la siguiente ecuación (6):

$$\sigma = \sqrt{\text{Varianza}} \quad (6)$$

Donde:  $\sigma$  = desviación estándar

**D. Coeficiente de variación:** es una medida que representa la dispersión o la homogeneidad que tiene el conjunto de datos analizados, cuando el valor es bajo los datos son homogéneos y si es mayor son datos muy variados, cuando es cero significa que no hay variación, se determina por la siguiente ecuación (7):

$$CV = \frac{\sigma}{\bar{x}} * 100 \quad (7)$$

Donde:  $\sigma$  = desviación estándar y  $\bar{x}$  = media aritmética.

### 1.13.3. Medidas de forma

Como su nombre lo indica estas medidas se utilizan para determinar la tendencia de la forma en un conjunto de datos.

**A. Asimetría:** la ecuación (8) muestra el valor que determina la tendencia de los datos hacia uno de los extremos de la distribución de la muestra, donde el valor positivo representa inclinación hacia la derecha y el negativo hacia la izquierda, si es cero es simétrica.

$$\text{Asimetría} = \frac{\bar{x} - M_o(\text{Mediana})}{\sigma} \quad (8)$$

Donde:  $\sigma$  = desviación estándar,  $\bar{x}$  = media aritmética y  $M_o$  = mediana.

**B. Curtosis:** la ecuación (9) indica la concentración de los datos en relación con la región central de la distribución, valores altos indican concentraciones en el centro y valores bajos denotan concentración de datos en las colas. Un valor mayor a 3 indica una distribución de datos puntiaguda, menor a 3 aplanada, y cuando es 3 significa que no es puntiaguda ni aplanada.

$$Curtosis = \frac{\sum(x_i - \bar{x})^4}{n * \sigma^4} \quad (9)$$

Donde: n= número de datos,  $x_i$ = valor individual,  $\bar{x}$  = media aritmética y  $\sigma$  = desviación estándar.


## CAPÍTULO II

### 2. MÉTODO Y MATERIALES

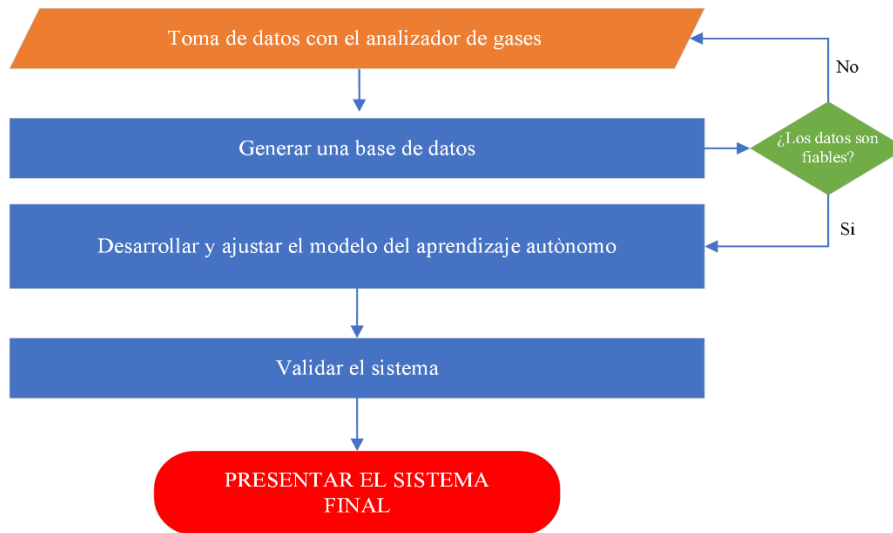
Este proyecto desarrolla un sistema de diagnóstico predictivo para motores diésel, utilizando machine learning y análisis de gases de escape para mantenimiento preventivo y detección temprana de fallos. Se seleccionaron gases clave para la combustión de motores diésel y se experimentó con un motor MAZDA BT 50, utilizando un analizador de gases y un dispositivo de simulación de fallas. Los datos se recogieron en diferentes condiciones operativas, incluyendo variaciones en el sensor MAF y estados de falla del motor. Utilizando MATLAB®, se creó un sistema de machine learning basado en una extensa base de datos de estas condiciones.

#### 2.1. METODOLOGÍA GENERAL DEL ESTUDIO

El desarrollo de un sistema de diagnóstico predictivo para motores diésel basado en el análisis de gases de escape requiere una metodología detallada para la recolección, procesamiento y análisis de datos del motor. Esta metodología incluye la selección de materiales, equipos, herramientas de medición y la identificación de parámetros relevantes para el análisis. Los detalles se encuentran en el Anexo 1, y un flujograma simplificado de la metodología se presenta en la figura 2.1.



Continúa.



**Figura 2.1.** Flujograma de la metodología del estudio.

## 2.2. DETERMINACIÓN DE LOS GASES EN EL ESTUDIO

### 2.2.1. *Matriz de decisión de gases de escape para diagnóstico predictivo*

La Tabla 2.1 resume las características más significativas de los gases de escape de vehículos diésel, como Dióxido de Carbono (CO<sub>2</sub>), Oxígeno (O<sub>2</sub>), Nitrógeno (N<sub>2</sub>), Agua (H<sub>2</sub>O), Monóxido de Carbono (CO), Partículas en Suspensión (PM), Hidrocarburos (HC), Óxidos de Nitrógeno (NO<sub>x</sub>), Plomo (Pb) y Óxidos de Azufre (SO<sub>x</sub>). Estos gases, analizados previamente en el capítulo de revisión bibliográfica, son esenciales para comprender las emisiones de los vehículos.

La matriz para el análisis de gases de escape se elabora teniendo en cuenta varios aspectos cruciales, incluyendo el proceso de generación de los gases en la combustión, su proporción en las emisiones, y cómo la temperatura de la cámara de combustión y el estado de los componentes del vehículo afectan estas emisiones. Se analiza también el cumplimiento de normativas de emisiones y el impacto de los gases en el medio ambiente y la salud, destacando la complejidad y relevancia del análisis.

**Tabla 2.1.** Matriz cualitativa para datos de gases de escape estudiados en capítulo I

Aspectos analizados	GASES DEL ESTUDIO									
	CO <sub>2</sub>	O <sub>2</sub>	N <sub>2</sub>	H <sub>2</sub> O	CO	HC	NO <sub>x</sub>	Pb	SO <sub>x</sub>	PM
<b>Forma de obtención del gas</b>	Combustión del combustible completa				Combustión incompleta del combustible			No se emite en vehículos diésel modernos	Reacción química existente con el oxígeno	Combustión incompleta del combustible
<b>Porcentaje (%) del gas presente en las emisiones</b>	12 %	9 %	67 %	11%	<1% (las emisiones de NO <sub>x</sub> destacan en dicha proporción)					
<b>Relación de la composición y consumo del combustible con los gases</b>	Directamente influenciada por la composición (cantidad de carbono) y tiene relación con el consumo del combustible	Mezcla pobre, menor consumo de combustible y mayor oxidación del carburante	No se relaciona directamente con la composición del combustible		Sus emisiones altas afectan al consumo de combustible. La calidad del combustible (número de cetano, densidad y valor calorífico) también influye en su formación		Depende de la calidad de combustible (mayor presencia de hidrocarburos aumentan los NO <sub>x</sub> )	Mal refinamiento del combustible se traduce en altas emisiones de Pb y Sox		Incremento del combustible suministrado en el cilindro se traduce en mayores emisiones de PM
<b>Relación con la Temperatura en la combustión</b>	Depende de la alta temperatura de la combustión				Temperaturas bajas provocan altos niveles de estos gases, ya que no se da la combustión correctamente.		Mayor tiempo de permanencia de los gases, las altas temperaturas en el cilindro y la distribución no uniforme de dicha temperatura aumentan los NO <sub>x</sub>		Temperaturas bajas producen altos niveles de ácido sulfúrico y temperaturas altas en el cilindro producen altos niveles de SO <sub>x</sub>	Temperaturas bajas producen PM altos, ya que los hidrocarburos no reaccionan correctamente
<b>Dependencia de otros compuestos o gases</b>	Depende de la cantidad adecuada de O <sub>2</sub> en la mezcla para la oxidación completa del CO	Depende de la Cantidad de O <sub>2</sub> en el aire y la reacción química con el carburante	Depende de la Cantidad de N <sub>2</sub> en el aire y la reacción química con el carburante	Se produce debido a las reacciones químicas de la obtención de CO <sub>2</sub> y NO <sub>x</sub>	Depende del O <sub>2</sub>		Depende del O <sub>2</sub> y de los hidrocarburos del combustible	Reacción química con el oxígeno		Depende de las regiones con poco O <sub>2</sub>

Continúa.

Aspectos analizados	CO <sub>2</sub>	O <sub>2</sub>	N <sub>2</sub>	H <sub>2</sub> O	CO	HC	NO <sub>x</sub>	Pb	SO <sub>x</sub>	PM
<b>Influencia directa para la formación o reducción de otros gases</b>	Su incremento influye en la disminución de HC y CO.	Su incremento Influye en la reducción de CO, HC y PM, e incrementa los NO <sub>x</sub> .	Influye en la formación de SO <sub>x</sub>	Influye en la formación de ácido sulfúrico	Su reducción incrementa y formación de CO <sub>2</sub> . Si se incrementan estos gases pueden generar mayores emisiones de PM. Además, si reaccionan con los NO <sub>x</sub> se puede obtener ozono	Influye en el	Puede reaccionar con los COV o el CH <sub>4</sub> y formar ozono	Puede formar PbO <sub>2</sub>	Influye en la formación de ácido sulfúrico	No influye de manera directa en la formación de otros compuestos
<b>Influencia con los elementos del motor</b>	Calidad de la atomización y de la inyección del combustible				Calidad de la atomización y de la inyección del combustible, daño en las bujías, obstrucción del filtro de aire o daños en el filtro de combustible, problemas de configuración de RPM y fallas en el tiempo de inyección. Cabe recalcar que la presencia de HC es más significativa que las emisiones de CO cuando se presentan fallos.		Componentes relacionados a la carga del motor (bomba de alta presión, turboalimentador, sistema de inyección, filtro de aire, intercooler y válvula EGR)		Ninguna, ya que las emisiones de dicho elemento producen daños en los componentes del motor	Componentes relacionados a la carga del motor (bomba de alta presión, turboalimentador, sistema de inyección, fallas del turbocompresor y filtro de aire)
<b>Relación con la Normativa</b>	Si se lo toma en cuenta en la normativa Euro V	No tomados en cuenta			Tomados en cuenta para el análisis de gases tanto en la normativa euro V y EPA 07			No tomados en cuenta		Tomado en cuenta para el análisis de gases tanto en la normativa euro V y EPA 07
<b>Consecuencias de su emisión</b>	Es un gas de efecto invernadero que favorece al cambio climático	No causan daños al medio ambiente, ya que son compuestos naturales			Nocivo para la salud (en cantidades pequeñas) y el medio ambiente	Nocivo para la salud (en altas cantidades) y el medio ambiente	Tóxico para la salud (en cantidades bajas) y el medio ambiente	Tóxico para la salud (en cantidades pequeñas) y el medio ambiente	Tóxico para la salud (en cantidades bajas), el medio ambiente y es altamente corrosivo	Tóxico para la salud (en cantidades pequeñas) y el medio ambiente

Fuente: (Aslan, Altinisik, & Keskin, 2015), (Pham, Le, Yeo, Choi, & Lee, 2022), (Sun, Wang, Wang, & Zhou, 2017), (Silveira, Molinar, Silveira, & Schlosser, 2023) & (Prasad & Sharma, 2020)

La Tabla 2.1 ofrece información cualitativa sobre los gases de escape, pero para mejorar la selección de gases en el sistema predictivo, se creó una tabla adicional con ponderaciones basadas en aspectos de la tabla anteriormente mencionada. Esta nueva tabla utiliza una escala de 1 a 5 para cuantificar cada aspecto, siendo 5 muy importante y 1 poco importante, con el fin de evaluar objetivamente la relevancia y la influencia de cada gas en el rendimiento del sistema. Este proceso sistemático de ponderación garantiza una evaluación precisa y efectiva de los gases en relación con los aspectos críticos del sistema predictivo.

**Tabla 2.2.** Cuantificación de datos cualitativos en la matriz de decisión de gases de escape

Aspectos Analizados	escape									
	CO <sub>2</sub>	O <sub>2</sub>	N <sub>2</sub>	H <sub>2</sub> O	CO	HC	NO <sub>x</sub>	Pb	SO <sub>x</sub>	PM
Forma de obtención (Combustión completa = 3, Combustión incompleta = 5, Refinación del combustible = 1 a 2)	3	3	3	3	5	5	5	0	2	5
Porcentaje (%) del gas presente en las emisiones (Un Mayor porcentaje en las emisiones se considera más importante)	4	4	5	4	2	2	3	0	1	3
Influencia directa para la formación o reducción de otros gases (Si incide en la formación o reducción de uno o más gases se considera muy importante)	3	5	3	3	4	4	4	3	3	2
Relación con las fallas de los componentes del vehículo	4	4	3	3	4	5	4	0	0	4
Consecuencias de su emisión al medio ambiente y al ser humano (Mayores consecuencias implica mayor importancia para el estudio)	3	0	0	0	5	4	5	5	5	5
<b>Total</b>	17	16	14	13	20	20	21	8	11	19

El análisis de la Tabla 2.2 revela que los gases más importantes en el estudio son aquellos con las mayores ponderaciones, indicando su relevancia para la investigación. Gases como SO<sub>x</sub>, Pb, N<sub>2</sub> y H<sub>2</sub>O, con ponderaciones inferiores a 15 pts, se descartan por su menor impacto en el funcionamiento del motor. El CO<sub>2</sub>, con una ponderación de 17 pts, y el O<sub>2</sub>, con 16 pts, se identifican como críticos para evaluar el rendimiento del combustible y la eficiencia de la combustión, siendo esenciales para analizar la condición del motor.



Los gases HC, CO, NOx y PM también obtuvieron altas ponderaciones, mayores a los 18 pts, resaltando su importancia en la eficiencia de la combustión y el rendimiento del motor. Sin embargo, se decidió excluir las emisiones de PM y HC por su menor influencia directa y las limitaciones del equipo de medición. El HC, aunque con una alta ponderación, se excluye por su similitud con el CO, que tiene una mayor relación con otros gases seleccionados como el CO<sub>2</sub> y el O<sub>2</sub>. Por lo tanto, los gases elegidos para el sistema predictivo, por su significativa importancia, son CO<sub>2</sub>, O<sub>2</sub>, CO y NOx.

## 2.3. SELECCIÓN DEL VEHÍCULO Y MATERIALES

### 2.3.1. Motor – Mazda BT-50

El motor seleccionado para este estudio es el de una camioneta Mazda BT50 del año 2012, perteneciente a la Universidad Técnica del Norte. Esta selección es estratégica, ya que el acceso al motor dentro de la institución facilita considerablemente la realización de pruebas y experimentos al ser parte del equipamiento académico de la universidad. A continuación, se presenta la Tabla 2.3 con la ficha técnica del motor del vehículo seleccionado:

**Tabla 2.3.** Ficha técnica de Mazda BT-50

<b>Características</b>	<b>Descripción</b>
<b>Numero de cilindros</b>	4 en línea, DOHC
<b>Cilindrada (cm<sup>3</sup>)</b>	2499
<b>Relación de compresión</b>	18x1
<b>Relación de corte de admisión</b>	2
<b>Aspiración</b>	Turbo- intercooler
<b>Inyección</b>	Electrónica de riel común CRDI
<b>Potencia máxima</b>	140,9 KW a 3500 rpm (157,30 HP)
<b>Torque máximo</b>	363 Nm a 1800 rpm
<b>Orden de encendido</b>	1-3-4-2
<b>Revoluciones máximas</b>	2850
<b>Ralentí (rpm)</b>	750 – 790
<b>Sistema de distribución</b>	Por banda
<b>Compresión del motor</b>	3040,59 KPa
<b>Lubricación</b>	Aceite 15W40 SAE con grado API

Fuente: (Ramírez, 2018, pág. 28)

### 2.3.2. Analizador de gases

Para este estudio se seleccionó el analizador de gases portátil KANE Autoplus 5-2 de uso automotriz debido a su disponibilidad, tamaño y al ser un equipo que tiene la capacidad de cumplir con la misión de medir los gases que son expulsados por el tubo de escape de un motor diésel. En la Tabla 2.4 se visualiza las especificaciones técnicas del analizador de gases.

**Tabla 2.4.** Características técnicas del analizador de gases KANE AUTOplus 5-2

<b>Características</b>	<b>Descripción</b>
<b>Tipo</b>	AUTOplus 5-2
<b>Gases analizables</b>	CO CO <sub>2</sub> HC O <sub>2</sub> NOX Lambda/AFR
<b>Medidas</b>	CO (0-10%) CO <sub>2</sub> (0-16%) HC (0-5000 ppm) O <sub>2</sub> (0-21%) Lambda/AFR (0,8-1,2) NOx (0-5000 ppm)
<b>Tipo de combustible</b>	Gasolina Diésel
<b>Características</b>	Cuenta con una batería de 4 horas de duración, ideal para diagnósticos y mantenimiento de vehículos. Se conecta fácilmente a PCs y dispositivos inalámbricos, proporcionando lecturas en tiempo real, lo que lo hace eficiente para pruebas de cumplimiento y diagnósticos automotrices.

Fuente: (Manual KANE Automotive Essential Instruments, pág. 3)

### 2.3.3. Bosch FSA 740

El Bosch FSA 740, es un dispositivo portátil que destaca por su software intuitivo y analizador de gases. Este equipo permite realizar comprobaciones eléctricas precisas y visualizar, a través del software ESI [tronic], valores en tiempo real como rendimiento del

motor, temperatura y velocidad. Es esencial para identificar anomalías en el rendimiento del vehículo. Las especificaciones detalladas de este equipo se encuentran en la Tabla 2.5.

**Tabla 2.5.** Datos técnicos del FSA 740

<b>Característica</b>	<b>Descripción</b>
Osciloscopio de 2 canales	Tasa de escaneo 50 MS/s
Rango de medición de voltaje	0 a 60 V
Rango de medición de corriente	0 a 1 000 A
Rango de medición de resistencia	0 a 1 MΩ
Rango de medición del voltaje de encendido	Hasta ± 50 Kv
Rango de medición de la temperatura del aceite	-20 °C a 150 °C
Rango de medición de la temperatura del aire	-20 °C a 100 °C
Rango de medición de la presión de líquido	0 a 1 000 kPa
número de procedimientos de prueba guiados	18 (con valores establecidos)
Número de señales del sensor visibles simultáneamente	6
Rango de temperatura de funcionamiento	5 °C a 40 °C

Fuente: BOSCH (2020).

#### **2.3.4. Dispositivo simulador de fallas**

Para el desarrollo del sistema de diagnóstico en esta investigación, se utiliza un dispositivo especializado para simular fallos en el Sensor MAF del motor del vehículo. Este aparato, al generar señales incorrectas o fuera de rango, permite operar el motor en distintos estados, facilitando la recolección de datos variados, cruciales para el avance del sistema de diagnóstico. La Figura 2.2 muestra cómo el dispositivo, mediante un potenciómetro, ajusta el voltaje enviado por el sensor MAF a la computadora del vehículo, conectándose directamente al terminal de señal y alimentándose de la batería del vehículo.



**Figura 2.2.** Dispositivo variador de voltaje para el sensor MAF

### **2.3.5. Software KANE LIVE**

Este software, utilizado en combinación con el analizador de gases KANE AUTOplus 5-2, facilita la recolección y manejo de datos obtenidos por el analizador. Proporciona una interfaz intuitiva para la configuración del dispositivo, captura, almacenamiento de datos, análisis y generación de informes detallados. Estos informes son fundamentales, ya que proporcionan los datos esenciales para el desarrollo del trabajo.

### **2.3.6. Software MATLAB®**

Este software sirve para analizar y simular datos, muy importante para procesar y analizar los datos obtenidos de los gases de escape del motor, además de este programa tiene muchas funciones y herramientas que se encargan especialmente en el análisis numérico estadístico y para realizar el aprendizaje autónomo. Es importante mencionar que se utilizará la versión estudiantil del programa proporcionado por la Universidad Técnica del Norte.

## **2.4. DETERMINACIÓN DE LOS ESTADOS DE FALLA SIMULAR EN EL MOTOR**

Para desarrollar un sistema de diagnóstico predictivo basado en gases de escape, es necesario simular diversas fallas en el motor de prueba. El objetivo principal es recopilar datos de los gases de escape mientras el motor opera en distintos estados. En este sentido, para delimitación y el alcance establecido para el estudio, se centra en el uso de tres componentes del motor: inyectores, válvula dosificadora ZME y el sensor MAF.

### **2.4.1. Estados de falla**

#### **A. Estado 1: Falla en los inyectores**

Este estado se utilizará para simular fallos y recopilar datos del motor para el aprendizaje autónomo. Se han considerado dos tipos de fallos: el fallo mecánico, que se relaciona con el desgaste en las toberas de los inyectores; y los fallos eléctricos, que son causados por señales erróneas emitidas por la unidad de control electrónica (ECU) del vehículo. El primer tipo de fallo se puede simular mediante la sustitución de inyectores en buen estado por aquellos que presentan desgaste en las toberas.

Para el segundo tipo de fallo, se requiere un dispositivo electrónico con un microcontrolador. Ambos tipos de fallos pueden dar lugar a un rendimiento deficiente del motor, aumento en el consumo de combustible, generación de ruido y vibraciones, así como un desgaste generalizado del motor.

La Tabla 2.6 es una tabla comparativa entre estos dos tipos de fallos y se utiliza para determinar cuál de ellos es relevante simular en el contexto de la investigación.

**Tabla 2.6.** Fallas mecánicas y eléctricas en los inyectores

Aspectos	Falla mecánica	Falla eléctrica
Nivel de impacto para la investigación (Relación con los gases de escape)	Alto impacto	Alto impacto
Dificultad para simular la falla	Fácil simulación	Difícil simulación
Acceso de recursos a emplear	Fácil acceso	Moderado acceso

Tras el análisis comparativo de las simulaciones de fallas en los inyectores, se concluyó que la opción más pertinente y eficiente para la investigación es la simulación de falla mecánica. Esta elección se fundamenta en la evaluación cualitativa realizada en la Tabla 2.6, la cual reveló que esta simulación tiene un impacto notable en el rendimiento del motor y en las emisiones de gases de escape. Además, es de fácil implementación y requiere de recursos accesibles para su ejecución.

**B. Estado 2:** Falla en el sensor de flujo de aire (MAF)

En este segundo estado, al igual que en el estado anterior, se consideran dos tipos de fallas para simular en el sensor MAF. El primero es una falla mecánica que puede surgir al ajustar ciertos componentes del motor para modificar la cantidad de aire en el cilindro. El segundo tipo de falla es eléctrica y requiere un dispositivo electrónico que utiliza un potenciómetro para enviar señales falsas a la ECU.

Estas fallas pueden causar variaciones en la mezcla de aire y combustible, generando mezclas ricas o pobres que afectan directamente los gases de escape. Para facilitar la elección de la falla más apropiada en la simulación del sensor, se presenta la Tabla 2.7, que compara estos dos tipos de falla y permite realizar un análisis para tomar una decisión apropiada.

**Tabla 2.7.** Fallas mecánicas y eléctricas en el sensor de flujo de aire

Aspectos	Falla mecánica	Falla eléctrica
Nivel de impacto para la investigación (Relación con los gases de escape)	Alto impacto	Alto impacto
Dificultad para simular la falla	Difícil simulación	Fácil simulación
Acceso de recursos a emplear	Difícil acceso	Moderado acceso

En la investigación, se selecciona la prueba de falla eléctrica sobre la mecánica para simular fallas en el sensor MAF por varias razones, según lo detallado en la Tabla 2.7. Primero, las fallas eléctricas tienen un mayor nivel de impacto en el funcionamiento del motor en comparación con las fallas mecánicas. Segundo, las fallas eléctricas son más fáciles de simular, ya que no requieren ajustes físicos en el motor o sus componentes, lo que simplifica el proceso de experimentación. Finalmente, simular fallas eléctricas requiere menos recursos y es más accesible, lo que hace este tipo de prueba más viable y eficiente para el propósito de la investigación.

### **C. Estado 3:**

En el tercer estado del motor, la Tabla 2.8 es esencial para comparar dos tipos de averías para simulación: fallas mecánicas y eléctricas. La falla mecánica implica el uso de una ZME desgastada, afectando componentes como el vástago y partes móviles, lo que conlleva a un sellado ineficiente y una regulación imprecisa del flujo de combustible. Por otro lado, la falla eléctrica se genera mediante la modificación precisa de la señal PWM enviada por la ECU al actuador, un proceso que requiere exactitud para prevenir malfuncionamientos. Al igual que la falla mecánica, esta alteración impacta significativamente la regulación del flujo de

combustible. Ambas fallas son cruciales para evaluar su impacto en los gases de escape, la toma de datos y el rendimiento del motor.

Para facilitar la elección de la falla más apropiada en la simulación del sensor, la Tabla 2.8 presenta una comparativa de estas fallas, permitiendo un análisis detallado para tomar una decisión informada en la investigación.

**Tabla 2.8.** Fallas mecánicas y eléctricas en la válvula ZME para la investigación.

Aspectos	Falla mecánica	Falla eléctrica
Nivel de impacto para la investigación (Relación con los gases de escape)	Alto impacto	Alto impacto
Dificultad para simular la falla	Fácil simulación	Difícil simulación
Acceso de recursos a emplear	Moderado acceso	Difícil acceso

En el estado 3 del motor, la investigación opta por la simulación de la falla mecánica debido a su sencilla ejecución y el acceso moderado a recursos, a diferencia de la más compleja y menos accesible falla eléctrica, según se detalla en la Tabla 2.8.

#### **2.4.2. Resultados de la selección de los estados de falla**

La exhaustiva evaluación de las condiciones de falla ha culminado en la identificación y selección de varios estados y condiciones del motor, los cuales se encuentran detalladamente presentados en la Tabla 2.9. Esta tabla no solo actúa como un compendio informativo de las condiciones de fallo, sino que también establece las bases sobre las cuales se llevarán a cabo la recopilación de datos y la posterior elaboración de los modelos correspondientes.



**Tabla 2.9.** Resumen de las condiciones de falla seleccionadas.

<b>Condición</b>	<b>Elemento de falla</b>	<b>Descripción</b>	<b>Tipo de Falla</b>
Estado 1	4 inyectores	Cuatro inyectores con desgaste en las toberas (factor cualitativo)	Mecánica
Estado 2	Sensor MAF	Manipulación de la lectura del sensor MAF a 4V (variable cuantitativa)	Eléctrica
Estado 3	Válvula dosificadora ZME	Una ZME con desgaste en el vástago y partes móviles (factor cualitativo)	Mecánica

## **2.5. PROCEDIMIENTO DE RECOPIACIÓN DE DATOS**

### **2.5.1. Proceso de toma de datos**

Se realizó un flujograma del proceso para la toma de datos, el cual se encuentra presente en el Anexo 2. Este diagrama está basado parcialmente en el procedimiento de la normativa INEN 2202 acerca de la prueba de opacidad en motores diésel a través del método de aceleración libre, además se tomó en cuenta el manual de usuario del analizador de gases KANE Autoplus 5-2.

### **2.5.2. Pasos para la recopilación y toma de datos**

**A. Preparación del motor:** antes de recopilar datos, es crucial confirmar que el motor esté en perfecto estado, revisando niveles de aceite, refrigerante y combustible, y chequeando que todos los componentes funcionen adecuadamente para garantizar la precisión de los datos. Como se evidencia en el Anexo 4.

**B. Preparación del analizador de gases:** es vital verificar que el analizador de gases, el KANE Autoplus 5-2, esté en condiciones óptimas antes de su utilización, incluyendo la

inspección y ajuste del filtro, mangueras, carga y sonda. La purga y la calibración cero son esenciales para establecer un punto de referencia y asegurar la precisión en las mediciones de los gases de escape.

- C. Conexión del analizador:** tras preparar el motor, se conecta la sonda del analizador de gases al tubo de escape para capturar y analizar las muestras de gases, obteniendo datos sobre la composición y emisiones.
- D. Seleccionar el estado del motor para la simulación:** Se selecciona el estado del motor para la recolección de datos basado en la simulación deseada, ajustando su funcionamiento para inducir el estado de falla requerido. La elección es vital para la pertinencia de los datos, detallados en la Tabla 2.9, que incluye elementos clave como ZME, MAF e inyectores.
- E. Recopilación de datos:** Con el motor en el estado adecuado, la sonda del analizador se conecta para iniciar la recolección de datos durante varios estados de funcionamiento, registrando 800 datos por estado, divididos en 16 muestras de 50 datos cada una. Se realizan purgas automáticas del dispositivo KANE para mantener la precisión de los datos, pausando la recopilación y limpiando la sonda antes de continuar. Los resultados son monitoreados en tiempo real mediante el software KANE LIVE y se codifican conforme a lo indicado en la Tabla 2.11 para su posterior análisis. Es importante destacar que la nomenclatura utilizada para dicha codificación corresponde a la Tabla 2.10.

**Tabla 2.10.** Nomenclatura de los estados del motor

<b>ESTADOS DEL MOTOR</b>	
<b>Nomenclatura</b>	<b>Descripción</b>
<b>I</b>	Inyectores
<b>Z</b>	Válvula ZME
<b>M</b>	Sensor MAF
<b>M90</b>	Sensor MAF con una entrada de aire de 90 gr/s
<b>D</b>	Dañado o desgastado
<b>B</b>	Buen estado

**Tabla 2.11.** Definición de la codificación de los estados del motor

ESTADOS DEL MOTOR	
CÓDIGO	DEFINICIÓN
IDZDM90	Inyectores con desgaste en las toberas, ZME defectuosa por el uso y MAF con una señal de 90 gr/s a la ECU
IDZBMB	Inyectores con desgaste en las toberas, ZME nueva y MAF trabajando de manera correcta
IBZDMB	Inyectores reparados, ZME defectuosa por el uso y MAF trabajando de manera correcta
IBZBMB	Inyectores reparados, ZME nueva y MAF trabajando de manera correcta
IBZBM90	Inyectores reparados, ZME nueva y MAF con una señal de 90 gr/s a la ECU

Como se puede observar en la tabla 2.11. se seleccionaron 5 pruebas para la recopilación de los datos. No obstante, se podrían analizar hasta 16 pruebas debido a la combinación que se puede obtener entre los estados del motor seleccionados. Cabe recalcar que se seleccionaron dichas pruebas debido a que se las consideró más significativas para la investigación, además de que el procesamiento de datos usando todas las combinaciones de los estados sería muy extenso.

**F. Uso del software KANE LIVE:** para la recopilación y gestión de datos de emisiones de gases de escape. Inicialmente, se debe conectar el software con el analizador de gases mediante Bluetooth, lo que habilita la visualización en tiempo real de mediciones críticas de gases como O<sub>2</sub>, CO<sub>2</sub>, CO, y NO<sub>x</sub> en la interfaz intuitiva y eficiente del software como se muestra en Anexo 7. Este paso también incluye la capacidad de almacenar los datos recogidos en formato .CSV, lo que facilita su posterior exportación e importación para un análisis detallado, haciendo de esta conexión y recolección de datos un componente vital del proceso.

### **2.5.3. Proceso de simulación de fallas y condiciones del motor.**

El procedimiento de simulación reveló el impacto de las fallas en el sensor MAF, la válvula dosificadora ZME y los inyectores en la combustión del motor diésel y, por ende, en la


composición de los gases de escape. Estos datos son clave para entender cómo el diagnóstico predictivo puede identificar y abordar problemas en estos componentes críticos, y a continuación, se detallarán las simulaciones realizadas en estos tres elementos esenciales del motor.

### 2.5.3.1. Simulación de falla en el sensor MAF

Para realizar estas modificaciones de voltaje en el Sensor MAF, se emplea un dispositivo electrónico con un potenciómetro como componente principal. Esta alteración cambia la señal eléctrica del sensor, afectando así el registro del flujo de aire al motor. Como resultado, el sensor MAF registra una entrada alterada de 90 gr/s de aire al cilindro, una cifra que contrasta significativamente con los niveles normales de flujo de aire, tal y como se detalla en el Anexo 9.

#### A. Creación del dispositivo electrónico simulador de fallas en el sensor MAF


Para la simulación de fallas en el Sensor MAF, se utiliza un dispositivo que modifica la señal eléctrica que es proporcionada desde el sensor hacia la ECU. Este dispositivo consiste en un potenciómetro conectado al socket del sensor como se observa en la Figura 2.3.



**Figura 2.3** Esquema eléctrico del dispositivo simulador de fallas MAF.

El potenciómetro se trata de una resistencia variable, donde su circuito se energiza directamente desde la batería del motor, y al mover su contacto deslizante hacia sus dos terminales varía el voltaje del MAF que éste envía como señal a la ECU del vehículo, cabe recalcar que la señal fue monitoreada por un multímetro para verificar que se envía los parámetros adecuados.


Para lograr la variación deseada, se realiza una conexión directa entre los pines del socket del sensor y el terminal del sensor MAF usando cables tal como se muestra en la Figura 2.4. Sin embargo, solo el pin de señal se conecta al potenciómetro previamente energizado con la batería del motor.



**Figura 2.4.** Dispositivo conectado al socket del sensor MAF

Para el estudio se modificó su señal a 4 Voltios provocando una entrada de aire de 90 gr/s. Este cambio de señal de dicho sensor afecta la señal de entrada de aire al cilindro del motor tienen un impacto directo en la composición de los gases de escape.

### 2.5.3.2. Simulación de Falla en la Válvula Dosificadora ZME




**Figura 2.5.** Diagrama de la simulación de la válvula "ZME"

Con el propósito de llevar a cabo simulaciones de fallas en la válvula dosificadora ZME, se optó por emplear dos válvulas distintas: una nueva y en perfecto estado, y otra previamente utilizada y con evidentes signos de desgaste. La primera de estas válvulas asegura una dosificación precisa del combustible, brindando un rendimiento óptimo en su funcionalidad. En contraste, la segunda válvula, al encontrarse en un estado de uso y desgaste, presenta la posibilidad de dosificar de manera ineficiente o irregular, lo que permite evaluar y simular escenarios de operación menos ideales. Este enfoque permite obtener datos valiosos sobre el comportamiento y la confiabilidad de la válvula ZME en situaciones diversas, contribuyendo así al análisis y mejora de su desempeño en condiciones adversas.



**Figura 2.6** Derecha ZME mal estado, izquierda ZME nueva

### 2.5.3.3. Simulación de Falla en los Inyectores



**Figura 2.7** Diagrama simulación de inyectores

Para simular fallas en los inyectores, se usan dos tipos: inyectores desgastados e inyectores reparados. Los desgastados cuentan con toberas dañadas que causan fugas y pérdidas de presión y mala pulverización. Los reparados, tras limpieza, cambio de toberas y calibración, funcionan óptimamente.

## 2.6. DETERMINACIÓN DE LAS VARIABLES ESTADÍSTICAS DEL ESTUDIO

El dispositivo KANE AUTOPLUS 5-2, diseñado para la recopilación de valores cuantitativos continuos, mide el CO<sub>2</sub>, CO y O<sub>2</sub> en porcentajes, y el NOx en partes por millón (ppm). Es crucial señalar que cada prueba realizada en el motor genera una amplia base de datos, con alrededor de 800 registros por prueba. Esta acumulación masiva de datos requiere un procesamiento meticuloso. Por lo tanto, es esencial identificar y utilizar variables estadísticas relevantes para el análisis de esta información.

### 2.6.1. Medidas estadísticas seleccionadas

Después de analizar las medidas estadísticas mediante una prueba piloto como se observa en el apartado 2.6.2 se determina que no se hará uso de las medidas de posición debido

a que dichas medidas se enfocan mayormente en encontrar la ubicación relativa de los datos, aspecto que no es relevante si se quiere determinar la tendencia y comportamiento general de la muestra. Cabe recalcar que el software MATLAB® permite realizar las operaciones antes mencionadas a través de comandos, esto lo realiza de manera automática con los datos establecidos, como se puede apreciar a continuación:

**Tabla 2.12.** Medidas estadísticas y sus comandos en MATLAB®.

Medida Estadística	Comando en MATLAB®
Media aritmética	mean(Datos)
Mediana	median(Datos)
Moda	mode(Datos)
Valor máximo	max(Datos)
Valor mínimo	min(Datos)
Rango	range(Datos)
Varianza	var(Datos)
Desviación estándar	std(Datos)
Coefficiente de variación	(Desviacion_estandar./Media).*100
Asimetría	skewness(Datos)
Curtosis	kurtosis(Datos)

Fuente: (MathWorks, 2018)

En la Tabla 2.12 se puede denotar que cada variable estadística seleccionada tiene su comando en el programa MATLAB®, la palabra “Datos” que se encuentra en cada comando hace referencia a la muestra de gases que es analizada.

### 2.6.2. Prueba piloto para la determinación de las variables estadísticas

Para una selección más precisa de las variables estadísticas en nuestro estudio, se llevó a cabo una prueba piloto utilizando las variables preseleccionadas. Esta prueba implicó el uso de cinco muestras de NOx para dos estados del motor: "IBZBMB" (en buen estado) e "IDZDM90" (con fallos). Cada muestra de estudio contenía 50 datos de NOx.

En la realización de la prueba piloto, se aplicaron los procedimientos especificados en los apartados 2.7.2 y 2.8. del documento. El subtema 2.7.2 se enfoca en la elaboración de una base de datos simplificada, mientras que el 2.8. detalla los pasos para implementar el



aprendizaje automático (“machine learning”) y la creación de representaciones gráficas de los resultados obtenidos. Los resultados de este proceso se encuentran descritos en la sección 3.1.

## 2.7. OBTENCIÓN Y TRATAMIENTO DE LA BASE DE DATOS

### 2.7.1. Elaboración de la base de datos inicial

Para la investigación fue necesario recopilar una gran cantidad de datos debido a que el aprendizaje autónomo requiere de una base de entrenamiento sólida que genere precisión, detecte los patrones de comportamiento y reduzca el sesgo estadístico o la desviación de la predicción. El software KANE LIVE tiene la capacidad para almacenar los datos obtenidos durante la prueba en un archivo con extensión “xlsx”, en dicho archivo se forman tablas con columnas que determinan el tiempo en la cual se registró el dato, el número de muestra, tipo de emisión y batería del dispositivo, algunos de estos datos fueron desechados y los más importantes fueron tratados para que la base de datos abarque únicamente las columnas que contenían el valor medido de emisión y la prueba (diagnóstico) a la que pertenecía.

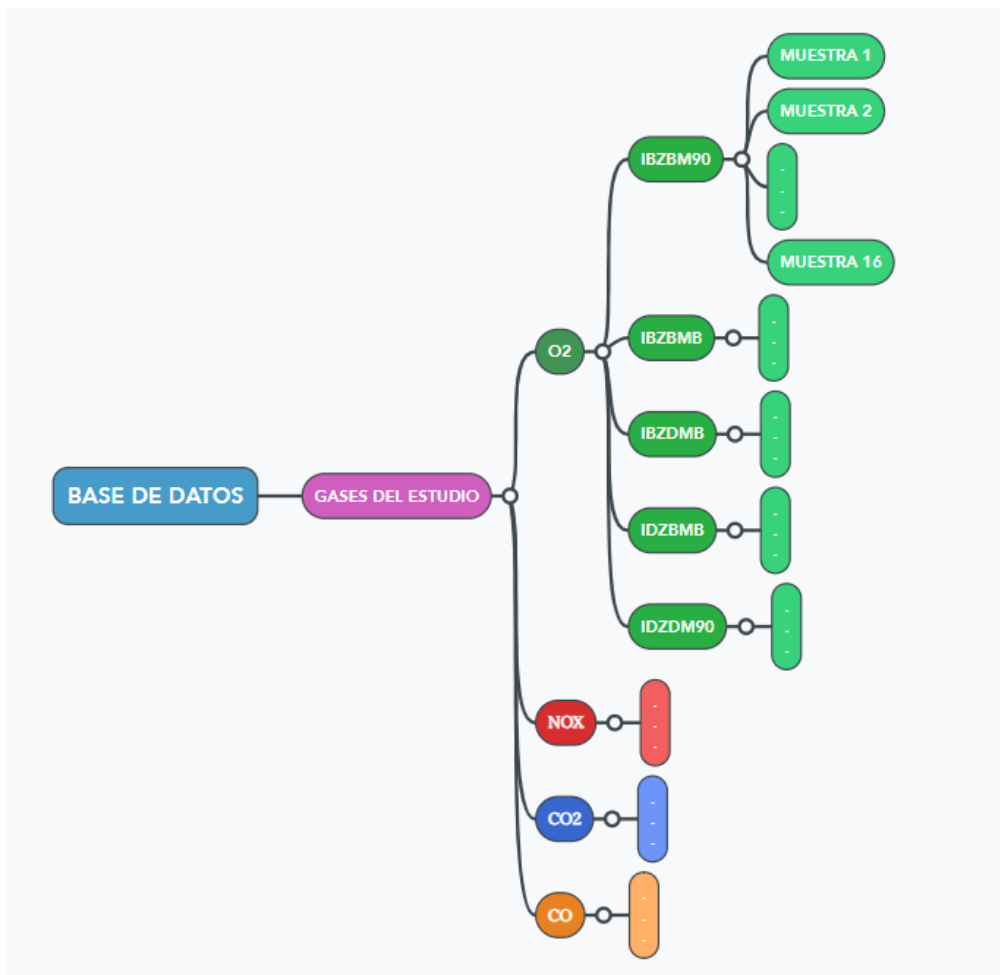
En este sentido para cada prueba se tomaron 16 muestras de 50 datos, lo que equivale a 800 datos por cada prueba, como son un total de 5 pruebas, se recopiló exactamente 4000 datos que fueron ordenados como se muestra en la Figura 2.8

	A	B	C	D	E
1	CO (%)	O2 (%)	CO2 (%)	NOx (ppm)	Diagnóstico
2	0.18	0.28	1.8	113	IBZBM90'
3	0.17	0.28	1.8	112	IBZBM90'
4	0.06	0.28	1.8	111	IBZBM90'
5	0.06	0.28	1.8	111	IBZBM90'
6	0.05	0.28	1.7	112	IBZBM90'
7	0.04	0.28	1.7	113	IBZBM90'
8	0.03	0.28	1.7	112	IBZBM90'
9	0.03	0.28	1.7	112	IBZBM90'

**Figura 2.8** Estructura inicial de la base de datos de emisiones.

La Figura 2.8 despliega de manera clara la estructura de los datos recolectados, destacando al final la columna denominada "diagnóstico". Esta columna es crucial, ya que indica el estado del motor durante la prueba y sirve como la etiqueta de clasificación en el proceso de aprendizaje automático.

Los datos indican que existe una amplia variación en las emisiones, lo que requiere un análisis específico para cada tipo de emisión. Por ello, se propone crear bases de datos separadas para cada gas, para mejorar la precisión en la evaluación y generación de los modelos. Este método se refleja en la Figura 2.9 que organiza las bases de datos por gas específico.



**Figura 2.9** Distribución de la base de datos inicial.


En la Figura 2.9 se puede observar que se realizó una base de datos para cada gas de emisión presente en el estudio, además de que cada gas tiene una base de datos de las 5 pruebas elaboradas, asimismo cada prueba contiene 16 muestras, las cuales tienen una cantidad de 50 datos cada una.

### 2.7.2. *Obtención de la base de datos simplificada*

El uso masivo y directo de toda la información que se posee no es adecuado para el aprendizaje autónomo. Por lo tanto, se optó por simplificar los datos mediante técnicas estadísticas. Este proceso de simplificación pretende mejorar la eficacia del aprendizaje automático por clasificación, asegurando que las variables resultantes sean más representativas de las características específicas de cada conjunto de datos. Además, esta simplificación ayuda a compilar la información de cada gas de emisión en una base de datos única.


#### 2.7.2.1. **Importación de datos en MATLAB®**

MATLAB® es un programa que puede importar y procesar los datos con extensión “xlsx”, ya que dentro del programa dichos archivos pueden ser transformados en tablas o matrices según sea necesario. Para realizar la importación de la base de datos se debe utilizar la herramienta de importación que presenta MATLAB® en el apartado “Variable” como se evidencia en la Figura 2.10.



**Figura 2.10** Sección de MATLAB® para importar archivos y datos.

Luego se procede a abrir el archivo con extensión “xlsx”, aquí se encuentran opciones como la selección del rango de datos y la salida del archivo, misma que puede ser una tabla o una matriz, en este caso se requirió de una salida de tipo tabla como la Figura 2.11.



**Figura 2.11** Opciones de importación en MATLAB®.

### 2.7.2.2. Código para crear la base de datos simplificada

En ese sentido, como ya se determinó las medidas estadísticas y exportado la información se procede a elaborar un código en Matlab que permita la obtención de dichas medidas para cada una de las pruebas. El código que permite obtener las medidas estadísticas de una muestra se observa en la Figura 2.12.

```
>> Datos=[IBZEM9002]; % Aquí se ingresa el nombre del archivo.xlsx importado.
Media=mean(Datos);
Mediana=median(Datos);
Moda=mode(Datos);
Maximo=max(Datos);
Minimo=min(Datos);
Rango=range(Datos);
Varianza=var(Datos);
Desviacion_estandar=std(Datos);
Coeficiente_variacion=(Desviacion_estandar./Media).*100;
Curtosis=kurtosis(Datos);
Asimetria=skewness(Datos);

Tablal=table(Media,Mediana,Moda, Maximo,Minimo,Rango,Varianza,Desviacion_estandar,Coeficiente_variacion, Curtosis,Asimetria);
disp("Procesamiento de valores");
disp(Tablal);
```

**Figura 2.12** Código en MATLAB® para simplificar datos de una muestra.

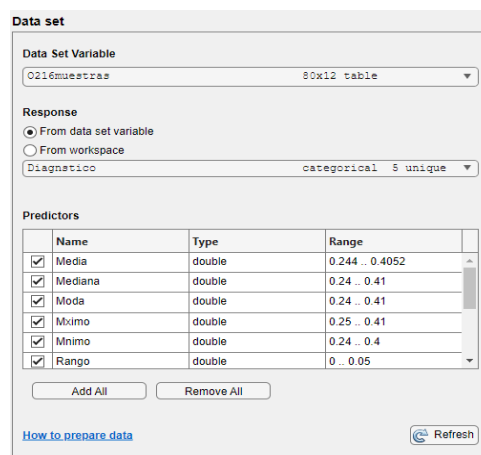
El código presentado en la Figura 2.12 se aplicó a las 16 muestras de cada ensayo asociado con el gas elegido. Posteriormente, los resultados se clasificaron y etiquetaron según la codificación correspondiente a cada prueba. Esta información se organizó en una tabla que incluye las siguientes medidas: media aritmética, mediana, moda, rango, varianza, desviación estándar, coeficiente de variación, asimetría y curtosis. Para más detalles, consulte el Anexo 3.

## 2.8. APLICACIÓN DE “MACHINE LEARNING” POR CLASIFICACIÓN

En este estudio, se aplicó Machine Learning de tipo clasificación en MATLAB® mediante la herramienta “Classification Learner”, parte del apartado “Machine learning and

deep learning". A diferencia de la regresión que predice valores, la clasificación asigna etiquetas o diagnósticos a diferentes características de una muestra.


Este es un enfoque de aprendizaje supervisado que requiere datos previamente etiquetados para realizar clasificaciones precisas. El software emplea términos como "respuestas" para referirse a las etiquetas, que en este caso son diagnósticos basados en cinco pruebas de motor, y utiliza 11 medidas estadísticas como "predictores" para diferenciar cada muestra, como se observa en la Figura 2.13.



**Figura 2.13** Preparación de los datos para el aprendizaje autónomo supervisado

### 2.8.1. Esquema de validación

Para el estudio, se seleccionó un método de validación después de recopilar los datos, con el fin de evaluar la precisión del modelo de Machine Learning y su capacidad para adaptarse a nuevos datos. Se consideraron tres esquemas de validación: Cross-Validation, Holdout Validation y Resubstitution Validation. El elegido fue Cross-Validation, preferido por su efectividad en prevenir el sobreajuste y por su adaptabilidad a datos nuevos. Este método divide el conjunto de datos en varias particiones, entrenando y evaluando cada una individualmente, lo que permite calcular un error de validación medio. Este proceso asegura una evaluación más rigurosa y es ideal para bases de datos no excesivamente grandes.




**Figura 2.14** Selección del esquema de validación del modelo.

La Figura 2.14 muestra que se usaron 5 particiones para validar el modelo, acorde con la recomendación de Baciero (2020) de usar entre 5 y 10 particiones, a menos que la base de datos sea muy grande o el sistema complejo. En este caso, debido a la simplificación de la base de datos, se optó por solo 5 particiones.

### **2.8.2. Selección del árbol de decisión**

Tras definir las variables relevantes, se procede a entrenar el modelo de clasificación utilizando árboles de decisión, que son eficientes en ajustes y predicciones al dividir la información en subconjuntos. El software proporciona tres tipos de árboles: grueso (4 divisiones), mediano (hasta 20 divisiones) y fino (hasta 100 divisiones), variando en flexibilidad y facilidad de interpretación según el número de divisiones.


Un árbol con muchas ramificaciones es preciso pero propenso al sobreentrenamiento, mientras que uno con pocas hojas es menos preciso, pero más interpretable. Se recomienda experimentar con todos los tipos para encontrar la configuración óptima del modelo.



**Figura 2.15** Tipos de árbol de decisión que el programa ofrece

### 2.8.3. *Obtención de la ecuación de predicción*

La aplicación de "machine learning" por clasificación tiene como objetivo crear un modelo que pueda predecir y clasificar nuevos datos. MATLAB® facilita esto mediante una función llamada "Export Model", usada después de entrenar el modelo con una base de datos. Esta función permite exportar el modelo desarrollado para su uso en futuras aplicaciones o análisis. En el programa, hay tres formas de exportar el modelo a la hoja de comandos, mostradas en la Figura 2.16. Estas son: exportación completa, compacta y experimental, cada una aplicando diferentes métodos para ajustar el modelo.



**Figura 2.16** Opciones de exportación en la aplicación "Classification Learner"

La opción de exportación completa se destaca por ser la más adecuada en este contexto, especialmente porque MATLAB® indica que esta modalidad es óptima para realizar predicciones con nuevos datos. Al elegir la exportación completa, se asegura que el modelo exportado esté totalmente equipado y listo para abordar eficientemente la tarea de predecir nuevos conjuntos de datos, manteniendo la integridad y la funcionalidad del sistema. El resultado de tal exportación se refleja en la información detallada en la Figura 2.17.

```
Structure 'trainedModel' exported from Classification Learner.  
To make predictions on a new table, T:  
[yfit,scores] = trainedModel.predictFcn(T)  
For more information, see How to predict using an exported model.
```

**Figura 2.17** Ecuación generada por la exportación del modelo

La Figura 2.17 ilustra la ecuación “yfit = trainedModel.predictFcn(T)”, donde “T” representa los nuevos datos, “trainedModel” es el nombre de la variable que utiliza el modelo y “yfit” da el resultado de la categoría a la que pertenecen los datos nuevos. Para utilizar dicha ecuación se debe contener una tabla que contenga las variables o características que fueron utilizadas para entrenar el modelo. Destacando que no se utiliza el apartado que contiene las etiquetas, esto con el objetivo de que la función pueda clasificar dicha información. Cabe recalcar que la tabla debe ser exportada en MATLAB®, en este caso se utilizó los nuevos datos con el nombre “NewData” debido al código elaborado.

Luego se vuelve a escribir la ecuación que dio el Classification Learned y se reemplaza la “T” con el nombre de la tabla de datos “NewData”, se presiona “Enter” y se observa la clasificación que proporciona la función, como se muestra en la Figura 2.18.

```
>> yfit = trainedModel.predictFcn(NewData)  
  
yfit =  
  
categorical  
  
IBZBM90
```

**Figura 2.18** Resultado del uso de la ecuación con nuevos datos

Es importante mencionar que el resultado de la ecuación depende de que tan eficiente es el modelo, es decir depende de su porcentaje de validación en el entrenamiento.



## 2.9. MODIFICACIÓN DE LA FUNCIÓN DE CLASIFICACIÓN PARA EL SISTEMA

Para el diagnóstico predictivo de motores, es crucial tener una ecuación que clasifique y prediga datos en etiquetas predefinidas. Este proceso implica el uso de sistemas de aprendizaje autónomo capaces de reentrenarse con nueva información, mejorando así la precisión del modelo en futuras predicciones. En MATLAB®, la ecuación del “Classification Learner” se ajusta mediante la edición de la función de predicción usando “Generate Function”, permitiendo personalizar y actualizar el modelo. Para reentrenar el modelo, es esencial reemplazar referencias a “trainingData” por los nuevos datos, en este caso “DataEmissions”, y ajustar el nombre de la función de predicción si se ha guardado con un nombre específico. El reentrenamiento también requiere modificar la tabla “DataEmissions” añadiendo nueva información relevante, mejorando así la capacidad del modelo para realizar predicciones informadas.

## **CAPÍTULO III**

### **3. ANÁLISIS Y RESULTADOS**

Este capítulo describe cómo se creó una base de datos y se procesó con MATLAB® para desarrollar cuatro modelos de clasificación de gases de escape (O<sub>2</sub>, CO<sub>2</sub>, CO, NO<sub>x</sub>) usando aprendizaje autónomo para clasificar las características de los gases de escape en relación con los cinco estados del motor previamente definidos. Estos modelos identifican el estado del motor a partir de los gases, siendo útiles en control y monitoreo de motores diésel. Se presentan los resultados, evaluando la capacidad de clasificar con precisión las características de los gases en los modelos propuestos.

#### **3.1. PRUEBA PILOTO PARA LA SELECCIÓN DE LAS VARIABLES ESTADÍSTICAS**

En el estudio en cuestión, las variables analizadas corresponden a los porcentajes y valores de los gases de escape seleccionados, es así como las medidas estadísticas desempeñan un papel crucial en este análisis, ya que proporcionan una descripción detallada y representativa de las características de estos gases. Mediante el uso de estadísticos descriptivos, como las medidas de tendencia central y dispersión, se logra resumir y comprender mejor el comportamiento de los porcentajes de los gases, facilitando así la interpretación de los datos y la toma de decisiones basada en evidencia sólida y comprensible.

Se llevó a cabo una prueba piloto utilizando una base de datos modesta, compuesta por 5 muestras de 50 datos correspondientes a dos estados del motor (IBZBMB e IDZDM90), con el objetivo de verificar la idoneidad de las variables seleccionadas para el aprendizaje autónomo.

La base de datos procesada utilizada en esta fase preliminar se detalla en el Anexo 11.1. En esta etapa, se puso especial atención en el análisis del gráfico de dispersión del “Classification Learner”, presentado en el Anexo 11.2, para examinar la dispersión de los datos en función de las variables designadas como "predictores". La selección de la media aritmética como variable principal para el eje X del gráfico se basó en su representatividad y facilidad de interpretación.

Los resultados obtenidos en la prueba piloto, enfocada en las emisiones de NOx y utilizando técnicas de aprendizaje autónomo, mostraron una clara distinción visual entre los dos estados del motor (IBZBMB en azul e IDZDM90 en naranja), facilitando la comparación de las emisiones bajo condiciones de análisis idénticas. El Anexo 11.2 resalta una dispersión de datos que sugiere una eficiente capacidad de clasificación del modelo con las variables estadísticas seleccionadas.

Además, el entrenamiento del modelo con estos datos alcanzó una validación del 100%, utilizando el método de validación de resubstitución, una técnica común en evaluaciones preliminares que resulta especialmente ventajosa en escenarios con bases de datos restringidas, permitiendo así identificar posibles insuficiencias en la información recopilada.

### **3.2 BASE DE DATOS PROCESADA**

La investigación analiza cuatro variables principales de gases de escape que son O<sub>2</sub>, NOx, CO y CO<sub>2</sub>, cada una con distintas unidades de medida. Debido a la diversidad en las medidas, fue necesario crear bases de datos separadas para cada tipo de emisión, con etiquetas específicas para cada prueba, facilitando así el aprendizaje del algoritmo.

Cada tabla de gases de escape incluye 80 muestras, y presenta características estadísticas detalladas como media, mediana, moda, valores máximo y mínimo, rango, varianza, desviación estándar, coeficiente de variación, curtosis y asimetría. Adicionalmente,

una columna adicional en cada tabla contiene las etiquetas o “diagnósticos” de las pruebas, distribuyendo las filas en 16 categorías según la codificación de cada prueba.

### **3.2.1 Oxígeno ( $O_2$ )**

El análisis de las muestras de  $O_2$  del Anexo 10.1 revela una alta similitud entre los valores, operando en un rango estrecho de 0,2 a 0,4% con varianza casi nula, lo que dificulta distinguir diferencias significativas. La mayoría de las muestras presentan valores positivos pequeños, en el orden de  $10^{-5}$  o  $10^{-6}$ .

En cuanto a la asimetría, se observa una diferencia clara entre los diferentes estados del motor. Los datos del motor en buen estado (IBZBMB) muestran un sesgo hacia valores más bajos, mientras que en condiciones defectuosas (IDZDM90) el sesgo es hacia valores más altos. Aunque estas diferencias son notables, es importante reconocer una limitación del modelo de aprendizaje automático: basándose en las emisiones de  $O_2$ , podría haber riesgos de diagnósticos erróneos debido a la mínima diferencia entre los conjuntos de datos.

### **3.2.2 Óxidos de nitrógeno (NOX)**

En el Anexo 10.2, dedicado a las emisiones de  $NO_x$ , se destacan diferencias significativas entre las pruebas al analizar estadísticas como promedios, medias, modas, y valores extremos, mostrando que operan en distintos intervalos. Un contraste marcado se observa entre los resultados de la prueba IBZBM90, relacionada con el MAF, y la prueba IDZDM90, que refleja el mal estado de todos los componentes.

Este contraste se evidencia en las diferencias en las métricas de promedio, máximo y mínimo, con una disparidad cercana a las 100 unidades de ppm. Además, la comparación del rango de valores indica una mayor amplitud entre los valores máximos y mínimos en la prueba IDZDM90, donde frecuentemente se superan los 10 ppm, en contraste con la prueba IBZBM90, donde los valores raramente exceden ese límite.

Al comparar las pruebas con motores en buen estado (IBZBMB) y con solo inyectores defectuosos (IDZBMB), se hallan similitudes en promedios y rangos, lo que representa un desafío para el aprendizaje automático. Sin embargo, este desafío podría abordarse a través del análisis de la asimetría y la curtosis de los datos.

### **3.2.3 Monóxido de carbono (CO)**

En las pruebas donde los inyectores están en buen estado (IBZBMB, IBZBM90 e IBZDMB), las muestras registran un 0,1% de CO en su mayoría. Sin embargo, en pruebas con inyectores defectuosos, varias muestras tienen valores inferiores al 0,09%, y pocas alcanzan el 0,1%. Además, en las pruebas sin fallas de inyectores, el valor más común (moda) es 0%, mientras que, en pruebas con inyectores defectuosos, el 0% nunca es la moda, presente en el Anexo 10.3.

La varianza, que mide cuánto varían los datos, es similar en todas las pruebas, pero es menor en las pruebas con inyectores defectuosos. Esto indica que los valores están más agrupados alrededor del promedio en estas pruebas.

Es importante destacar que en las tres primeras pruebas muestran asimetría positiva, sugiriendo que los valores más altos son más comunes. En contraste, la prueba IDZDM90 presenta asimetría negativa. Sin embargo, es necesario realizar comparaciones con la medida de curtosis para validar la distribución de los datos.

A pesar de estas observaciones, es posible que el análisis realizado por un sistema de aprendizaje automático supervisado genere diagnósticos incorrectos debido a las similitudes en las mediciones, particularmente en las tres primeras pruebas. Esto conduce a aprendizajes erróneos durante el proceso de entrenamiento del modelo.

### **3.2.4 Dióxido de carbono (CO<sub>2</sub>)**

Al analizar los datos de media, mediana y moda del CO<sub>2</sub> (Anexo 10.4), hay similitudes notables en todas las pruebas, con valores fluctuando entre el 1,6% y el 1,8%. Esta uniformidad sugiere que hay pocas variaciones entre las muestras.

No obstante, es importante subrayar que, debido a la notable similitud de esta base de datos en todas las pruebas, existe el riesgo de que el modelo de entrenamiento pueda generar diagnósticos incorrectos, lo que podría resultar en eficiencias de entrenamiento por debajo de las expectativas.

## **3.3 ENTRENAMIENTO DE CADA GAS POR ALGORITMO DE CLASIFICACIÓN**

Este apartado evalúa la eficacia de las estrategias de entrenamiento en aprendizaje automático, utilizando datos detallados en la sección 3.2. La revisión busca identificar las técnicas más efectivas y los desafíos en cada sistema, aportando una comprensión más profunda de las metodologías de entrenamiento. Los modelos de clasificación se entrenaron en MATLAB® con datos presentes en el Anexo 10, además se explicarán más a detalle los modelos con eficiencias superiores al 50%.

### **3.3.1. Entrenamiento basado en emisiones de O<sub>2</sub>**

Para este entrenamiento se utilizaron los datos procesados que se encuentran en el Anexo 10.1, en este entrenamiento se tomó en cuenta a todas las 5 pruebas presentes en dicha tabla para realizar un análisis holístico y determinar qué tan eficiente es un modelo a partir de las emisiones de O<sub>2</sub> en el motor. Este modelo tuvo una precisión baja debido a su porcentaje de validación del 41.2%, lo que sugiere que su capacidad predictiva es menos efectiva que una elección aleatoria.

### 3.3.2. Entrenamiento basado en emisiones de NOX

Durante esta fase de entrenamiento, se emplearon los datos procesados que se encuentran en el Anexo 10.2. En este proceso de aprendizaje autónomo incluyó el análisis de las cinco pruebas seleccionadas, con el objetivo de evaluar exhaustivamente la eficacia de un modelo basado en las emisiones de NOx del motor.

#### A. Eficiencia del entrenamiento

☆ 2.1 Tree	Accuracy (Validation): 88.8%
Last change: Fine Tree	11/11 features
☆ 2.2 Tree	Accuracy (Validation): 88.8%
Last change: Medium Tree	11/11 features
☆ 2.3 Tree	Accuracy (Validation): 81.2%
Last change: Coarse Tree	11/11 features

**Figura 3.1** Selección del árbol de decisión para la prueba NOx

La Figura 3.1 muestra una notable mejora en el rendimiento del modelo de aprendizaje automático, alcanzando cerca del 90% de eficiencia, lo que refuerza su fiabilidad para diagnósticos automotrices donde la precisión es esencial.

Entre los modelos analizados, el árbol de decisión mediano fue elegido sobre el fino, debido a su similar eficiencia, pero con menor riesgo de sobreentrenamiento, asegurando mejor adaptabilidad a nuevos datos.

Esta elección equilibra precisión y capacidad de generalización, siendo crucial para mantener un modelo eficiente y flexible, capaz de responder correctamente a futuras variaciones o nuevos patrones de datos. La preferencia por el árbol mediano refleja un balance ideal entre complejidad y funcionalidad en el contexto del diagnóstico automotriz.

## B. Resultados gráficos del entrenamiento

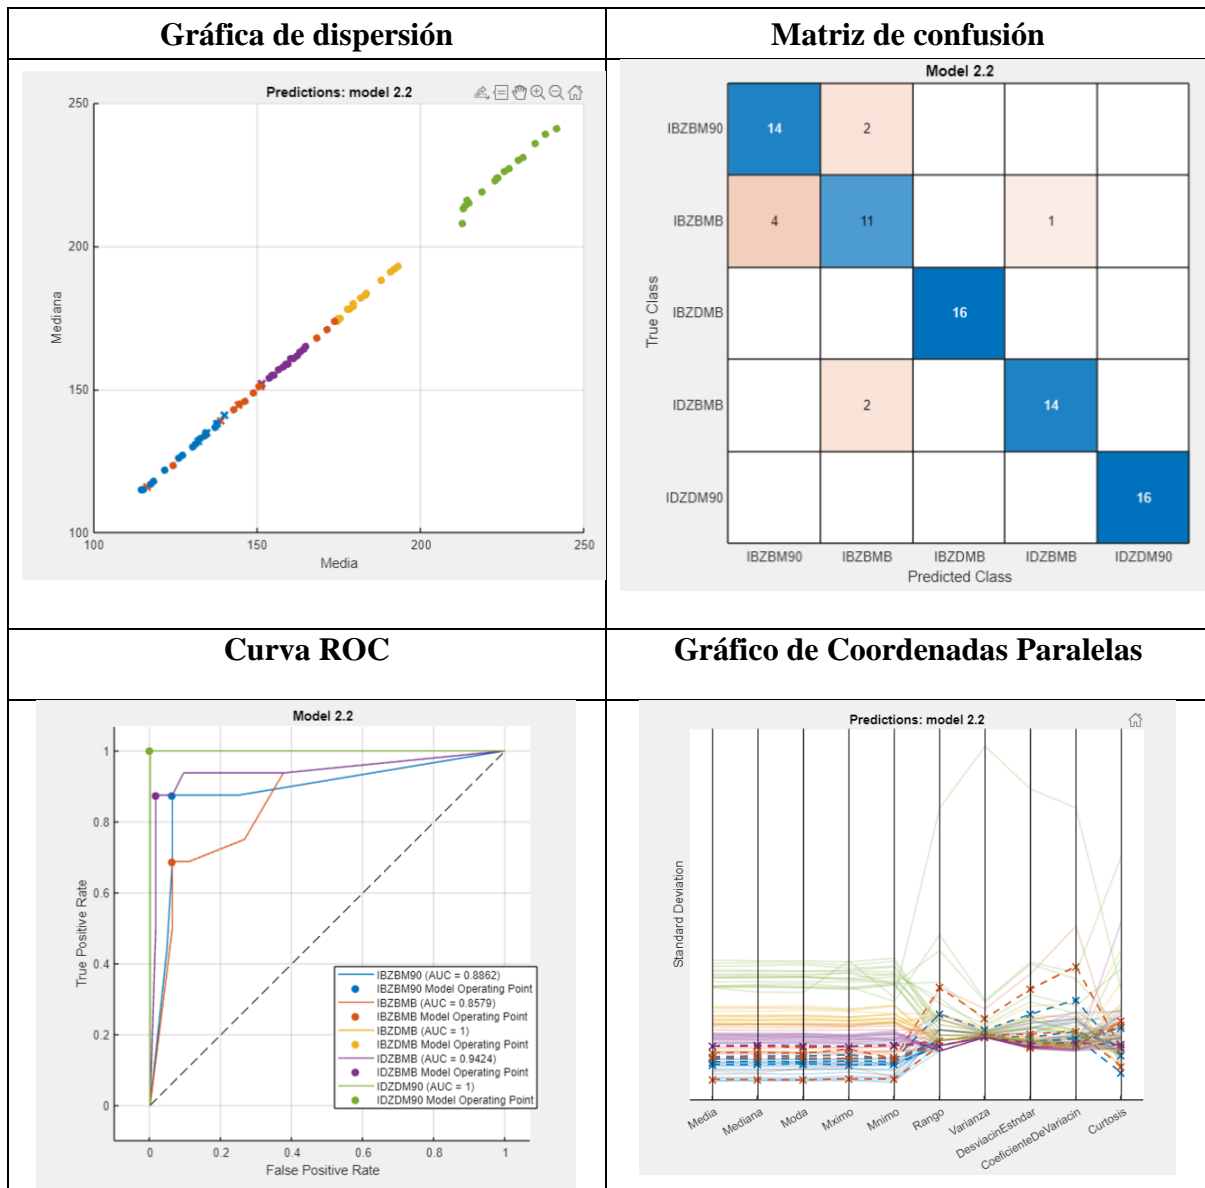


Figura 3.2 Resultados del entrenamiento basado en emisiones de NOx

## C. Análisis

La Figura 3.2 revela una mejora significativa en la organización de los datos en el gráfico de dispersión, con menos separaciones y mayor orden, excepto por algunos datos de la prueba IBZBMB (Naranja) que se mezclan ligeramente con otros, sin afectar considerablemente la eficiencia del modelo.



La matriz de confusión revela un elevado nivel de precisión, destacando particularmente en las pruebas IBZDMB e IDZDM90, donde se registran puntajes impecables. En el caso de las pruebas IDZBMB e IBZBM90, se observan 14 aciertos para cada una, cabe recalcar que en ambas se producen dos confusiones con la prueba que indica un estado óptimo (IBZBMB). Por otro lado, la prueba IBZBMB alcanza 11 aciertos, pero se confunde en cuatro ocasiones con la prueba de fallo en el MAF y una vez con la prueba de fallos en los inyectores.

En el gráfico de coordenadas paralelas, la mayoría de los datos siguen un camino consistente, con pocas líneas segmentadas y mínima desviación, demostrando que el modelo satisface ampliamente los requerimientos de la investigación.

### 3.3.3. Entrenamiento basado en emisiones de CO

En este entrenamiento se utilizaron los datos procesados que se encuentran en el Anexo 10.3, al igual como en los anteriores modelos se tomó en cuenta a todas las pruebas para realizar dicho entrenamiento, esto con el objetivo de determinar qué tan eficiente es un modelo a partir de únicamente las emisiones de CO.

#### A. Eficiencia del entrenamiento

Durante el entrenamiento del árbol de decisión se obtuvieron los siguientes resultados:


☆ 2.1 Tree	Accuracy (Validation): 51.2%
Last change: Fine Tree	11/11 features
☆ 2.2 Tree	Accuracy (Validation): 51.2%
Last change: Medium Tree	11/11 features
☆ 2.3 Tree	Accuracy (Validation): 45.0%
Last change: Coarse Tree	11/11 features

**Figura 3.3** Selección del árbol de decisión para la prueba de CO

La Figura 3.3 muestra que, aunque los árboles de decisión fino y mediano superan ligeramente el 50% en validación, este nivel de precisión no cumple con los altos estándares

requeridos en sistemas de diagnóstico automotriz. Es esencial mejorar o buscar alternativas para estos modelos para asegurar una predicción y clasificación de fallos del motor.

### B. Resultados gráficos del entrenamiento



**Figura 3.4** Resultados del entrenamiento basado en emisiones de CO

### C. Análisis

La Figura 3.4 indica que, en la gráfica de dispersión, los datos están desordenadamente dispersos y se mezclan entre diferentes pruebas, aumentando el riesgo de clasificaciones erróneas. La matriz de confusión revela que el modelo clasifica con mayor precisión las pruebas con inyectores dañados (IDZBMB e IDZDM90), errando en solo 5 muestras, pero falla

significativamente en clasificar correctamente pruebas en buen estado o con fallos específicos en el MAF (IBZBM90) y la ZME (IBZDMB), debido a la similitud en los datos.

La curva de ROC confirma esta tendencia, mostrando eficiencia en clasificar IDZBMB e IDZDM90 con resultados superiores a 0.8, mientras falla en otras pruebas, especialmente en IBZBM90. Aunque las curvas generalmente superan el 0.5, el diagrama de coordenadas paralelas destaca numerosos diagnósticos erróneos y sugiere una mejor clasificación en pruebas con inyectores defectuosos.

### 3.3.3. Entrenamiento basado en emisiones de CO<sub>2</sub>

Para el entrenamiento descrito en este caso, se emplearon los datos procesados del Anexo 10.4. Al igual que en modelos previos, se consideraron todas las pruebas disponibles para llevar a cabo el entrenamiento, con el fin de evaluar la eficacia de un modelo basado exclusivamente en las emisiones de CO.

#### A. Eficiencia del entrenamiento

En este entrenamiento basado en emisiones de CO<sub>2</sub> se obtuvieron los siguientes resultados para los árboles de decisión:

☆ 2.1 Tree	Accuracy (Validation): 52.5%
Last change: Fine Tree	11/11 features
☆ 2.2 Tree	Accuracy (Validation): 52.5%
Last change: Medium Tree	11/11 features
☆ 2.3 Tree	Accuracy (Validation): 55.0%
Last change: Coarse Tree	11/11 features

**Figura 3.5** Selección del árbol de decisión para la prueba con CO<sub>2</sub>

Como se evidencia en la Figura 3.5 la validación del modelo de aprendizaje autónomo basado en emisiones de CO<sub>2</sub>, que utiliza un árbol de decisión grueso, alcanza solo un 55%, un valor insuficiente para garantizar la fiabilidad requerida en un sistema de diagnóstico predictivo automotriz.

## B. Resultados gráficos del entrenamiento

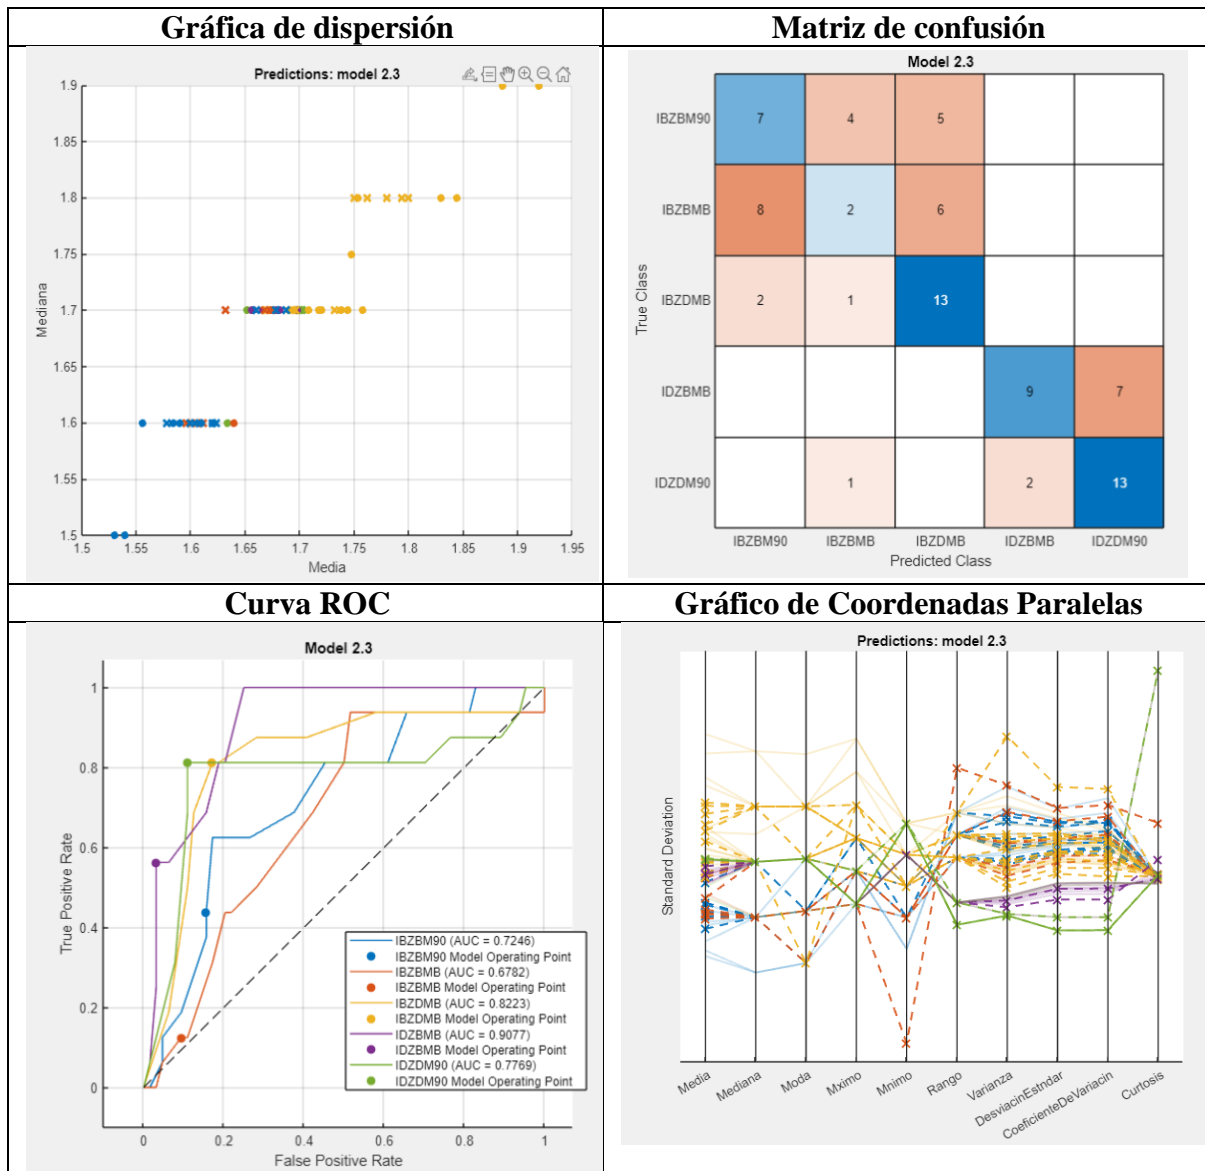


Figura 3.6 Resultados del entrenamiento basado en emisiones de CO<sub>2</sub>.

## C. Análisis

La Figura 3.6 muestra que, en la gráfica de dispersión de CO<sub>2</sub>, la mayoría de los datos están agrupados en el eje x, indicando similitudes entre las diferentes pruebas y posibles clasificaciones erróneas, aunque la prueba IDZBMB se destaca por su separación de los demás. En la matriz de confusión, las pruebas IBZDMB e IDZDM90 muestran mejor clasificación, en especial IBZDMB con más aciertos y menos errores, mientras que las pruebas en buen estado y con fallos en el MAF presentan significativos errores de clasificación.

La curva de ROC revela eficiencia en las pruebas con fallas en inyectores y ZME, con valores de AUC superiores a 0,8, pero dificultades en las pruebas en buen estado, aunque todas las curvas superan el 0,5. Finalmente, el diagrama de coordenadas paralelas evidencia numerosos diagnósticos erróneos, particularmente en la prueba IBZBMB, mientras que las pruebas con fallas siguen un patrón más claro en la clasificación.

#### ***3.3.4. Entrenamiento de un modelo integral de emisiones***

Los gases de escape seleccionados operan en porcentajes y medidas distintas, por ese motivo se optó por considerar realizar un modelo para cada emisión, además también se pudo determinar que existen modelos muy eficaces como es el caso del NOx que pueden llegar a un porcentaje de eficiencia del 88%. Sin embargo, los modelos que fueron poco eficientes si pudieron realizar algunas clasificaciones correctas y algunos superaron el 50% de eficiencia. En este sentido, se elaboró un modelo que emplee como características principales a los gases seleccionados para determinar si existe un aumento en la eficiencia de entrenamiento del modelo.

#### ***3.3.5. Determinación de la variable estadística clave para el entrenamiento integral***

Para realizar el entrenamiento de clasificación integral, se identificó una variable estadística clave que transforma los gases de escape en predictores eficientes. Este enfoque llevó a realizar 11 entrenamientos distintos, cada uno centrado en una medida estadística diferente.

Los resultados, detallados en la Tabla 3.1, ofrecen una comparativa del impacto de cada variable en el rendimiento del modelo, permitiendo evaluar la eficacia de las técnicas usadas y detectar áreas de mejora. Esta tabla es crucial para entender el avance del modelo y guiar futuras decisiones en el perfeccionamiento del aprendizaje automático.

**Tabla 3.1.** Eficiencia del entrenamiento de cada variable estadística.

<b>Medida estadística</b>	<b>Eficiencia del entrenamiento (%)</b>	<b>Árbol de decisión</b>
Media aritmética	93,8	Árbol fino y mediano
Mediana	92,5	Árbol fino y mediano
Moda	92,5	Árbol fino y mediano
Máximo	90,0	Árbol fino y mediano
Mínimo	87,5	Árbol fino y mediano

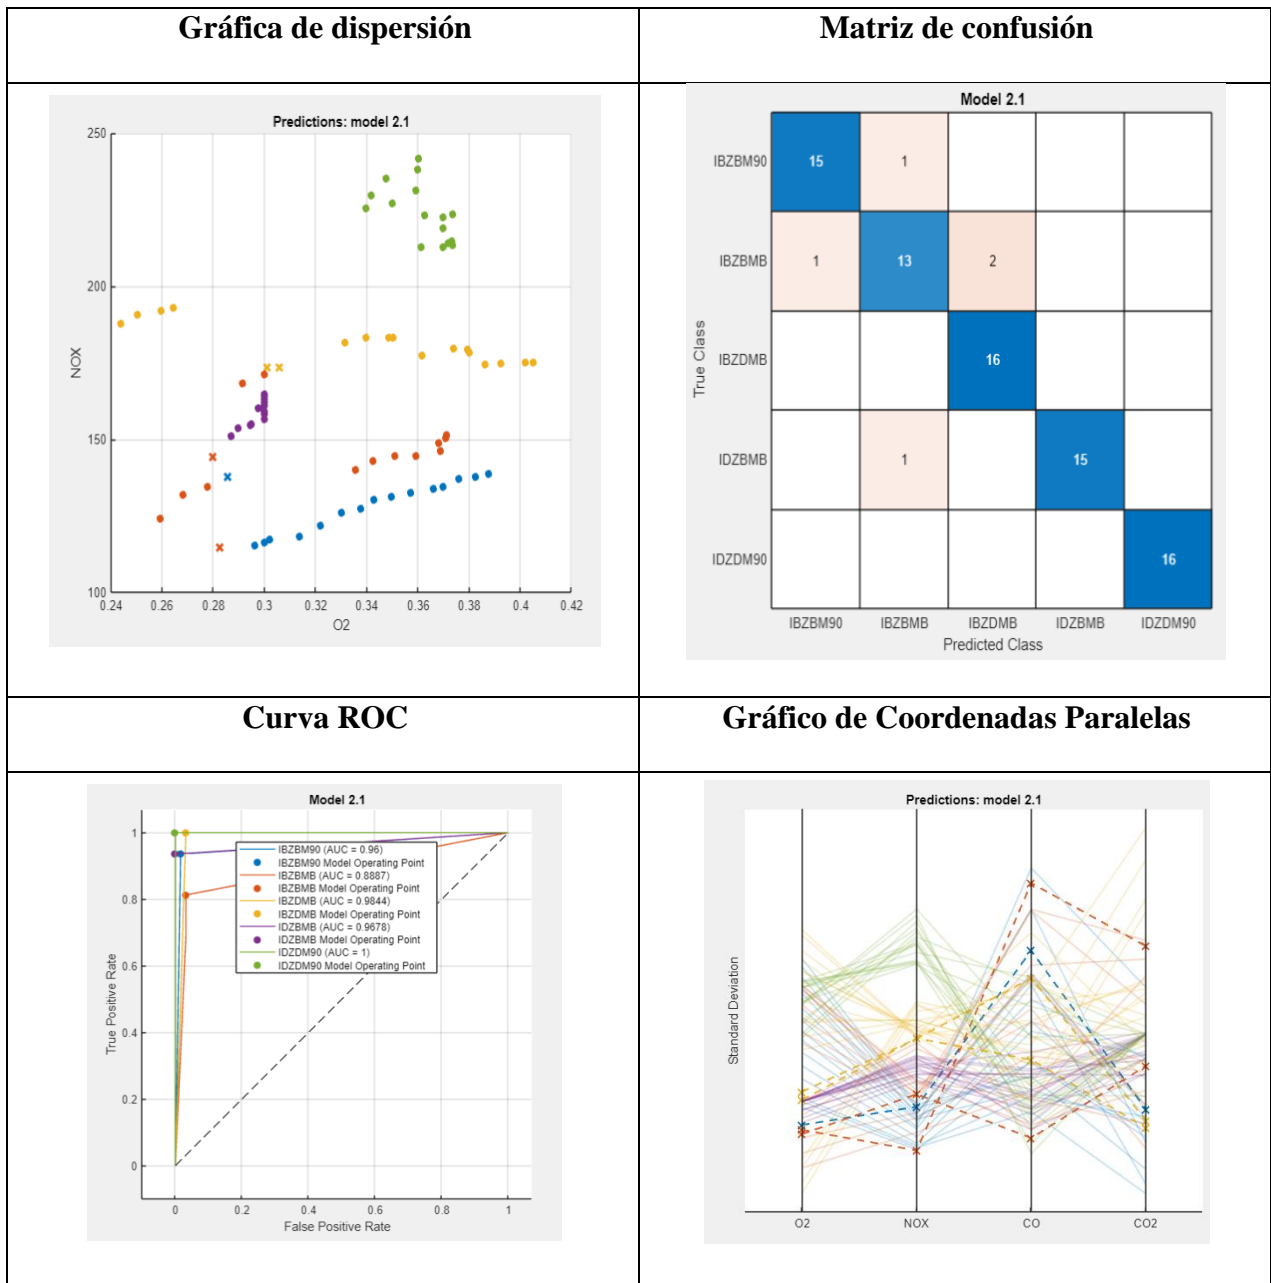
  

<b>Medida estadística</b>	<b>Eficiencia del entrenamiento (%)</b>	<b>Árbol de decisión</b>
Rango	53,8	Árbol grueso
Varianza	48,8	Árbol fino y mediano
Desviación estándar	41,2	Árbol grueso
Coefficiente de variación	53,8	Árbol fino y mediano
Curtosis	42,5	Árbol fino y mediano
Asimetría	36,2	Árbol fino y mediano

Como se puede evidenciar en la Tabla 3.1, el modelo integral que emplea como variable estándar a la media aritmética tiene el porcentaje de validación más alto, alcanzando un 93.8% de eficiencia, por tal motivo se usara dicha variable para realizar el modelo integral.

#### **A. Resultados del entrenamiento del modelo integral de emisiones**

En este apartado se analiza el modelo integral de gases de escape con la medida estadística de la media aritmética.



**Figura 3.7** Resultados del entrenamiento integral

## B. Análisis

La Figura 3.7 muestra en su gráfica de dispersión que el modelo integral presenta datos más dispersos con rangos definidos, aunque hay intersecciones leves, especialmente notables en la prueba IBZBMB. La matriz de confusión muestra un rendimiento de clasificación casi óptimo en las pruebas IBZDMB e IDZDM90, con la mayoría de los errores concentrados en la prueba IBZBMB. Esta última fue incorrectamente clasificada en tres ocasiones: una en los casos de fallo de MAF y dos en los de fallo de ZME. Además, la prueba IBZBM90, que

corresponde a fallos en MAF, fue incorrectamente clasificada en una ocasión, confundiéndose con una prueba en la que todos los componentes funcionaban correctamente. De manera similar, la prueba IDZBMB, asociada a inyectores defectuosos, fue erróneamente clasificada como si todos los elementos estuvieran en óptimas condiciones. A pesar de estos errores, la clasificación fue precisa en 75 de los 80 casos evaluados.

La curva de ROC refuerza esta eficiencia, mostrando altos valores en las pruebas IDZDM90 e IBZDMB, seguidos por IDZBMB e IBZBM90, y un rendimiento algo menor en IBZBMB. El gráfico de coordenadas paralelas revela solo 5 errores de clasificación, indicando una adecuada precisión del modelo a pesar de estos fallos.

### 3.4. SELECCIÓN DE LOS MODELOS PARA EL SISTEMA DE MACHINE LEARNING

La Tabla 3.2 resume los resultados obtenidos de los cinco modelos realizados previamente.

**Tabla 3.2.** Eficiencia del entrenamiento en todos los modelos de predicción

<b>Modelo de predicción</b>	<b>Porcentaje de validación (%)</b>
Basado en emisiones de O <sub>2</sub>	41,2
Basado en emisiones de CO	51,2
Basado en emisiones de CO <sub>2</sub>	55,0
Basado en emisiones de NO <sub>x</sub>	88,8
Integral de emisiones	93,8

De acuerdo con la información que se muestra en la Tabla 3.2, se evidencia que el modelo basado únicamente en NO<sub>x</sub> y el modelo integral de emisiones presentan porcentajes de 88.8 y 93.8% respectivamente. Esto quiere decir que el programa en dichos modelos pudo



clasificar correctamente un porcentaje de muestras superior al 80%, por tal motivo, se considera que esos sistemas pueden generar predicciones correctas en la investigación.

### 3.4.1. Función de predicción del modelo basado en emisiones de NOX

Cuando se exporta la ecuación de predicción relacionada con las emisiones de NOx, se obtiene un código en el espacio de trabajo, como se ilustra en la Figura 3.8 a continuación:

```
SISTEMA PARA EL DIAGNÓSTICO PREDICTIVO DE UN MOTOR DIÉSEL EN BASE A NOX
Unrecognized function or variable 'Emisiones'.

Structure 'ModeloNOX' exported from Classification Learner.
To make predictions on a new table, T:
[yfit,scores] = ModeloNOX.predictFcn(T)
For more information, see How to predict using an exported model.
```

**Figura 3.8** Respuesta del software al exportar el modelo de NOx.

En la figura anterior, se describe la función que se debe utilizar para llevar a cabo las predicciones, la cual es la siguiente:

(10)

$$yfit = ModeloNOX.predictFcn(T)$$

Donde:

- Yfit = Predicción
- ModeloNOX = Modelo entrenado con la base de datos de emisiones de NOx
- predictFcn = Es la función que emplea el modelo para realizar la predicción de nuevos datos
- T = Nueva tabla de datos (muestra para clasificar).

Para lograr que la función pueda predecir una muestra se debe alterar únicamente la variable “T” por los datos que se desean clasificar, cabe recalcar que la función puede servir cuando se utiliza una tabla de datos que contenga todas las características estadísticas que se utilizaron durante el entrenamiento del modelo. En este caso la tabla de datos debe contener

los valores de la media, mediana, moda, máximo, mínimo, rango, varianza, desviación estándar, coeficiente de variación, curtosis y asimetría.

Con el fin de establecer dicha tabla “T” con una muestra de emisiones de NOx sin procesar se emplea el siguiente código:

```
>> clc;

disp('SISTEMA PARA EL DIAGNÓSTICO PREDICTIVO DE UN MOTOR DIÉSEL EN BASE A NOX');

Datos=[Emisiones]; % Aquí se ingresa el nombre del archivo.xlsx importado.

Media=mean(Datos);
Mediana=median(Datos);
Moda=mode(Datos);
Maximo=max(Datos);
Minimo=min(Datos);
Rango=range(Datos);
Varianza=var(Datos);
Desviacion_estandar= std(Datos);
Coeficiente_variacion=(Desviacion_estandar./Media).*100;
Curtosis=kurtosis(Datos);
Asimetria=skewness(Datos);

Tablal=table(Media,Mediana,Moda, Maximo,Minimo,Rango,Varianza,Desviacion_estandar,Coeficiente_variacion, Curtosis,Asimetria);
disp("Procesamiento de valores");
disp(Tablal);
```

**Figura 3.9** Código para obtener la tabla de datos “T” para el modelo basado en NOx

Como se evidencia en la Figura 3.9, se requiere de un archivo de extensión “xlsx” que se encuentre importado en el espacio de MATLAB®, este archivo debe contener los datos de NOx ordenados en una única columna.

### 3.4.2. Función de predicción del modelo integral de emisiones

Al momento de exportar el modelo de sistema predictivo basado en todos los gases de escape aparece el siguiente texto en el espacio de MATLAB®:

```
Structure 'ModeloIntegral' exported from Classification Learner.
To make predictions on a new table, T:
    [yfit,scores] = ModeloIntegral.predictFcn(T)
For more information, see How to predict using an exported model.
```

**Figura 3.10** Respuesta del software al exportar el modelo integral

En la Figura 3.10 se explica que la función para realizar predicciones es la siguiente:

$$y_{fit} = \text{ModeloIntegral.predictFcn}(T)$$

Donde:

- $Y_{fit}$  = Predicción
- ModeloIntegral = Modelo entrenado con la base de datos integral de emisiones
- predictFcn = Es la función que emplea el modelo para realizar la predicción de nuevos datos
- T = Nueva tabla de datos (muestra para clasificar).

Los datos T deben contener las cuatro características que se utilizaron durante el entrenamiento, es decir, la media aritmética del O<sub>2</sub>, NO<sub>x</sub>, CO y CO<sub>2</sub>. A fin de obtener dicha tabla de manera automática en el programa se usó el siguiente código:

```
>> clc;

disp('SISTEMA PARA EL DIAGNÓSTICO PREDICTIVO DE UN MOTOR DIÉSEL EN BASE A GASES DE ESCAPE');

Datos=[Emisiones]; % Aquí se ingresa el nombre del archivo.xlsx importado.

Media=mean(Datos);

disp("Procesamiento de valores");
disp(Media);
```

**Figura 3.11** Código para obtener la tabla de datos “T” para el modelo integral

El código representado en la Figura 3.11, requiere de un archivo con extensión “xlsx” que se encuentre en el espacio de MATLAB, es importante mencionar que dicha tabla de entrada debe contener cuatro columnas referentes a los cuatro gases de escape seleccionados en el estudio, además estos datos necesitan estar ordenados de la siguiente manera: O<sub>2</sub>, NO<sub>x</sub>, CO y CO<sub>2</sub>.

### 3.5. VALIDACIÓN DEL SISTEMA DE DIAGNÓSTICO PREDICTIVO

Validar un modelo con datos independientes permite evaluar su capacidad de clasificación y detectar posibles problemas de sobreajuste, además esta validación proporciona una evaluación imparcial y realista de su eficacia, asegurando que pueda cumplir su propósito en el contexto de nuestra investigación.

Para ese propósito, se empleó una base de datos externa que constaba de 4000 datos. Esta base de datos se dividió equitativamente entre las cinco pruebas seleccionadas, es decir, cada prueba disponía de 800 datos. En cada una de esas pruebas, se crearon 16 conjuntos de datos, cada uno de ellos compuesto por 50 datos. Es importante destacar que esos datos no fueron utilizados durante el proceso de entrenamiento de los modelos.

#### 3.5.1. Modelo basado en emisiones de NOX

Este modelo, basado en emisiones de NOx, demostró un rendimiento variable en las cinco pruebas diseñadas para evaluar su capacidad de clasificación. A continuación, se presenta la Tabla 3.4, que muestra los resultados de este proceso:

**Tabla 3.3.** Eficiencia del entrenamiento en el modelo de predicción basado en NOx.

N° de prueba	Cantidad de muestras	Categoría que se espera obtener	Clasificaciones correctas	Clasificaciones erróneas	Validez (%)	Validez del modelo (%)
1		IDZDM90	16	0	100	
2		IDZBMB	0	16	0	
3	16	IBZDMB	8	8	50	50
4		IBZBMB	12	4	75	
5		IBZBM90	4	12	25	

La Tabla 3.3 muestra resultados variados en la clasificación de distintas condiciones del motor en una investigación sobre emisiones de NOx. La prueba 1 (IDZDM90), simulando múltiples fallos, tuvo un desempeño perfecto con un 100% de clasificación correcta. La prueba 2 (IDZBMB), con inyectores defectuosos, no logró clasificar correctamente ningún caso. En la prueba 3 (IBZBMB), centrada en la ZME dañada, el sistema tuvo un 50% de precisión. La prueba 4 (IBZBMB), evaluando un motor en buen estado, alcanzó un 75% de precisión, mientras que la prueba 5 (IBZBM90), con un sensor MAF defectuoso, solo tuvo un 25% de éxito. En general, el modelo mostró un rendimiento medio del 50%, indicando la necesidad de mejoras para un diagnóstico predictivo más preciso de los estados y problemas del motor diésel, especialmente en el contexto de las emisiones de NOx.

### 3.5.2. Modelo integral de emisiones

El segundo modelo de aprendizaje automático, enfocado en las emisiones de O<sub>2</sub>, NOx, CO y CO<sub>2</sub>, mostró un desempeño general con un 67,5% de validez en la validación. Este se sometió a las mismas cinco pruebas que el modelo anterior basado en emisiones de NOx. Los resultados específicos de cada prueba están detallados en la Tabla 3.4, proporcionando una visión clara del rendimiento del modelo en distintos escenarios.

**Tabla 3.4.** Eficiencia de entrenamiento del modelo integral de emisiones.

N° de prueba	Cantidad de muestras	Categoría que se espera obtener	Clasificaciones correctas	Clasificaciones erróneas	Validez (%)	Validez del modelo (%)
1		IDZDM90	16	0	100	
2		IDZBMB	11	5	68,75	
3	16	IBZDMB	8	8	50	67,5
4		IBZBMB	15	1	93,75	
5		IBZBM90	4	12	25	

El modelo basado en emisiones de O<sub>2</sub>, NO<sub>x</sub>, CO y CO<sub>2</sub> demostró un rendimiento variado en cinco pruebas diferentes. En la prueba 1 (IDZDM90), que simulaba múltiples fallos, el modelo alcanzó un 100% de precisión, destacando su capacidad para identificar problemas en inyectores, ZME y MAF. La prueba 2 (IDZBMB), centrada en inyectores defectuosos, logró un 68,75% de precisión. La prueba 3 (IBZBMB), evaluando la ZME dañada, obtuvo un 50% de clasificación correcta, mientras que la prueba 4 (IBZBMB), en un motor en buen estado, alcanzó un 93,75% de precisión. En la prueba 5 (IBZBM90), enfocada en un sensor MAF defectuoso, la precisión fue del 25%. Estos resultados indican un rendimiento generalmente sólido del modelo, con áreas de mejora en la identificación de problemas en la ZME y el sensor MAF, subrayando su utilidad en diagnósticos automotrices y la necesidad de optimización continua.

## CAPÍTULO IV

### 4. CONCLUSIONES Y RECOMENDACIONES

#### 4.1. CONCLUSIONES

En base a los resultados obtenidos en el presente estudio se puede concluir que:

- Los gases más importantes para este estudio deben estar relacionados con el funcionamiento del motor, en lugar de la calidad del combustible. Por lo tanto, se descartaron las emisiones de SO<sub>x</sub>, Pb, N<sub>2</sub> y H<sub>2</sub>O debido a su puntaje por debajo de 15 puntos en la matriz de decisión cualitativa. En cambio, se seleccionaron las emisiones de NO<sub>x</sub> (21 pts.), CO (20 pts.), CO<sub>2</sub> (17 pts.) y O<sub>2</sub> (16 pts.) debido a su impacto directo en el rendimiento del motor, la eficiencia de la combustión y su relación con fallas en los componentes del vehículo. Estos gases también comparten características con otras emisiones cruciales como el HC y PM, y algunas de ellas tienen implicaciones medioambientales y para la salud humana.
- Los sistemas de alimentación e inyección son clave en la eficiencia de la combustión y la emisión de gases en motores diésel. Las Fallas en los inyectores y en la válvula ZME afectan directamente estos procesos, donde inyectores defectuosos causan combustiones incompletas y emisiones de CO, HC y PM, mientras que problemas en la válvula ZME incrementan la producción de NO<sub>x</sub>. Además, se determinó que la manipulación de la señal en el sensor MAF a 4V, frente a los valores normales de 0,8 a 1,2V, incrementó la entrada de aire a 90 gr/s, afectando la mezcla aire-combustible.
- Tras evaluar detalladamente las variables estadísticas cuantitativas y enfocarnos en medidas de dispersión, forma y tendencia central, la prueba piloto con muestras de NO<sub>x</sub> representando dos estados del motor validó la relevancia de las variables seleccionadas al diferenciar claramente entre los estados del motor. Además, el entrenamiento preliminar

del modelo logró una validación del 100%, respaldando la base para el análisis completo en esta investigación.

- La utilización de dos bases de datos fue fundamental para desarrollar el sistema de diagnóstico predictivo de emisiones. Inicialmente, se recolectaron 4000 mediciones para cada uno de los 5 estados simulados. Sin embargo, al validar con una base de datos externa de igual tamaño, se encontraron discrepancias críticas. La precisión del modelo de NOx disminuyó en un 38,8%, y la del modelo integral de emisiones disminuyó en un 26,3% al probarlos con nuevos datos.
- En el procesamiento de datos para diagnóstico predictivo de motores diésel se determinó que el modelo más eficiente es el de NOx, con un 88.8% de rendimiento, destacando en la detección de fallos en todas las pruebas, con ligeros problemas para diagnosticar un MAF descompuesto. Adicionalmente, el modelo de media aritmética destacó con una eficiencia del 93,8%. Este modelo fue preciso en identificar pruebas donde todos los componentes fallan (IDZDM90) y en pruebas con fallas solo en el MAF (IBZDMB). Aunque hubo algunas clasificaciones incorrectas en pruebas de buen estado (IBZBMB), MAF defectuoso (IBZDMB) e inyectores defectuosos (IDZBMB).
- En el análisis de validación del modelo de diagnóstico basado en emisiones de NOx mostró un rendimiento mixto: 100% de precisión en pruebas con fallos en todos los componentes (IDZDM90), pero 0% en pruebas con inyectores defectuosos (IDZBMB). Obtuvo un 50% de precisión en pruebas de ZME defectuosa (IBZDMB) y un 75% en motores en buen estado (IBZBMB), aunque bajó a 25% en pruebas con sensor MAF dañado (IBZBM90).
- El modelo Integral, combinando O<sub>2</sub>, NOx, CO y CO<sub>2</sub>, también alcanzó un 100% en pruebas con fallos generales (IDZDM90), pero fue menos preciso en pruebas de ZME y MAF defectuosos, con 50% y 25% respectivamente. Aunque superó al modelo de NOx en identificar motores en buen estado (93,75%), su efectividad general fue del 67,5%, señalando la necesidad de mejorar en áreas específicas.



## 4.2. RECOMENDACIONES

- A pesar de descartar ciertas emisiones como SO<sub>x</sub>, Pb, N<sub>2</sub> y H<sub>2</sub>O, podría ser beneficioso reevaluar la inclusión de algunos de estos gases en futuras investigaciones. Esto se debe a que las emisiones desechadas pueden tener impactos indirectos en la eficiencia del motor.
- Se recomienda continuar explorando y posiblemente expandiendo el enfoque en las medidas de dispersión, forma y tendencia central, dado su impacto efectivo en el análisis de patrones y toma de decisiones en el diagnóstico de emisiones.
- Es crucial aumentar la diversidad y el tamaño de las bases de datos utilizadas para el entrenamiento y la validación de modelos. Esto ayudará a mejorar la precisión y la fiabilidad de los modelos en diferentes escenarios del mundo real.
- Continuar el desarrollo y refinamiento del modelo Integral, que combina diversas emisiones, para mejorar su habilidad en identificar fallos específicos en componentes, en especial en la válvula ZME y el sensor MAF.
- Se necesita expandir la investigación a la utilización de diferentes variedades de métodos y softwares para procesar los datos de gases de escape recogidos.
- Experimentar con técnicas innovadoras de aprendizaje autónomo y tecnologías de IA puede proporcionar enfoques más eficaces y novedosos en el análisis de datos.

## 5. REFERENCIAS BIBLIOGRÁFICAS

1. Apolon, V. (2021). Ventajas y Desventajas del Mantenimiento Preventivo en 2021. Obtenido de <https://www.mantenimientopreventivo.site/ejecucion/mantenimiento-preventivo-4-ventajas-y-2-desventajas/>
2. Ashok, B., Naresh, A., Jacob, A., & Vignesh, R. (2022). Chapter 1 - Emission formation in IC engines. En NOx Emission Control Technologies in Stationary and Automotive Internal Combustion Engines (págs. 1-38). B. Ashok.
3. ACEA, Auto Alliance, EMA & JAMA. (2019). Worldwide Harmonisation of Gasoline and Diesel Fuel. Obtenido de <https://www.acea.auto/publication/worldwide-fuel-charter-2019-gasoline-and-diesel-fuel/>
4. Adams, T. (2021). The origins and chemistry of diesel emissions in mining. Obtenido de <https://globalroadtechnology.com/the-origins-and-chemistry-of-diesel-emissions-in-mining/>
5. Appen. (2022). “machine learning” Model Validation – The Data-Centric Approach. Obtenido de <https://appen.com/blog/machine-learning-model-validation/#:~:text=The%20resubstitution%20validation%20method%20is,the%20gaps%20in%20your%20data.>
6. Aslan, I., Altinisik, K., & Keskin, A. (2015). The pollutant emissions from diesel-engine vehicles and exhaust aftertreatment systems. *Clean Techn Environ Policy*, 15-27.
7. Atecnea. (2021). “machine learning” con MATLAB (Tutorial BASICO). Obtenido de <https://www.youtube.com/watch?v=torhYoh10uU&list=PLyDzGuMm1rUE3tM8KjjoywR52r5GmA9bL>

8. Baciero, J. (2020). Elaboración de un Modelo de Reconocimiento de "Entidades Nominales" (NER) para su Uso en Aplicaciones de Procesamiento del Lenguaje Natural (NLP). Madrid: Universidad Politécnica de Madrid.
9. BESKO. (2019). DENOXTRONIC DIESEL SYSTEMER. Obtenido de [https://www.besko.dk/wp-content/uploads/2021/06/D-Nox\\_2019\\_Web.pdf](https://www.besko.dk/wp-content/uploads/2021/06/D-Nox_2019_Web.pdf)
10. Bentancourt & Flores (2018). Diagnóstico del aceite usado de motor de la empresa de transporte urbano LANCOMTRI S.A. [Tesis de grado, Universidad Politécnica Salesiana]. Recuperado de: <http://dspace.ups.edu.ec/handle/123456789/16816>
11. Bitta, P. (2022). Vehicle Management and Emission Control and Maintenance.
12. Bosch. (2018). High-pressure pump CPN6. Obtenido de <https://www.bosch-mobility-solutions.com/en/solutions/pumps/high-pressure-pump-cpn6/>
13. Bosch. (2019). Improved vision, safe journey. Truck World, 6.
14. BOSCH. (2020). FSA 740 – equipo de medición. Automotive Aftermarket España. <https://www.boschaftermarket.com/es/es/equipos-y-diagnosis/analisis/analisis-de-sistemas-del-veh%C3%ADculo/fsa-740-sin-kts-560>
15. Bosch. (2022). Bosch diesel system components. Karlsruhe.
16. Bosch, R. (2021). A Bosch Guide to Potential Causes of Common Rail Injector Failures. USA: BOSCH.
17. Bosch Contribuye Con Su Sistema Common Rail a Reducir Las Emisiones Contaminantes - Tecnología - Híbridos y Eléctricos | Coches Eléctricos, Híbridos Enchufables, n.d.
18. Cacuango Caranqui, J. A., & Ulcuango Ulcuango, J. S. (2022). Diseño de un sistema de mantenimiento predictivo automotriz basada en la industria 4.0. [Tesis de pregrado,

- Universidad Técnica del Norte]. Recuperado de <http://repositorio.utn.edu.ec/handle/123456789/11877>
19. Cangás Ortega, H. E. (2021). Gestión del mantenimiento vehicular a base del aprendizaje autónomo en motores de tractores agrícolas [Tesis de pregrado, Universidad Técnica del Norte]. Recuperado de <http://repositorio.utn.edu.ec/handle/123456789/11675>
  20. Castillo, J., Solórzano, B., & Moreno, J. (2018). Design of a Neural Network for the Prediction of the coefficient of Primary Losses in Turbulent Flow Regime. *Ingenius. Revista de Ciencia y Tecnología*, 21-27.
  21. Consejo de Ministros para la Sustentabilidad de Chile. (2016). Acuerdo N°7. Ministerio del Medio Ambiente.
  22. Coral, F. (2013). “Diseño e implementación de un banco de pruebas de inyectores de vehículos a diésel crdi para la escuela de ingeniería automotriz” [Escuela Superior Politécnica De Chimborazo]. <http://dspace.esoch.edu.ec/handle/123456789/2963>
  23. Costa, I. (2015). Estudio de la concentración de compuestos orgánicos volátiles, óxidos de nitrógeno y ozono en el núcleo urbano de la ciudad de Cartagena y evaluación de la exposición de la población. Universidad de Murcia.
  24. Cuesta, A., González, C., Velasco, M., & Aristízabal, B. (2018). Distribución espacial de concentraciones de nox y o3 en el aire ambiente de manizales. 489-504.
  25. DCCEEW. (2023). Emission Estimation Technique Manual for Aggregated Emissions from Motor Vehicles. Obtenido de <https://www.dcceew.gov.au/environment/protection/mpi/reporting/industry-reporting-materials/diffuse-emissions-manuals/emission-estimation-technique-manual-aggregated-emissions-motor-vehicles>

26. Deighton, M. (2016). Facility Integrity Management: Chapter 5 - Maintenance Management. Effective Principles and Practices for the Oil, Gas and Petrochemical Industries, 87-139.
27. Dobrzyńska, E., Szewczyńska, M., Posniak, M., Szczotkab, A., Puchałka, B., & Woodburnb, J. (2020). Emisiones de escape de motores diesel alimentados por diferentes mezclas con la adición de nanomodificadores y aceite vegetal hidrotratado HVO. Contaminación ambiental.
28. Donado, I. A. (2020). Tipos de herramientas para el Diagnóstico Automotriz. Autosoporte.com • Capacitación Automotriz; Autosoporte Capacitacion Automotriz. <https://autosoporte.com/tipos-de-herramientas-para-el-diagnostico-automotriz/>
29. Erbesd, T. (2021, junio 19). Principios Básicos de Análisis de Vibraciones & Monitoreo Continuo. ERBESSD INSTRUMENTS. <https://www.erbessd-instruments.com/es/articulos/analisis-de-vibraciones/>
30. Esic. (2022, mayo 25). Algoritmos matemáticos: qué son y nuestros ejemplos. Esic.edu; ESIC. <https://www.esic.edu/rethink/tecnologia/algoritmos-matematicos-que-es-y-ejemplos>
31. Farrow, A., Miller, K., Rolle, J., Céspedes, T., & Anhaeuser, A. (2021). Contaminación del aire por el tráfico vehicular. Bogotá, Colombia: Greenpeace Research Laboratories.
28. Fernández, D., Pérez, S., & Renedo, C. (2022). Termodinámica y Máquinas Térmicas. Creative Commons.
29. Frosina, E., Romagnuolo, L., Bonavolontà, A., Andreozzi, A., Senatore, A., Fortunato, F., & Giliberti, P. (2018). Evaporative emissions in a fuel tank of vehicles: numerical and temperature function for a long-term district heat demand forecast. 12-14.

30. Gao, K., Mei, G., Piccialli, F., Cuomo, S., Tu, J., & Huo, Z. (2020). Julia language in “machine learning”: Algorithms, applications, and open issues. *Computer Science Review*, 37(100254), 100254. <https://doi.org/10.1016/j.cosrev.2020.100254>
31. Gaskell, R. (2023). Bosch and Denso Fuel Injector Failure Prevention. Fleet Service Northwest.
32. GraphEverywhere. (2019). “machine learning”. GraphEverywhere; Graph Everywhere SL. <https://www.grapheverywhere.com/machine-learning-que-es-tipos-ejemplos-y-como-implementarlo/>
33. Greenpeace. (2019). La industria automotriz emite 9% de los GEI. EFE.
34. Guo, X., & Ha, K. D. (2020). Atmospheric Pressure Plasma for Diesel Particulate Matter Treatment: A Review. *A Review*. In *Catalysts*, 29.
35. Gómez, R., Franco, P., Allen, J., Tejeda, D., & Aguilar, J. (2009). Guía metodológica para la estimación de emisiones vehiculares en ciudades mexicanas. México.
36. Hunicz, J., Krzaczek, P., Gęca, M., Rybak, A., & Mikulski, M. (2021). Comparative study of combustion and emissions of diesel engine fuelled with FAME and HVO. Creative Commons.
37. INEN. (2016). Gestión ambiental. aire. vehículos automotores. límites permitidos de emisiones producidas por fuentes móviles terrestres que utilizan diesel. Quito. Obtenido de [https://www.normalizacion.gob.ec/buzon/normas/nte\\_inen\\_2207\\_2.pdf](https://www.normalizacion.gob.ec/buzon/normas/nte_inen_2207_2.pdf)
38. Instituto Ecuatoriano de Normalización, (2013). Gestión ambiental. aire. vehículos automotores. determinación de la opacidad de emisiones de escape de motores de diésel mediante la prueba estática. método de aceleración libre. <https://www.normalizacion.gob.ec/buzon/normas/2202-1.pdf>

39. Istrate, A., Bică, M., & Simion, M. (2020). Compression ignition engine - sources of pollution. IOP Conf. Series: Materials Science and Engineering 997. doi:10.1088/1757-899X/997/1/012148
40. Jääskeläinen, H. (2021). Efecto de emisión de fallas y servicio del motor. Obtenido de [https://dieselnet.com/tech/emissions\\_fault.php](https://dieselnet.com/tech/emissions_fault.php)
41. Jeevahan, J., Poovannan, A., Raj, D., Maghwaran, G., & Britto, J. (2017). Effect of intake air oxygen enrichment for improving engine performance and emissions control in diesel engine. Chennai, India: International Journal of Ambient Energy.
42. Juca, K. (2015). Identificación de espectros acústicos en motores de combustión interna a través del análisis en tiempos cortos [Universidad Politécnica Salesiana Sede Cuenca]. <https://dspace.ups.edu.ec/bitstream/123456789/8918/1/UPS-CT005159.pdf>
43. Khobragade, R., Kumar, S., Chandra, P., Gupta, T., Al-Fatesh, A., Kumar, A., & Labhasetwar, N. (2019). Chemical composition of diesel particulate matter and its control. Taylor & Francis.
44. Kittelson, D. (1998). Engines and nanoparticles: a review. *Journal of Aerosol Science*, 575-588.
45. Koten, H., Can, E., & Guner, K. (2018). Piezo-actuated common rail injector structure and efficient design. Istanbul: Journal of Energy Systems.
46. Kozak, M., & Merkisz, J. (2022). Oxygenated Diesel Fuels and Their Effect on PM Emissions. *Applied Sciences*.
47. Laskowski, P., Zasina, D., Zimakowska, M., Zawadzki, J., & Warchałowski, A. (2019). Vehicle Hydrocarbons' Emission Characteristics Determined Using the Monte Carlo Method. *Environmental Modeling & Assessment*, 311-318.

48. La industria automotriz emite 9% de los GEI: Greenpeace. (2019, septiembre 10). Manufactura. <https://manufactura.mx/automotriz/2019/09/10/la-industria-automotriz-emite-9-de-los-gei-greenpeace>
49. Lowe, D., Wu, W., & Tan, A. (2011). Experimentally induced diesel engine injector faults and some preliminary Acoustic Emission Signal Observations. Brisbane: QUT.
50. Marques, B., Kostenidou, E., Martinez, A., Vansevenant, B., Sarica, T., Fine, L., . . . D'Anna, B. (2022). Detailed Speciation of Non-Methane Volatile Organic Compounds in Exhaust Emissions from Diesel and Gasoline Euro 5 Vehicles Using Online and Offline Measurements. Toxics.
51. MathWorks. (24 de Febrero de 2018). Neural Net Pattern Recognition. Obtenido de <https://la.mathworks.com/help/deeplearning/ref/neuralnetpatternrecognition-app.html>
52. MathWorks. (2023). Seleccionar datos para regresión o abrir una sesión guardada en la app. Obtenido de <https://la.mathworks.com/help/stats/select-data-and-validation-for-regression-problem.html>
53. Méndez & Reyes. (2021). Análisis y Clasificación de Sonidos de Motores de Carros, para Diagnosticar Fallas, con Ayuda de Redes Neuronales. newton.azc.uam.mx. Recuperado el 24 de marzo de 2023, de [http://newton.azc.uam.mx/mcc/01\\_esp/08\\_sitios/micai\\_06/WORKSHOPS/WTI06/WTI03.PDF](http://newton.azc.uam.mx/mcc/01_esp/08_sitios/micai_06/WORKSHOPS/WTI06/WTI03.PDF)
54. Ministerio de Transportes y Telecomunicaciones, (2001). Establece normas de emision de contaminantes aplicables a los vehiculos motorizados y fija los procedimientos para su control. <https://sinca.mma.gob.cl/uploads/documentos/17563b785f1066c9c5b550c90185416b.pdf>



55. Ministerio del Medio Ambiente de Chile, (2017). Decreto 31 Establece plan de prevención y descontaminación. Gob.cl. [https://ppda.mma.gob.cl/wp-content/uploads/2018/05/DTO-31\\_24-Establece-plan-de-prevencion-y-descontaminacion-atmosferica-para-la-Region-Metropolitana-de-santiago.pdf](https://ppda.mma.gob.cl/wp-content/uploads/2018/05/DTO-31_24-Establece-plan-de-prevencion-y-descontaminacion-atmosferica-para-la-Region-Metropolitana-de-santiago.pdf)
56. Mital, A. D., Subramanian, A., & Mital, A. (2014). Designing for Maintenance. A Structured Approach to Consumer Product Development, Design, and Manufacture, 203-268.
57. Moreno, H., Pineda, D., & Santos, L. (2022). Evolución e historia de los motores diesel. Polo del Conocimiento, 744-760.
58. Morocho, J., & Nagua, J. (2019). Análisis del comportamiento de motores de combustión interna ciclo otto y diésel durante el efecto producido por averías en el sistema electrónico. Cuenca: Universidad Politécnica Salesiana.
59. OECD. (2020). Non-exhaust Particulate Emissions from Road Transport. Obtenido de <https://www.oecd.org/env/highlights-non-exhaust-particulate-emissions-from-road-transport.pdf>
60. Osuagwu, C. (2020). Investigation of volatile organic compounds from diesel engine emissions using H<sub>3</sub>O<sup>+</sup> chemical ionisation mass spectrometry (H<sub>3</sub>O<sup>+</sup>-CIMS). Queensland University of Technology.
61. Parker, J. (2017). Diseño y construcción de un simulador del funcionamiento normal y de fallas de los sensores maf y tps, para la carrera de ingeniería automotriz [Universidad Tecnológica Equinoccial]. <http://repositorio.ute.edu.ec/handle/123456789/16518>
62. Pham, V. C., Le, V. V., Yeo, S., Choi, J.-H., & Lee, W.-J. (2022). Effects of the Injector Spray Angle on Combustion and Emissions of a 4-Stroke Natural Gas-Diesel DF Marine Engine. MDPI.

63. Posada, G. (2016). Elementos Básicos de Estadística Descriptiva para el análisis de datos. Medellín: Luis Amigó.
64. Prasad, A., & Sharma, K. (2020). Engine Emission Control Technologies: Design Modifications and Pollution Mitigation Techniques. CRC Press.
65. Raff, M., Weingarten, E., & Muslija, M. (2019). Denoxtronic 5.3 – A modular system for applications worldwide. PROCEE.
66. Ramírez D. (2018). Análisis de eficiencia energética del ciclo diésel [Tesis de pregrado, Universidad Técnica del Norte]. Recuperado de <http://repositorio.utn.edu.ec/handle/123456789/8110>
67. Reisel, J. (2021). Principles of Engineering Thermodynamics 2nd Edición. Cengage Learning.
68. Rentar Environmental Solutions. (2018). Diesel Emissions: Types and Effects of Diesel Engine Emissions. Obtenido de <https://rentar.com/diesel-emissions-types-effects-diesel-engine-emissions/>
69. Riveros, H., Cabrera, E., & Enrique, J. (2021). Emisiones vehiculares. Instituto de Física - UNAM.
70. Rojas, E., Romero, V., & Pancha, J. (2020). Análisis del comportamiento de las emisiones de CO<sub>2</sub>, CO y del factor lambda de un vehículo con sistema de inyección convencional con catalizador y sin catalizador. Ingenius. doi: <https://doi.org/10.17163/>
71. Sánchez, Fabela, Flores, Hernández, Vázquez, & Cruz. (2019). Revisión de la normativa internacional sobre límites de emisiones contaminantes de vehículos de carretera. Imt.mx. <https://imt.mx/archivos/Publicaciones/PublicacionTecnica/pt562.pdf>


72. Secretaría de medio ambiente y recursos naturales. (2004). Norma Oficial Mexicana NOM-042-SEMARNAT-2003.  
<http://siga.jalisco.gob.mx/assets/documentos/normatividad/nom042semarnat2003.htm>
73. Secretaría de Medio Ambiente y Recursos Naturales. (2014). Norma Oficial Mexicana NOM-047-SEMARNAT-2014.  
[https://www.dof.gob.mx/nota\\_detalle.php?codigo=5371998&fecha=26/11/2014](https://www.dof.gob.mx/nota_detalle.php?codigo=5371998&fecha=26/11/2014)
74. Secretaría de Medio Ambiente y Recursos Naturales. (2017). Norma Oficial Mexicana NOM-167-SEMARNAT-2017.  
[https://dof.gob.mx/nota\\_detalle.php?codigo=5496105&fecha=05/09/2017](https://dof.gob.mx/nota_detalle.php?codigo=5496105&fecha=05/09/2017)
75. SEMARNAT (2006). NORMA Oficial Mexicana NOM-044-SEMARNAT-2006, Secretaría de Medio Ambiente y Recursos Naturales. Gob.mx.  
[https://www.profepa.gob.mx/innovaportal/file/658/1/NOM\\_044\\_SEMARNAT\\_2006\\_12\\_OCT\\_06.pdf](https://www.profepa.gob.mx/innovaportal/file/658/1/NOM_044_SEMARNAT_2006_12_OCT_06.pdf)
76. Servicio Ecuatoriano de Normalización, (2017). Gestión ambiental. aire. vehículos automotores. Límites permitidos de emisiones producidas por fuentes móviles terrestres que emplean gasolina.  
[https://www.normalizacion.gob.ec/buzon/normas/nte\\_inen\\_2204-2.pdf](https://www.normalizacion.gob.ec/buzon/normas/nte_inen_2204-2.pdf)
77. Sharma, S., & Maréchal, F. (2019). Carbon Dioxide Capture From Internal Combustion Engine Exhaust Using Temperature Swing Adsorption. *Frontiers in Energy Research*. doi:10.3389/fenrg.2019.00143
78. Silveira, F., Molinar, F., Silveira, M., & Schlosser, J. (2023). Fuel consumption by agricultural machinery: a review of pollutant emission control technologies. *Ciência Rural*.

79. Simões, A., Torres, J., & Fonseca, I. (2020). Ecological Predictive Maintenance of Diésel Engines. Diésel and Gasoline Engines.
80. Simões, A., Torres, J., & Fonseca, I. (2020). Ecological Predictive Maintenance of Diésel Engines. En Diésel and Gasoline Engines (págs. 137-160). London.
81. Simeone, O. (2018). A Very Brief Introduction to “machine learning” With Applications to Communication Systems. En Repositorio Universidad de Cornell. <http://arxiv.org/abs/1808.02342>
82. Sun, Z., Wang, X., Wang, X., & Zhou, J. (2017). Combustion and emission analysis of heavyduty vehicle diesel engine. AIP Conference Proceedings.
83. Torres E. (2017). Sistema de diagnóstico automotriz mediante el análisis de emisiones contaminantes con la aplicación de redes neuronales para la detección de fallas. [Tesis de pregrado, Universidad Politécnica Salesiana]. Recuperado de: <http://dspace.ups.edu.ec/handle/123456789/14914>
84. U.S. Environmental Protection Agency. (2020). Fuel Effects on Exhaust Emissions from Onroad Vehicles in MOVES3. EPA. Obtenido de <https://www.epa.gov/sites/default/files/2020-11/documents/420r20016.pdf>
85. Urieli, I. (2021). Engineering Thermodynamics - A Graphical Approach. Ohio University.
86. Vega D. (2014). Análisis y diagnóstico de vibraciones en vehiculos livianos de combustion interna [Escuela Politécnica Nacional]. <https://bibdigital.epn.edu.ec/bitstream/15000/7131/1/CD-5321.pdf>
87. Vidal, F. (2021, mayo 18). Mantenimiento Preventivo: Qué es, tipos y cómo hacerlo eficazmente. STEL Order. <https://www.stelorder.com/blog/mantenimiento-preventivo/>


88. Vijay, M., Veeresh, A., Reddy, R., Mohit, P., Zawbaa, H., & Kamel, S. (2022). Investigation of the combustion of exhaust gas recirculation in diesel engines with a particulate filter and selective catalytic reactor technologies for environmental gas reduction. *Case Studies in Thermal Engineering*.
89. Virca, I., & Badea, D. (2019). Study on the Predictive Maintenance of Vehicles and its Management Using the Specific “Keep the Machine Running” Application. *International conference KNOWLEDGE-BASED ORGANIZATION*, 291-297.
90. Wang, M. (2019). Study of Volatile Organic Compounds (VOC) in the cloudy atmosphere : air/droplet partitioning of VOC. *HAL Open Science*. Université Clermont Auvergne.
91. Wei, S., Ji, K., Leng, X., Wang, F., & Liu, X. (2014). Numerical simulation on effects of spray angle in a swirl chamber combustion system of DI (direct injection) diesel engines. *Energy*, 289–294.
92. Wei, Y.-J., Zhang, Y.-J., Zhu, X., Gu, H.-M., Zhu, Z.-Q., Liu, S.-H., . . . Jiang, X.-L. (2022). Effects of Diesel Hydrocarbon Components on Cetane Number and Engine Combustion and Emission Characteristics. *Applied Sciences*. doi: <https://doi.org/10.3390/app12073549>
93. Xin, Q. (2013). Durability and reliability in diesel engine system design. En *Diesel Engine System Design* (págs. 113-202). doi: 10.1533/9780857090836.1.113
94. Zambrano & Pérez (2021). Estudio de la aplicación del mantenimiento predictivo en motores diésel en la provincia de Manabí. *Revista Científica INGENIAR: Ingeniería, Tecnología E Investigación*. ISSN: 2737-6249., 4(8 Ed. esp.), 96-116. <https://doi.org/10.46296/ig.v4i8edespdic.0053>

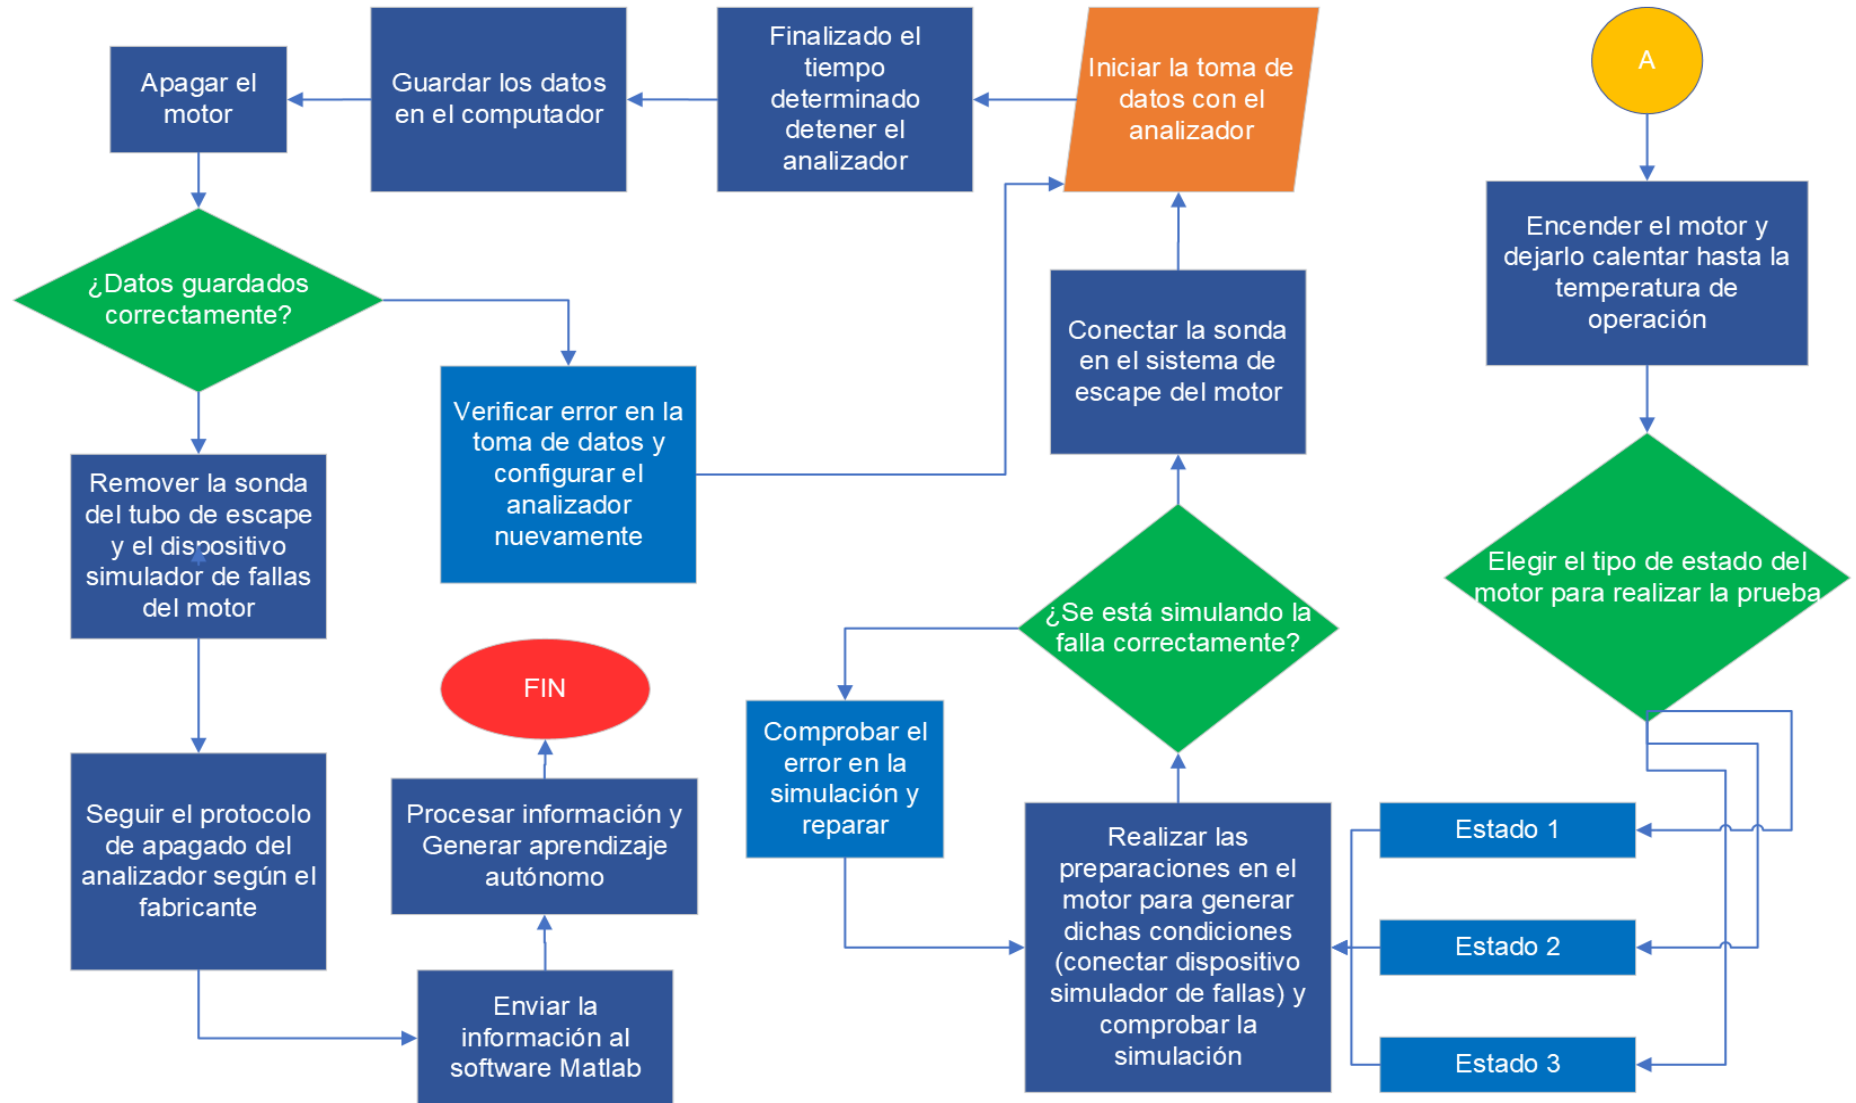
## 6. ANEXOS

Anexo 1. Flujograma de la metodología general del estudio



Anexo 2. Flujograma de la recopilación de datos y análisis de datos







**Anexo 3.** Formato de las tablas del aprendizaje autónomo por clasificación.

<b>OXÍGENO (O2)</b>											
<b>CARACTERÍSTICAS</b>											<b>ETIQUETA</b>
<b>Media</b>	<b>Mediana</b>	<b>Moda</b>	<b>Máximo</b>	<b>Mínimo</b>	<b>Rango</b>	<b>Varianza</b>	<b>Desviación estándar</b>	<b>Coefficiente de variación</b>	<b>Curtosis</b>	<b>Asimetría</b>	<b>Diagnóstico</b>
-	-	-	-	-	-	-	-	-	-	-	IDZDM90
-	-	-	-	-	-	-	-	-	-	-	IDZBMB
-	-	-	-	-	-	-	-	-	-	-	IBZDMB
-	-	-	-	-	-	-	-	-	-	-	IBZBMB
-	-	-	-	-	-	-	-	-	-	-	IBZBM90

#### **Anexo 4. Comprobaciones de fluidos del motor**



#### **Anexo 5. Elementos del analizador de gases**



#### **Anexo 6. Conexión del analizador al tubo de escape**



## Anexo 7. Interfaz software KANE AUTOPLUS



## Anexo 8. Recolección de datos mediante el software KANE LIVE



## Anexo 9. Información eléctrica del sensor MAF

Estado	Voltaje (V)	Cantidad de aire ingresado al motor (gr/s)
Sensor MAF señal normal ralentí	0,8 – 1,2 V	18 - 27 gr/s
Sensor MAF señal modificada	4 V	90 gr/s

## Anexo 10. Datos estadísticos de los gases para el machine learning

### Anexo 10.1 Datos resultantes del procesamiento estadístico del O<sub>2</sub>

OXÍGENO (O2)											
CARACTERÍSTICAS											ETIQUETA
Media	Mediana	Moda	Máximo	Mínimo	Rango	Varianza	Desviación estándar	Coefficiente de variación	Curtosis	Asimetría	Diagnóstico
0.2916	0.29	0.29	0.3	0.29	0.01	1.3714E-05	0.0037033	1.27	4.4405	1.8549	IBZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IBZBMB
0.301	0.3	0.3	0.31	0.3	0.01	9.1837E-06	0.0030305	1.0068	8.1111	2.6667	IBZBMB
0.306	0.31	0.31	0.31	0.3	0.01	0.00002449	0.0049487	1.6172	1.1667	-0.40825	IBZBMB
0.2592	0.26	0.26	0.26	0.25	0.01	7.5102E-06	0.0027405	1.0573	10.587	-3.0963	IBZBMB
0.2682	0.27	0.27	0.27	0.26	0.01	1.5061E-05	0.0038809	1.447	3.7751	-1.6659	IBZBMB
0.2778	0.28	0.28	0.28	0.27	0.01	0.00001751	0.0041845	1.5063	2.8275	-1.3519	IBZBMB
0.2856	0.29	0.29	0.29	0.28	0.01	2.5143E-05	0.0050143	1.7557	1.0584	-0.24175	IBZBMB
0.3356	0.34	0.34	0.34	0.33	0.01	2.5143E-05	0.0050143	1.4941	1.0584	-0.24175	IBZBMB
0.3426	0.34	0.34	0.35	0.34	0.01	1.9633E-05	0.0044309	1.2933	2.1975	1.0943	IBZBMB
0.3512	0.35	0.35	0.36	0.35	0.01	1.0776E-05	0.0032826	0.93468	6.4697	2.3387	IBZBMB
0.3592	0.36	0.36	0.37	0.35	0.02	2.3837E-05	0.0048823	1.3592	4.0956	-0.20747	IBZBMB
0.3688	0.37	0.37	0.38	0.36	0.02	2.7102E-05	0.005206	1.4116	3.4868	-0.16552	IBZBMB
0.3682	0.37	0.37	0.38	0.36	0.02	5.1796E-05	0.0071969	1.9546	1.988	0.27634	IBZBMB
0.371	0.37	0.37	0.38	0.37	0.01	9.1837E-06	0.0030305	0.81683	8.1111	2.6667	IBZBMB
0.3714	0.37	0.37	0.38	0.37	0.01	1.2286E-05	0.0035051	0.94375	5.3056	2.075	IBZBMB
0.2826	0.28	0.28	0.29	0.28	0.01	1.9633E-05	0.0044309	1.5679	2.1975	1.0943	IBZBMB
0.2964	0.3	0.3	0.3	0.29	0.01	0.00002351	0.0048487	1.6359	1.3403	-0.58333	IBZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IBZBMB
0.3022	0.3	0.3	0.31	0.3	0.01	0.00001751	0.0041845	1.3847	2.8275	1.3519	IBZBMB
0.3138	0.31	0.31	0.32	0.31	0.01	2.4041E-05	0.0049031	1.5625	1.2445	0.49445	IBZBMB
0.3218	0.32	0.32	0.33	0.32	0.01	1.5061E-05	0.0038809	1.206	3.7751	1.6659	IBZBMB
0.33	0.33	0.33	0.34	0.32	0.02	8.1633E-06	0.0028571	0.8658	12.5	-5.8771E-14	IBZBMB
0.3376	0.34	0.34	0.34	0.33	0.01	1.8612E-05	0.0043142	1.2779	2.4825	-1.2176	IBZBMB
0.343	0.34	0.34	0.35	0.34	0.01	2.1429E-05	0.0046291	1.3496	1.7619	0.87287	IBZBMB
0.3498	0.35	0.35	0.35	0.34	0.01	0.000002	0.0014142	0.40429	48.02	-6.8571	IBZBMB
0.3572	0.36	0.36	0.36	0.35	0.01	2.0571E-05	0.0045356	1.2698	1.9603	-0.97996	IBZBMB
0.3662	0.37	0.37	0.37	0.36	0.01	2.4041E-05	0.0049031	1.3389	1.2445	-0.49445	IBZBMB
0.37	0.37	0.37	0.37	0.37	0	0	0	0	3	0	IBZBMB
0.376	0.38	0.38	0.38	0.37	0.01	0.00002449	0.0049487	1.3161	1.1667	-0.40825	IBZBMB
0.3826	0.38	0.38	0.39	0.38	0.01	1.9633E-05	0.0044309	1.1581	2.1975	1.0943	IBZBMB
0.3876	0.39	0.39	0.39	0.38	0.01	1.8612E-05	0.0043142	1.1131	2.4825	-1.2176	IBZBMB
0.244	0.24	0.24	0.25	0.24	0.01	0.00002449	0.0049487	2.0282	1.1667	0.40825	IBZBMB
0.2504	0.25	0.25	0.26	0.25	0.01	3.9184E-06	0.0019795	0.79053	23.042	4.6949	IBZBMB
0.2596	0.26	0.26	0.26	0.25	0.01	3.9184E-06	0.0019795	0.76251	23.042	-4.6949	IBZBMB
0.2646	0.26	0.26	0.27	0.26	0.01	2.5347E-05	0.0050346	1.9027	1.0258	0.16051	IBZBMB
0.3316	0.33	0.33	0.34	0.33	0.01	1.3714E-05	0.0037033	1.1168	4.4405	1.8549	IBZBMB
0.3398	0.34	0.34	0.34	0.33	0.01	0.000002	0.0014142	0.41619	48.02	-6.8571	IBZBMB
0.3488	0.35	0.35	0.36	0.34	0.02	1.4857E-05	0.0038545	1.1051	5.4531	-1.1854	IBZBMB
0.3504	0.35	0.35	0.36	0.35	0.01	3.9184E-06	0.0019795	0.56492	23.042	4.6949	IBZBMB
0.3618	0.36	0.36	0.37	0.36	0.01	1.5061E-05	0.0038809	1.0727	3.7751	1.6659	IBZBMB
0.374	0.37	0.37	0.38	0.37	0.01	0.00002449	0.0049487	1.3232	1.1667	0.40825	IBZBMB
0.3796	0.38	0.38	0.38	0.37	0.01	3.9184E-06	0.0019795	0.52147	23.042	-4.6949	IBZBMB
0.3802	0.38	0.38	0.39	0.38	0.01	0.000002	0.0014142	0.37197	48.02	6.8571	IBZBMB
0.3862	0.39	0.39	0.39	0.38	0.01	2.4041E-05	0.0049031	1.2696	1.2445	-0.49445	IBZBMB
0.3924	0.39	0.39	0.4	0.39	0.01	1.8612E-05	0.0043142	1.0994	2.4825	1.2176	IBZBMB
0.402	0.4	0.4	0.41	0.39	0.02	2.0408E-05	0.0045175	1.1238	3.32	0.80498	IBZBMB
0.4052	0.41	0.41	0.41	0.4	0.01	2.5469E-05	0.0050467	1.2455	1.0064	-0.080064	IBZBMB
0.28	0.28	0.28	0.28	0.28	0	0	0	0	3	0	IDZBMB
0.287	0.29	0.29	0.29	0.28	0.01	2.1429E-05	0.0046291	1.6129	1.7619	-0.87287	IDZBMB
0.2898	0.29	0.29	0.29	0.28	0.01	0.000002	0.0014142	0.488	48.02	-6.8571	IDZBMB
0.2948	0.29	0.29	0.3	0.29	0.01	2.5469E-05	0.0050467	1.7119	1.0064	0.080064	IDZBMB
0.2946	0.29	0.29	0.3	0.29	0.01	2.5347E-05	0.0050346	1.709	1.0258	0.16051	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.2976	0.3	0.3	0.3	0.29	0.01	1.8612E-05	0.0043142	1.4497	2.4825	-1.2176	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.3	0.3	0.3	0.3	0.3	0	0	0	0	3	0	IDZBMB
0.3396	0.34	0.34	0.34	0.33	0.01	3.9184E-06	0.0019795	0.58289	23.042	-4.6949	IDZBMB
0.3476	0.35	0.35	0.35	0.34	0.01	1.8612E-05	0.0043142	1.2411	2.4825	-1.2176	IDZBMB
0.35	0.35	0.35	0.35	0.35	0	0	0	0	3	0	IDZBMB
0.3594	0.36	0.36	0.36	0.35	0.01	5.7551E-06	0.002399	0.6675	14.73	-3.7055	IDZBMB
0.36	0.36	0.36	0.36	0.36	0	0	0	0	3	0	IDZBMB
0.3602	0.36	0.36	0.37	0.36	0.01	0.000002	0.0014142	0.39262	48.02	6.8571	IDZBMB
0.3614	0.36	0.36	0.37	0.36	0.01	1.2286E-05	0.0035051	0.96987	5.3056	2.075	IDZBMB
0.37	0.37	0.37	0.37	0.37	0	0	0	0	3	0	IDZBMB
0.37347	0.37	0.37	0.38	0.37	0.01	2.3129E-05	0.0048093	1.2877	1.4136	0.64312	IDZBMB
0.37327	0.37	0.37	0.38	0.37	0.01	2.249E-05	0.004738	1.2693	1.5473	0.73983	IDZBMB
0.37204	0.37	0.37	0.38	0.37	0.01	1.6582E-05	0.0040721	1.0945	3.1564	1.4685	IDZBMB
0.37	0.37	0.37	0.37	0.37	0	0	0	0	3	0	IDZBMB
0.37	0.37	0.37	0.37	0.37	0	0	0	0	3	0	IDZBMB
0.3738	0.37	0.37	0.38	0.37	0.01	2.4041E-05	0.0049031	1.3117	1.2445	0.49445	IDZBMB
0.3626	0.37	0.37	0.38	0.33	0.05	0.0002931	0.01712	4.7215	1.737	-0.63228	IDZBMB
0.3418	0.34	0.34	0.35	0.34	0.01	1.5061E-05	0.0038809	1.1354	3.7751	1.6659	IDZBMB

## Anexo 10.2 Datos resultantes del procesamiento estadístico de NOx.

ÓXIDOS DE NITRÓGENO (NOx)											
CARACTERÍSTICAS											ETIQUETA
Media	Mediana	Moda	Máximo	Mínimo	Rango	Varianza	Desviación estándar	Coefficiente de variación	Curtosis	Asimetría	Diagnóstico
168.36	168	168	171	165	6	2.03E+00	1.4251	0.84648	2.6566	-0.26932	IBZBMB
171.4	171	171	174	169	5	1.51E+00	1.23E+00	7.17E-01	3.0467	0.33324	IBZBMB
173.68	174	174	176	172	4	9.16E-01	0.95704	0.55103	3.0768	0.11108	IBZBMB
173.62	174	174	175	173	2	3.63E-01	0.60238	0.34695	2.3175	0.37847	IBZBMB
124.34	123.5	128	131	117	14	2.19E+01	4.6756	3.7604	1.6746	-0.085434	IBZBMB
132.02	132	133	133	130	3	8.36E-01	0.91451	0.6927	1.5928	-0.20106	IBZBMB
134.68	135	135	137	133	4	1.36E+00	1.1683	0.86746	2.3674	0.25654	IBZBMB
137.78	138	138	140	136	4	8.28E-01	0.91003	0.6605	2.9251	-0.21021	IBZBMB
140.12	141	141	144	135	9	5.94E+00	2.4381	1.74	2.1139	-0.3797	IBZBMB
143.04	143	143	144	141	3	4.47E-01	0.66884	0.46759	3.6266	-0.45706	IBZBMB
144.56	145	145	146	143	3	4.15E-01	0.64397	0.44547	2.8319	-0.22529	IBZBMB
144.68	145	145	146	144	2	4.26E-01	0.65278	0.45119	2.2847	0.42119	IBZBMB
146.4	146	145	149	143	6	2.73E+00	1.6537	1.1296	2.1121	0.027351	IBZBMB
148.96	149	149	151	148	3	5.70E-01	0.75485	0.50675	2.6239	0.35246	IBZBMB
150.64	151	151	152	148	4	1.21E+00	1.1021	0.73163	3.1243	-0.91447	IBZBMB
151.6	152	152	153	150	3	6.94E-01	0.83299	0.54947	2.4256	2.06E-14	IBZBMB
114.78	115	116	117	111	6	2.62E+00	1.6199	1.4113	2.6206	-8.32E-01	IBZBM90
115.26	115	115	116	114	2	4.00E-01	0.63278	0.549	2.354	-0.25894	IBZBM90
116.32	116	116	118	115	3	3.44E-01	5.87E-01	5.05E-01	3.1207	0.42382	IBZBM90
117.42	117	117	119	116	3	9.02E-01	0.94954	0.80867	2.1156	0.087379	IBZBM90
118.46	118	118	121	116	5	2.01E+00	1.4172	1.1964	2.1041	-0.070149	IBZBM90
121.88	122	122	125	119	6	1.90E+00	1.3797	1.132	2.5726	0.028783	IBZBM90
126.16	126	127	128	124	4	9.13E-01	9.55E-01	7.57E-01	2.9844	-7.49E-01	IBZBM90
127.34	127	127	129	125	4	8.82E-01	0.93917	0.73753	2.7051	0.023652	IBZBM90
130.38	130	130	132	129	3	4.44E-01	0.6667	0.51135	2.9384	0.23842	IBZBM90
131.28	131	132	133	129	4	8.18E-01	0.90441	0.68892	2.5727	-0.24425	IBZBM90
132.72	133	133	134	131	3	5.73E-01	0.75701	0.57038	2.9354	-0.34763	IBZBM90
133.98	134	134	135	132	3	7.96E-01	0.89191	0.66571	2.4211	-0.48408	IBZBM90
134.46	135	135	137	131	6	2.74E+00	1.66E+00	1.23E+00	2.0103	-0.35103	IBZBM90
137.12	137	137	139	135	4	6.79E-01	0.82413	0.60103	3.2913	-0.44444	IBZBM90
137.76	138	138	139	137	2	3.90E-01	0.62466	0.45344	2.4052	0.20786	IBZBM90
138.92	139	139	140	137	3	4.83E-01	0.69517	0.50041	3.0063	-0.26332	IBZBM90
187.94	188	189	191	182	9	5.69E+00	2.3854	1.2692	3.4269	-0.96717	IBZDMB
190.76	191	191	192	189	3	5.94E-01	0.7709	0.40412	2.5662	-0.1054	IBZDMB
191.98	192	192	193	190	3	8.77E-01	0.93656	0.48784	2.7235	-0.71322	IBZDMB
193.06	193	194	194	190	4	9.96E-01	0.99816	0.51702	3.5121	-0.99084	IBZDMB
181.72	182	182	184	176	8	2.74E+00	1.6542	0.91029	5.2334	-1.2401	IBZDMB
183.14	183	184	185	181	4	1.35E+00	1.1608	0.63381	2.1128	-0.11686	IBZDMB
183.42	183.5	184	185	181	4	1.06E+00	1.0319	0.56261	2.63	-0.34614	IBZDMB
183.2	183	183	185	181	4	8.98E-01	0.94761	0.51725	2.624	0.17444	IBZDMB
177.58	178	180	181	172	9	5.11E+00	2.2596	1.2724	2.3035	-0.48617	IBZDMB
179.56	180	180	181	177	4	7.82E-01	0.88433	0.4925	3.2325	-0.45186	IBZDMB
179.3	179	179	181	177	4	6.63E-01	0.81441	0.45422	3.151	-0.36638	IBZDMB
178.4	178	178	181	176	5	7.35E-01	0.85714	0.48046	4.2593	0.11785	IBZDMB
174.6	174	173	179	170	9	8.29E+00	2.8785	1.6486	1.6112	-0.11202	IBZDMB
174.94	175	175	176	173	3	9.56E-01	0.9775	0.55876	2.283	-0.54212	IBZDMB
175.14	175	176	177	173	4	1.22E+00	1.1068	0.63192	2.2235	-0.27898	IBZDMB
175.32	175	175	177	174	3	6.71E-01	0.81916	0.46724	2.4167	0.029884	IBZDMB
144.38	144.5	144	150	136	14	1.47E+01	3.83E+00	2.65E+00	2.3055	-0.41974	IDZBMB
151.14	151	150	153	149	4	1.80E+00	1.3403	0.88677	1.781	0.10185	IDZBMB
153.74	154	154	155	152	3	6.45E-01	0.80331	0.52251	2.614	-0.21704	IDZBMB
155.12	155	155	157	154	3	2.71E-01	0.5206	0.33561	6.0724	1.0422	IDZBMB
154.64	155	156	157	149	8	4.60E+00	2.1453	1.3873	3.4089	-1.1778	IDZBMB
156.74	157	157	158	155	3	3.60E-01	6.00E-01	3.83E-01	3.3936	-0.41852	IDZBMB
158.16	158	158	160	157	3	4.23E-01	6.50E-01	4.11E-01	3.2984	0.28861	IDZBMB
159.32	159	159	160	158	2	3.04E-01	5.51E-01	3.46E-01	2.3113	0.0094611	IDZBMB
158.8	159	161	161	155	6	3.80E+00	1.95E+00	1.23E+00	2.1113	-0.4683	IDZBMB
161.12	161	161	162	160	2	3.93E-01	6.27E-01	3.89E-01	2.5311	-0.085798	IDZBMB
162.28	162	162	163	161	2	3.69E-01	6.07E-01	3.74E-01	2.4086	-0.21015	IDZBMB
163.24	163	163	164	162	2	3.09E-01	5.55E-01	3.40E-01	2.6689	0.050802	IDZBMB
160.36	161	161	164	155	9	3.79E+00	1.9458	1.2134	3.1754	-0.7519	IDZBMB
163.26	163	164	165	161	4	8.90E-01	9.44E-01	5.78E-01	2.6241	-0.53759	IDZBMB
164.22	164	164	165	163	2	4.20E-01	6.48E-01	3.95E-01	2.3195	-0.23594	IDZBMB
164.84	165	165	166	164	2	3.41E-01	5.84E-01	3.54E-01	2.7805	0.023829	IDZBMB
225.62	226	225	233	212	21	2.72E+01	5.2134	2.3107	2.8499	-0.73037	IDZDM90
235.1	236	237	238	230	8	4.50E+00	2.1213	0.90231	2.5391	-0.67638	IDZDM90
226.98	227	227	233	221	12	5.2037	2.2812	1.005	3.4886	-0.30861	IDZDM90
231.44	231	230	236	229	7	4.50E+00	2.1205	0.9162	2.9653	0.9404	IDZDM90
238.28	239	239	241	235	6	3.022	1.7384	0.72956	2.4605	-0.50811	IDZDM90
241.6	241	241	245	238	7	4.33E+00	2.08	0.86094	2.0712	0.25565	IDZDM90
212.68	208	208	246	198	48	2.22E+02	14.902	7.0066	4.0324	1.625	IDZDM90
212.96	213	213	215	211	4	9.78E-01	9.89E-01	4.64E-01	2.6577	0.33581	IDZDM90
213.58	214	213	216	211	5	1.11E+00	1.0515	0.49234	3.4579	-0.053703	IDZDM90
214.76	215	214	217	213	4	8.80E-01	0.93808	0.43681	2.3223	0.19323	IDZDM90
214.14	216	217	218	194	24	2.84E+01	5.3261	2.4872	8.0068	-2.3292	IDZDM90
218.86	219	219	223	215	8	2.94E+00	1.71E+00	7.83E-01	2.7924	-0.099721	IDZDM90
222.7	223	224	225	219	6	3.23E+00	1.80E+00	8.08E-01	1.8657	-0.32955	IDZDM90
223.68	224	224	227	222	5	9.98E-01	0.99877	0.44652	5.0192	1.1704	IDZDM90
223.36	224	224	227	212	15	12.358	3.5153	1.5738	4.6717	-1.5586	IDZDM90
229.84	230	230	235	224	11	9.77E+00	3.1257	1.3599	1.9333	-0.27139	IDZDM90

### Anexo 10.3 Datos resultantes del procesamiento estadístico del CO.

MONÓXIDO DE CARBONO (CO)											
CARACTERÍSTICAS											ETIQUETA
Media	Mediana	Moda	Máximo	Mínimo	Rango	Varianza	Desviación estándar	Coefficiente de variación	Curtosis	Asimetría	Diagnóstico
0.0448	0.01	0	0.21	0	0.21	3.48E-03	0.059014	131.73	3.4116	1.1619	IBZBMB
0.0288	0.005	0	0.3	0	0.3	2.92E-03	5.40E-02	1.88E+02	14.359	3.0823	IBZBMB
0.0676	0.03	0	0.34	0	0.34	7.44E-03	0.08625	127.59	5.1559	1.5973	IBZBMB
0.113	0.045	0	0.42	0	0.42	1.74E-02	0.13173	116.57	2.7168	1.0607	IBZBMB
0.05	0.025	0	0.24	0	0.24	3.47E-03	0.058936	117.87	4.5559	1.5118	IBZBMB
0.0698	0.03	0	0.39	0	0.39	7.52E-03	0.086744	124.27	5.7063	1.7218	IBZBMB
0.1154	0.04	0	0.45	0	0.45	1.84E-02	0.13577	117.65	2.7763	0.99555	IBZBMB
0.1284	0.065	0	0.46	0	0.46	1.99E-02	0.14095	109.77	2.2627	0.85281	IBZBMB
0.1506	0.145	0	0.47	0	0.47	1.73E-02	0.1315	87.315	2.4762	0.57034	IBZBMB
0.1514	0.125	0	0.4	0	0.4	1.61E-02	0.12701	83.888	1.8266	0.37004	IBZBMB
0.112	0.05	0.01	0.34	0	0.34	1.33E-02	0.11537	103.01	1.9011	0.65337	IBZBMB
0.096	0.05	0	0.34	0	0.34	1.15E-02	0.10704	111.5	2.4449	0.87427	IBZBMB
0.1202	0.06	0	0.48	0	0.48	1.66E-02	0.1289	107.23	2.5437	0.81739	IBZBMB
0.0888	0.03	0	0.42	0	0.42	1.18E-02	0.10853	122.22	3.7281	1.2623	IBZBMB
0.0314	0.01	0	0.31	0	0.31	3.82E-03	0.061777	196.74	12.404	3.1087	IBZBMB
0.0458	0.02	0	0.25	0	0.25	3.94E-03	0.062763	137.04	4.5977	1.57E+00	IBZBMB
0.166	0.165	0.02	0.44	0.02	0.42	1.86E-02	0.13625	82.077	1.9819	5.13E-01	IBZBM90
0.0668	0.015	0	0.24	0	0.24	7.03E-03	0.083823	125.48	2.3289	0.91871	IBZBM90
0.0386	0.01	0	0.27	0	0.27	3.94E-03	6.28E-02	1.63E+02	6.5335	2.053	IBZBM90
0.0472	0.02	0	0.34	0	0.34	4.47E-03	0.066885	141.71	10.206	2.5405	IBZBM90
0.0834	0.03	0	0.3	0	0.3	1.05E-02	0.10233	122.7	2.3782	0.94063	IBZBM90
0.089	0.04	0	0.37	0	0.37	1.06E-02	0.10304	115.78	3.446	1.2452	IBZBM90
0.1094	0.035	0	0.53	0	0.53	2.07E-02	1.44E-01	1.31E+02	3.7497	1.34E+00	IBZBM90
0.1744	0.16	0.16	0.47	0	0.47	1.31E-02	0.11454	65.676	2.4642	0.41716	IBZBM90
0.1012	0.055	0	0.38	0	0.38	1.39E-02	0.11806	116.66	2.3161	0.88904	IBZBM90
0.0508	0.01	0	0.31	0	0.31	8.09E-03	0.089917	177	5.2216	1.8876	IBZBM90
0.0658	0.02	0.01	0.31	0	0.31	7.86E-03	0.088643	134.72	3.9701	1.473	IBZBM90
0.114	0.075	0.01	0.34	0	0.34	1.18E-02	0.1085	95.172	2.1664	0.69065	IBZBM90
0.1158	0.07	0.01	0.58	0	0.58	1.98E-02	1.41E-01	1.22E+02	3.993	1.2626	IBZBM90
0.0582	0.02	0	0.28	0	0.28	6.67E-03	0.081659	140.31	3.6974	1.4008	IBZBM90
0.1514	0.08	0	0.61	0	0.61	2.74E-02	0.16543	109.27	2.8841	0.99684	IBZBM90
0.0586	0.01	0.01	0.26	0	0.26	5.69E-03	0.075404	128.68	2.9424	1.188	IBZBM90
0.1044	0.035	0	0.41	0	0.41	1.65E-02	0.12843	123.02	3.0952	1.1303	IBZDMB
0.0794	0.02	0	0.36	0	0.36	1.20E-02	0.10942	137.81	3.267	1.3223	IBZDMB
0.0642	0.0642	0	0.27	0	0.27	6.17E-03	0.078535	122.33	3.0749	1.2043	IBZDMB
0.0866	0.05	0.01	0.34	0	0.34	8.74E-03	0.093473	107.94	3.5638	1.2053	IBZDMB
0.0534	0	0	0.41	0	0.41	8.31E-03	0.091174	170.74	6.4072	1.8835	IBZDMB
0.0724	0.025	0.01	0.27	0	0.27	7.57E-03	0.08698	120.14	2.4554	0.99661	IBZDMB
0.0708	0.01	0	0.3	0	0.3	8.64E-03	0.092974	131.32	2.7749	1.0895	IBZDMB
0.0996	0.045	0	0.37	0	0.37	1.31E-02	0.11453	114.99	2.1934	0.78029	IBZDMB
0.076	0.01	0	0.35	0	0.35	1.18E-02	0.10842	142.66	3.2107	1.2542	IBZDMB
0.065	0.01	0	0.3	0	0.3	7.47E-03	0.086455	133.01	3.5988	1.263	IBZDMB
0.1104	0.11	0	0.43	0	0.43	1.23E-02	0.11104	100.58	3.7381	1.0099	IBZDMB
0.0566	0.01	0	0.36	0	0.36	8.83E-03	0.093952	165.99	6.168	1.9855	IBZDMB
0.0444	0.005	0	0.26	0	0.26	5.52E-03	0.07429	167.32	3.9834	1.5606	IBZDMB
0.1126	0.065	0.02	0.43	0	0.43	1.35E-02	0.11614	103.15	3.0354	1.0424	IBZDMB
0.1384	0.13	0	0.46	0	0.46	1.77E-02	0.13304	96.127	2.6797	0.82043	IBZDMB
0.0896	0.02	0	0.48	0	0.48	1.51E-02	0.12286	137.12	5.006	1.5522	IBZDMB
0.024	0.02	0.02	0.05	0.01	0.04	8.98E-05	9.48E-03	3.95E+01	2.8223	0.29073	IDZBMB
0.0404	0.04	0.04	0.1	0.01	0.09	2.00E-04	0.014136	34.991	7.7956	1.3737	IDZBMB
0.0286	0.03	0.03	0.08	0.01	0.07	2.04E-04	0.014287	49.955	7.5159	1.6481	IDZBMB
0.0598	0.06	0.06	0.08	0.03	0.05	1.04E-04	0.0102	17.057	3.2352	-0.65934	IDZBMB
0.0596	0.055	0.1	0.13	0.01	0.12	1.13E-03	0.033622	56.413	1.9099	0.11958	IDZBMB
0.047	0.05	0.04	0.07	0.02	0.05	2.30E-04	1.52E-02	3.22E+01	2.0012	-0.085333	IDZBMB
0.0372	0.03	0.03	0.11	0.01	0.1	6.04E-04	2.46E-02	6.61E+01	5.3699	1.743	IDZBMB
0.072	0.06	0.06	0.13	0.02	0.11	8.53E-04	2.92E-02	4.06E+01	2.1164	0.57488	IDZBMB
0.0574	0.04	0.03	0.11	0.02	0.09	9.54E-04	3.09E-02	5.38E+01	1.5418	0.43958	IDZBMB
0.048	0.04	0.03	0.11	0.02	0.09	7.35E-04	2.71E-02	5.65E+01	3.033	1.1205	IDZBMB
0.051	0.05	0.05	0.11	0.03	0.08	3.97E-04	1.99E-02	3.91E+01	5.8597	1.7064	IDZBMB
0.0324	0.03	0.03	0.09	0.01	0.08	2.72E-04	1.65E-02	5.09E+01	6.8762	1.4615	IDZBMB
0.04	0.04	0.04	0.11	0.02	0.09	4.29E-04	0.020702	51.755	8.4966	2.4676	IDZBMB
0.0612	0.06	0.05	0.12	0.04	0.08	4.19E-04	2.05E-02	3.34E+01	5.2409	1.5387	IDZBMB
0.0624	0.06	0.06	0.09	0.02	0.07	2.27E-04	1.51E-02	2.41E+01	4.0381	-0.74068	IDZBMB
0.0412	0.03	0.03	0.11	0.02	0.09	6.48E-04	2.54E-02	6.18E+01	4.6864	1.7187	IDZBMB
0.0436	0.04	0.04	0.06	0.03	0.03	3.98E-05	0.0063116	14.476	3.2147	0.53996	IDZDM90
0.0288	0.03	0.03	0.04	0.02	0.02	5.16E-05	0.0071827	24.94	1.9822	0.17731	IDZDM90
0.1096	0.11	0.11	0.12	0.01	0.02	2.8408E-05	0.0053299	4.8631	3.5646	-0.04444	IDZDM90
0.0408	0.04	0.04	0.06	0.03	0.03	6.06E-05	0.0077828	19.075	2.8395	0.38707	IDZDM90
0.0152	0.01	0.01	0.04	0	0.04	0.00013976	0.011822	77.775	2.5102	0.55078	IDZDM90
0.0802	0.085	0.1	0.11	0.02	0.09	6.31E-04	0.025111	31.311	3.2664	-1.179	IDZDM90
0.0812	0.11	0.12	0.13	0.01	0.12	2.36E-03	0.048556	59.798	1.2504	-0.39364	IDZDM90
0.0526	0.05	0.04	0.12	0.03	0.09	5.71E-04	2.39E-02	4.54E+01	5.7699	1.9932	IDZDM90
0.021	0.02	0.02	0.04	0.01	0.03	7.04E-05	0.008391	39.957	2.6837	0.43967	IDZDM90
0.0364	0.04	0.04	0.04	0.02	0.02	3.58E-05	0.0059796	16.427	3.9588	-1.4218	IDZDM90
0.0972	0.1	0.1	0.1	0.09	0.01	2.06E-05	0.0045356	4.6662	1.9603	-0.97996	IDZDM90
0.1134	0.11	0.11	0.14	0.1	0.04	1.00E-04	1.00E-02	8.84E+00	3.4249	0.87705	IDZDM90
0.0336	0.04	0.04	0.05	0.01	0.04	1.13E-04	1.06E-02	3.17E+01	3.1639	-0.96222	IDZDM90
0.0386	0.04	0.04	0.05	0.03	0.02	2.04E-05	0.0045221	11.715	4.1414	-0.59177	IDZDM90
0.0478	0.05	0.05	0.06	0.03	0.03	6.2408E-05	0.0078999	16.527	2.0998	0.15535	IDZDM90
0.0542	0.05	0.05	0.06	0.05	0.01	2.49E-05	0.0049857	9.1987	1.1051	0.32418	IDZDM90

## Anexo 10.4 Datos resultantes del procesamiento estadístico del CO<sub>2</sub>.

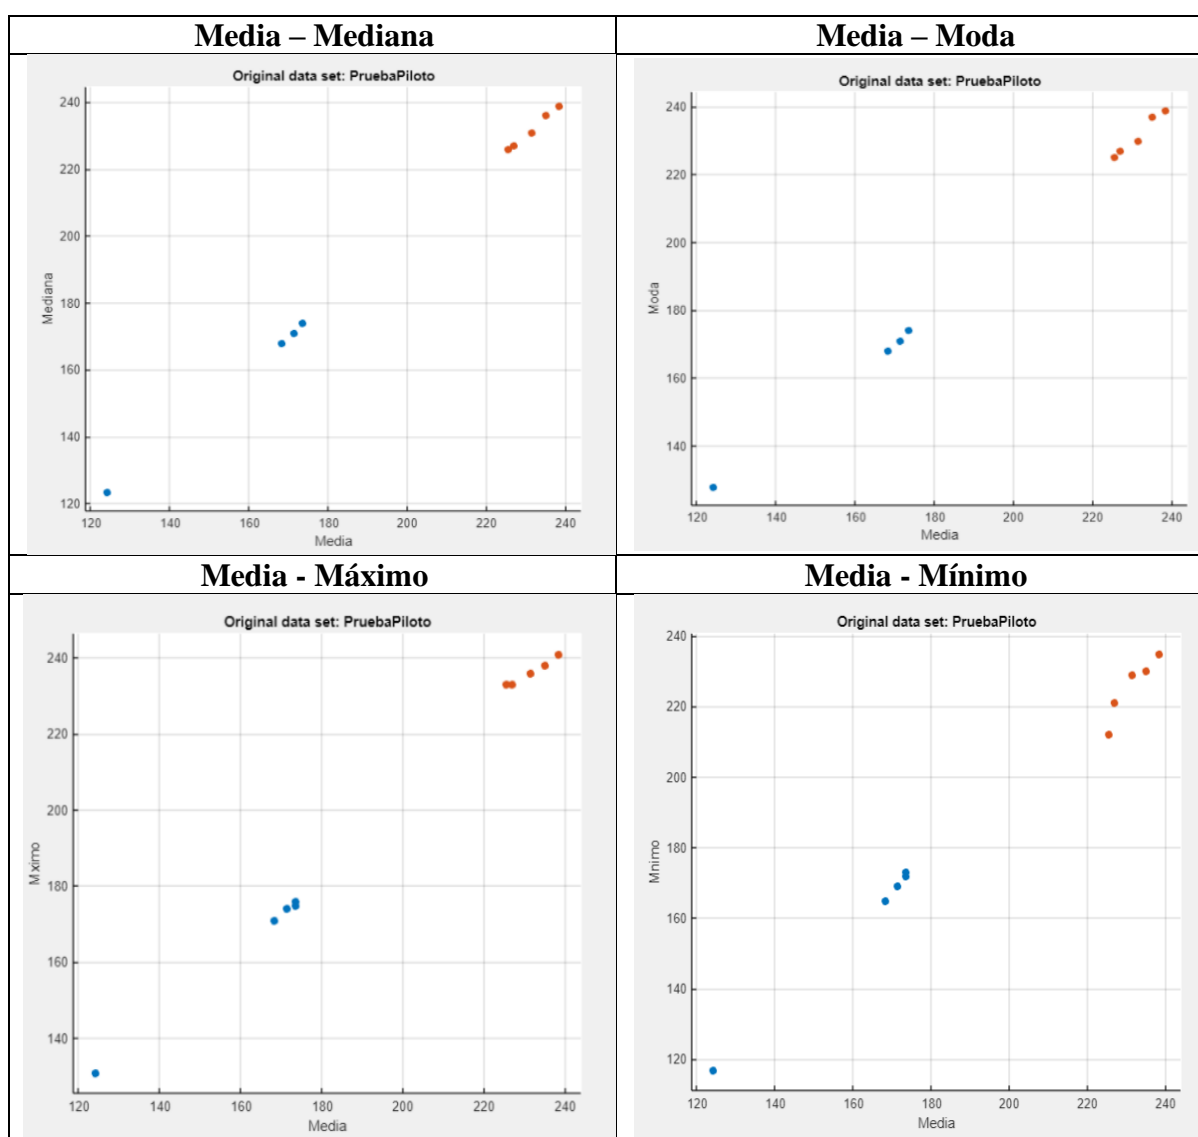
DÍOXIDO DE CARBONO (CO <sub>2</sub> )											
CARACTERÍSTICAS											ETIQUETA
Media	Mediana	Moda	Máximo	Mínimo	Rango	Varianza	Desviación estándar	Coeficiente de variación	Curtosis	Asimetría	Diagnóstico
1.762	1.8	1.8	1.9	1.6	0.3	3.63E-03	0.060238	3.4187	2.773	-0.18743	IBZBMB
1.674	1.7	1.7	1.9	1.5	0.4	9.31E-03	9.65E-02	5.76E+00	2.8817	0.12535	IBZBMB
1.6	1.6	1.6	1.8	1.5	0.3	6.94E-03	0.083299	5.2062	1.9896	0.214	IBZBMB
1.608	1.6	1.5	1.8	1.4	0.4	1.22E-02	0.11036	6.8633	2.1503	0.025325	IBZBMB
1.694	1.7	1.7	1.9	1.5	0.4	9.56E-03	0.09775	5.7704	2.6553	-0.14483	IBZBMB
1.66	1.7	1.7	1.9	1.5	0.4	8.57E-03	0.092582	5.5772	3.3265	0.40526	IBZBMB
1.624	1.6	1.6	1.9	1.4	0.5	1.29E-02	0.1135	6.9887	3.0299	0.44928	IBZBMB
1.62	1.6	1.6	1.8	1.5	0.3	7.35E-03	0.085714	5.291	2.3333	0.19642	IBZBMB
1.732	1.7	1.7	1.9	1.6	0.3	6.71E-03	0.081916	4.7296	2.6165	0.25491	IBZBMB
1.8	1.8	1.7	2	1.6	0.4	1.02E-02	0.10102	5.612	2.2	0.12	IBZBMB
1.624	1.6	1.6	1.8	1.5	0.3	6.76E-03	0.082214	5.0625	2.2291	-0.019944	IBZBMB
1.578	1.6	1.6	1.8	1.4	0.4	9.91E-03	0.099571	6.3099	2.6258	0.07508	IBZBMB
1.78	1.8	1.8	2	1.6	0.4	1.06E-02	0.10302	5.7874	2.3728	0.067886	IBZBMB
1.67	1.7	1.7	1.8	1.5	0.3	8.67E-03	0.093131	5.5767	2.4018	-0.44407	IBZBMB
1.64	1.6	1.6	1.8	1.5	0.3	6.12E-03	0.078246	4.7711	2.5467	-0.05164	IBZBMB
1.604	1.6	1.6	1.8	1.4	0.4	8.96E-03	0.094675	5.9024	2.3873	-7.95E-02	IBZBMB
1.794	1.8	1.8	1.9	1.6	0.3	7.11E-03	0.084298	4.6989	2.3158	-3.00E-01	IBZBM90
1.596	1.6	1.6	1.8	1.4	0.4	9.37E-03	0.096806	6.0655	2.4936	-0.056501	IBZBM90
1.53	1.5	1.5	1.7	1.4	0.3	7.86E-03	8.86E-02	5.79E+00	2.2333	0.0888	IBZBM90
1.612	1.6	1.6	1.7	1.4	0.3	5.16E-03	0.071827	4.4558	3.1464	-0.5111	IBZBM90
1.678	1.7	1.7	1.8	1.5	0.3	7.06E-03	0.084007	5.0064	2.1389	0.012352	IBZBM90
1.606	1.6	1.6	1.8	1.4	0.4	9.56E-03	0.09775	6.0866	2.4144	0.012396	IBZBM90
1.54	1.5	1.5	1.8	1.3	0.5	1.67E-02	1.29E-01	8.40E+00	2.348	-3.43E-02	IBZBM90
1.75	1.8	1.8	1.9	1.6	0.3	5.82E-03	0.076265	4.358	2.6547	-0.5577	IBZBM90
1.674	1.7	1.7	1.8	1.5	0.3	4.41E-03	0.066425	3.968	2.8555	-0.088459	IBZBM90
1.604	1.6	1.5	1.8	1.4	0.4	1.35E-02	0.11599	7.2311	2.0996	0.23895	IBZBM90
1.59	1.6	1.6	1.8	1.3	0.5	1.19E-02	0.10926	6.872	2.9882	-0.27498	IBZBM90
1.61	1.6	1.6	1.8	1.4	0.4	9.08E-03	0.095298	5.9191	2.4867	0.22867	IBZBM90
1.62	1.6	1.6	1.9	1.5	0.4	1.06E-02	1.03E-01	6.36E+00	2.7278	0.61098	IBZBM90
1.556	1.6	1.6	1.7	1.4	0.3	8.23E-03	0.090711	5.8298	2.2703	-0.18003	IBZBM90
1.584	1.6	1.7	1.8	1.4	0.4	1.40E-02	0.11843	7.4763	1.9178	-0.43208	IBZBM90
1.696	1.7	1.5	2	1.5	0.5	2.32E-02	0.15248	8.9903	1.8939	0.24235	IBZBM90
1.92	1.9	1.9	2.2	1.7	0.5	1.55E-02	0.12454	6.4865	2.5734	0.1921	IBZDMB
1.688	1.7	1.6	1.9	1.5	0.4	1.33E-02	0.11542	6.8379	2.1081	0.31622	IBZDMB
1.738	1.7	1.7	1.9	1.6	0.3	5.67E-03	0.075295	4.3323	2.7183	0.12494	IBZDMB
1.758	1.7	1.7	1.9	1.6	0.3	5.34E-03	0.073095	4.1578	2.4815	0.51157	IBZDMB
1.844	1.8	1.8	2.1	1.7	0.4	9.04E-03	0.095105	5.1575	2.7833	0.31726	IBZDMB
1.668	1.7	1.7	1.8	1.5	0.3	6.30E-03	0.079385	4.7593	2.5706	-0.11195	IBZDMB
1.718	1.7	1.7	1.9	1.5	0.4	9.67E-03	0.098333	5.7237	2.3745	0.15444	IBZDMB
1.748	1.75	1.8	1.9	1.6	0.3	5.40E-03	0.073512	4.2055	2.7046	-0.086184	IBZDMB
1.886	1.9	1.8	2.2	1.7	0.5	1.43E-02	0.11954	6.3383	2.7757	0.63414	IBZDMB
1.678	1.7	1.7	1.8	1.5	0.3	6.65E-03	0.081541	4.8594	2.6046	-0.26483	IBZDMB
1.708	1.7	1.7	1.9	1.5	0.4	1.05E-02	0.1027	6.0128	2.2628	0.06797	IBZDMB
1.744	1.7	1.7	1.9	1.5	0.4	8.64E-03	0.092934	5.3288	2.7711	-0.2086	IBZDMB
1.83	1.8	1.8	2.1	1.6	0.5	1.19E-02	0.10926	5.9707	2.5393	0.33187	IBZDMB
1.72	1.7	1.7	1.9	1.5	0.4	8.57E-03	0.092582	5.3827	2.8776	-0.24939	IBZDMB
1.69	1.7	1.7	1.8	1.5	0.3	5.82E-03	0.076265	4.5127	2.9501	-0.39039	IBZDMB
1.754	1.8	1.8	2	1.6	0.4	8.25E-03	0.090824	5.1781	2.9525	0.045303	IBZDMB
1.666	1.7	1.7	1.7	1.6	0.1	2.29E-03	4.79E-02	2.87E+00	1.4563	-0.67552	IDZBMB
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0	0	3	0	IDZBMB
1.658	1.7	1.7	1.7	1.6	0.1	2.49E-03	0.049857	3.0071	1.1051	-0.32418	IDZBMB
1.698	1.7	1.7	1.7	1.6	0.1	2.00E-04	0.014142	0.83287	48.02	-6.8571	IDZBMB
1.656	1.7	1.7	1.7	1.6	0.1	2.51E-03	0.050143	3.0279	1.0584	-0.24175	IDZBMB
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0.00E+00	0.00E+00	3	0	IDZBMB
1.674	1.7	1.7	1.7	1.6	0.1	1.96E-03	4.43E-02	2.65E+00	2.1975	-1.0943	IDZBMB
1.702	1.7	1.7	1.8	1.7	0.1	2.00E-04	1.41E-02	8.31E-01	48.02	6.8571	IDZBMB
1.678	1.7	1.7	1.7	1.6	0.1	1.75E-03	4.18E-02	2.49E+00	2.8275	-1.3519	IDZBMB
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0.00E+00	0.00E+00	3	0	IDZBMB
1.682	1.7	1.7	1.7	1.6	0.1	1.51E-03	3.88E-02	2.31E+00	3.7751	-1.6659	IDZBMB
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0.00E+00	0.00E+00	3	0	IDZBMB
1.658	1.7	1.7	1.7	1.6	0.1	2.49E-03	0.049857	3.0071	1.1051	-0.32418	IDZBMB
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0.00E+00	0.00E+00	3	0	IDZBMB
1.672	1.7	1.7	1.7	1.6	0.1	2.06E-03	4.54E-02	2.71E+00	1.9603	-0.97996	IDZBMB
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0.00E+00	0.00E+00	3	0	IDZBMB
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0	0	3	0	IDZDM90
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0	0	3	0	IDZDM90
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0	0	3	0	IDZDM90
1.674	1.7	1.7	1.7	1.6	0.1	1.96E-03	0.044309	2.6469	2.1975	-1.0943	IDZDM90
1.702	1.7	1.7	1.8	1.7	0.1	0.0002	0.014142	0.83091	48.02	6.8571	IDZDM90
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0	0	3	0	IDZDM90
1.632	1.7	1.7	1.7	1	0.7	1.69E-02	0.13005	7.9691	14.451	-3.1976	IDZDM90
1.688	1.7	1.7	1.7	1.6	0.1	1.08E-03	3.28E-02	1.94E+00	6.4697	-2.3387	IDZDM90
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0	0	3	0	IDZDM90
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0	0	3	0	IDZDM90
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0	0	3	0	IDZDM90
1.652	1.7	1.7	1.7	1.6	0.1	2.55E-03	5.05E-02	3.05E+00	1.0064	-0.080064	IDZDM90
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0.00E+00	0.00E+00	3	0	IDZDM90
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0.00E+00	0.00E+00	3	0	IDZDM90
1.634	1.6	1.6	1.7	1.6	0.1	0.0022898	0.047852	2.9285	1.4563	0.67552	IDZDM90
1.7	1.7	1.7	1.7	1.7	0	0.00E+00	0	0	3	0	IDZDM90

## Anexo 11. Prueba piloto

### Anexo 11.1 Base de datos procesada de la prueba piloto

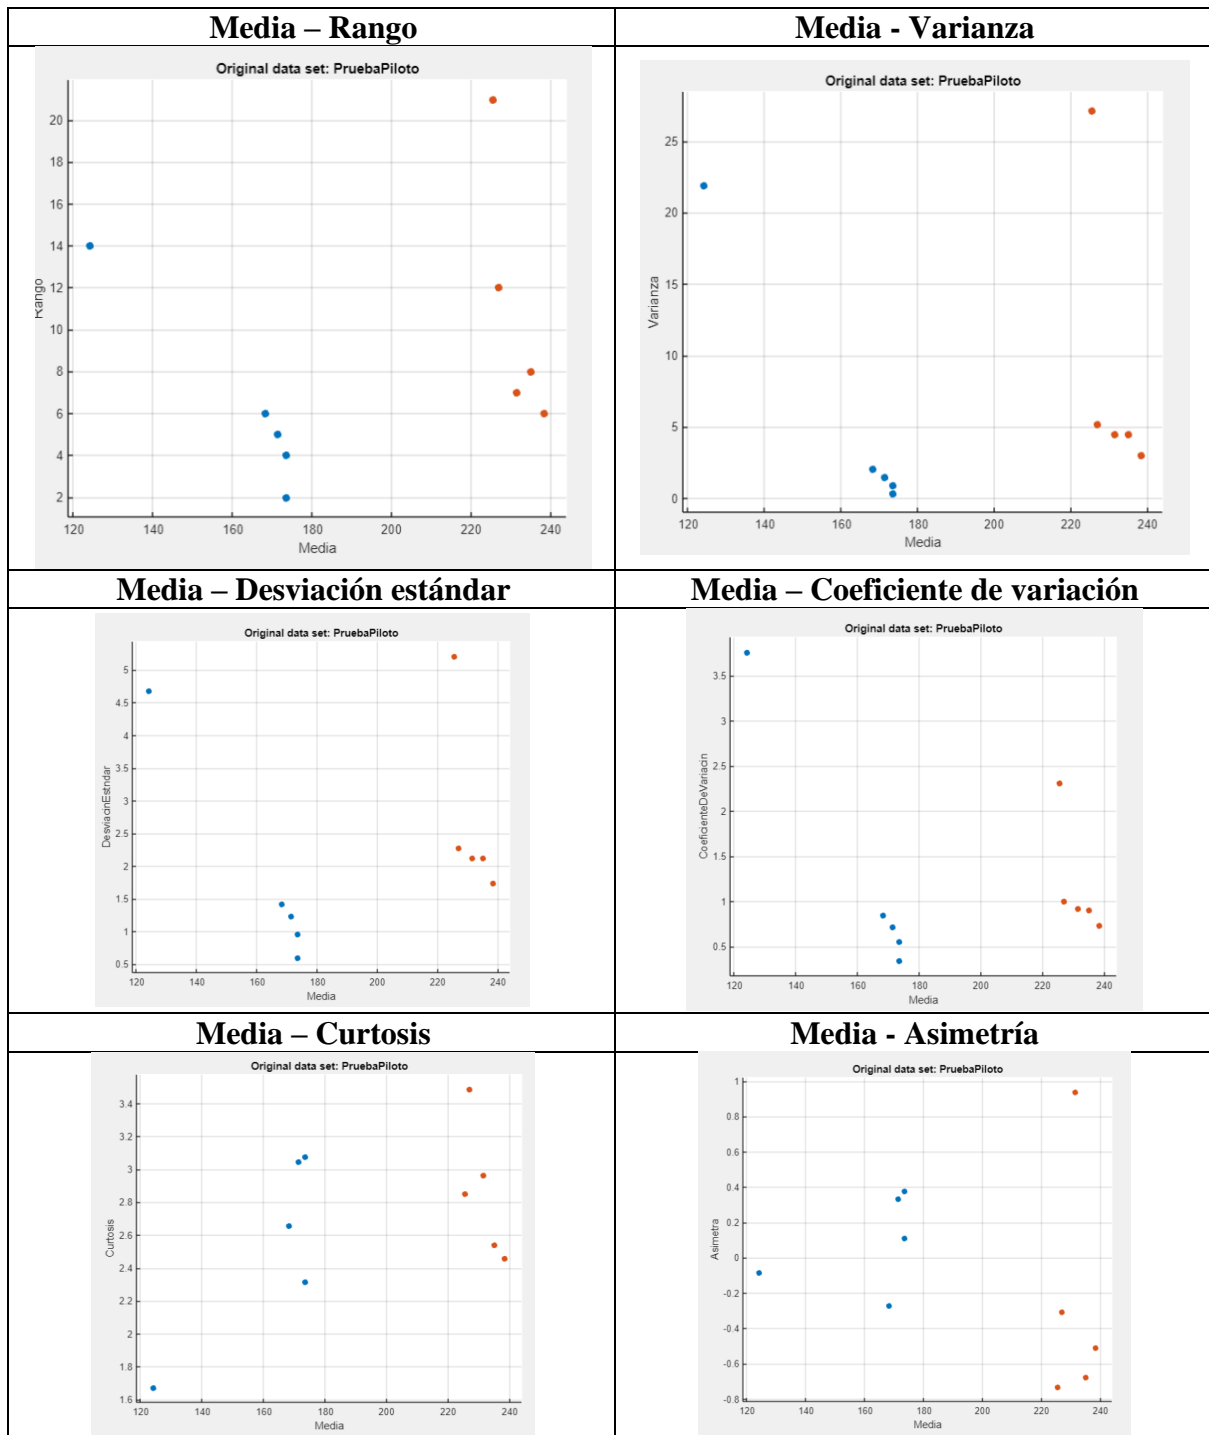
Media	Mediana	Moda	Máximo	Mínimo	Rango	Varianza	Desviación estándar	Coefficiente de variación	Curtois	Asimetría	Diagnóstico
168.36	168	168	171	165	6	2.03E+00	1.4251	0.84648	2.6566	-0.26932	IBZBMB
171.4	171	171	174	169	5	1.51E+00	1.23E+00	7.17E-01	3.0467	0.33324	IBZBMB
173.68	174	174	176	172	4	9.16E-01	0.95704	0.55103	3.0768	0.11108	IBZBMB
173.62	174	174	175	173	2	3.63E-01	0.60238	0.34695	2.3175	0.37847	IBZBMB
124.34	123.5	128	131	117	14	2.19E+01	4.6756	3.7604	1.6746	-0.085434	IBZBMB
225.62	226	225	233	212	21	2.72E+01	5.2134	2.3107	2.8499	-0.73037	IDZDM90
235.1	236	237	238	230	8	4.50E+00	2.1213	0.90231	2.5391	-0.67638	IDZDM90
226.98	227	227	233	221	12	5.2037	2.2812	1.005	3.4886	-0.30861	IDZDM90
231.44	231	230	236	229	7	4.50E+00	2.1205	0.9162	2.9653	0.9404	IDZDM90
238.28	239	239	241	235	6	3.022	1.7384	0.72956	2.4605	-0.50811	IDZDM90

### Anexo 11.2 Resultados del entrenamiento de la prueba piloto basado en emisiones de NOx





Continua.



## Anexo 12. Código del sistema basado en emisiones de NOx.

```
clc;

disp('SISTEMA PARA EL DIAGNÓSTICO PREDICTIVO DE UN MOTOR DIÉSEL EN BASE A
GASES DE ESCAPE');

Datos=[Untitled]; % Aquí se ingresa el nombre del archivo.xlsx importado.

Media=mean(Datos);

Mediana=median(Datos);

Moda=mode(Datos);

Maximo=max(Datos);

Minimo=min(Datos);

Rango=range(Datos);

Varianza=var(Datos);

Desviacion_estandar= std(Datos);

Coeficiente_variacion=(Desviacion_estandar./Media).*100;

Curtosis=kurtosis(Datos);

Asimetria=skewness(Datos);

Tabla1=table(Media,Mediana,Moda,
Maximo,Minimo,Rango,Varianza,Desviacion_estandar,Coeficiente_variacion, Curtosis,Asimetria);

disp("Procesamiento de valores");

disp(Tabla1);

[trainedClassifier, validationAccuracy] = trainClassifier(DataEmissions)

inputTable = DataEmissions;

predictorNames = {'Media', 'Mediana', 'Moda', 'Mximo', 'Mnimo', 'Rango', 'Varianza',
'DesviacinEstndar', 'CoeficienteDeVariacin', 'Curtosis', 'Asimetra'};

predictors = inputTable(:, predictorNames);

response = inputTable.Diagnostico;

isCategoricalPredictor = [false, false, false, false, false, false, false, false, false, false];
```

```

classNames = categorical({'IBZBM90'; 'IBZBMB'; 'IBZDMB'; 'IDZBMB'; 'IDZDM90'});

% Train a classifier

% This code specifies all the classifier options and trains the classifier.

classificationTree = fitctree(...

    predictors, ...

    response, ...

    'SplitCriterion', 'gdi', ...

    'MaxNumSplits', 100, ...

    'Surrogate', 'off', ...

    'ClassNames', classNames);

% Create the result struct with predict function

predictorExtractionFcn = @(t) t(:, predictorNames);

treePredictFcn = @(x) predict(classificationTree, x);

trainedClassifier.predictFcn = @(x) treePredictFcn(predictorExtractionFcn(x));

% Add additional fields to the result struct

trainedClassifier.RequiredVariables = {'Media', 'Mediana', 'Moda', 'Mximo', 'Mnimo', 'Rango',

'Varianza', 'DesviacinEstndar', 'CoeficienteDeVariacin', 'Curtosis', 'Asimetra'};

trainedClassifier.ClassificationTree = classificationTree;

trainedClassifier.About = 'This struct is a trained model exported from "Classification Learner"  
R2023b.';

trainedClassifier.HowToPredict = sprintf('To make predictions on a new table, T, use: \n [yfit,scores]  
= c.predictFcn(T) \nreplacing "c" with the name of the variable that is this struct, e.g. "trainedModel".  
\n \nThe table, T, must contain the variables returned by: \n c.RequiredVariables \nVariable formats  
(e.g. matrix/vector, datatype) must match the original training data. \nAdditional variables are ignored.

```

\n \nFor more information, see

```
% Extract predictors and response
```

```
% This code processes the data into the right shape for training the
```

```
% model.
```

```
inputTable = DataEmissions;
```

```
predictorNames = {'Media', 'Mediana', 'Moda', 'Mximo', 'Mnimo', 'Rango', 'Varianza',  
'DesviacinEstndar', 'CoeficienteDeVariacin', 'Curtosis', 'Asimetra'};
```

```
predictors = inputTable(:, predictorNames);
```

```
response = inputTable.Diagnostico;
```

```
isCategoricalPredictor = [false, false, false, false, false, false, false, false, false, false];
```

```
classNames = categorical({'IBZBM90'; 'IBZBMB'; 'IBZDMB'; 'IDZBMB'; 'IDZDM90'});
```

```
% Perform cross-validation
```

```
partitionedModel = crossval(trainedClassifier.ClassificationTree, 'KFold', 5);
```

```
% Compute validation predictions
```

```
[validationPredictions, validationScores] = kfoldPredict(partitionedModel);
```

```
% Compute validation accuracy
```

```
validationAccuracy = 1 - kfoldLoss(partitionedModel, 'LossFun', 'ClassifError');
```

```
yfit = ModeloNOX.predictFcn(Tabla1)
```

### Anexo 13. Código del sistema integral de emisiones.

```
clc;

disp('SISTEMA PARA EL DIAGNÓSTICO PREDICTIVO DE UN MOTOR DIÉSEL EN BASE A
GASES DE ESCAPE');

Datos=[Emisiones]; % Aquí se ingresa el nombre del archivo.xlsx importado.

Media=mean(Datos);

disp("Procesamiento de valores");

disp(Media);

[trainedClassifier, validationAccuracy] = trainClassifier(DataEmissions)

inputTable = DataEmissions;

predictorNames = {'Media', 'Mediana', 'Moda', 'Mximo', 'Mnimo', 'Rango', 'Varianza',
'DesviacinEstndar', 'CoeficienteDeVariacin', 'Curtosis', 'Asimetra'};

predictors = inputTable(:, predictorNames);

response = inputTable.Diagnostico;

isCategoricalPredictor = [false, false, false, false, false, false, false, false, false, false];

classNames = categorical({'IBZBM90'; 'IBZBMB'; 'IBZDMB'; 'IDZBMB'; 'IDZDM90'});

% Train a classifier

% This code specifies all the classifier options and trains the classifier.

classificationTree = fitctree(...

    predictors, ...

    response, ...

    'SplitCriterion', 'gdi', ...

    'MaxNumSplits', 100, ...

    'Surrogate', 'off', ...

    'ClassNames', classNames);
```

```

% Create the result struct with predict function

predictorExtractionFcn = @(t) t(:, predictorNames);

treePredictFcn = @(x) predict(classificationTree, x);

trainedClassifier.predictFcn = @(x) treePredictFcn(predictorExtractionFcn(x));

% Add additional fields to the result struct

trainedClassifier.RequiredVariables = {'Media', 'Mediana', 'Moda', 'Mximo', 'Mnimo', 'Rango',
'Varianza', 'DesviacinEstndar', 'CoeficienteDeVariacin', 'Curtosis', 'Asimetra'};

trainedClassifier.ClassificationTree = classificationTree;

trainedClassifier.About = 'This struct is a trained model exported from ‘Classification Learner’
R2023b.';

trainedClassifier.HowToPredict = sprintf('To make predictions on a new table, T, use: \n [yfit,scores]
= c.predictFcn(T) \nreplacing "c" with the name of the variable that is this struct, e.g. "trainedModel".
\n \nThe table, T, must contain the variables returned by: \n c.RequiredVariables \nVariable formats
(e.g. matrix/vector, datatype) must match the original training data. \nAdditional variables are ignored.
\n \nFor more information, see <a href="matlab:helpview(fullfile(docroot, "stats", "stats.map"),
"appclassification_exportmodeltoworkspace")">How to predict using an exported model</a>.';

% Extract predictors and response

% This code processes the data into the right shape for training the
% model.

inputTable = DataEmissions;

predictorNames = {'Media', 'Mediana', 'Moda', 'Mximo', 'Mnimo', 'Rango', 'Varianza',
'DesviacinEstndar', 'CoeficienteDeVariacin', 'Curtosis', 'Asimetra'};

predictors = inputTable(:, predictorNames);

response = inputTable.Diagnostico;

isCategoricalPredictor = [false, false, false, false, false, false, false, false, false, false];

classNames = categorical({'IBZBM90'; 'IBZBMB'; 'IBZDMB'; 'IDZBMB'; 'IDZDM90'});

```

```
% Perform cross-validation
partitionedModel = crossval(trainedClassifier.ClassificationTree, 'KFold', 5);

% Compute validation predictions
[validationPredictions, validationScores] = kfoldPredict(partitionedModel);

% Compute validation accuracy
validationAccuracy = 1 - kfoldLoss(partitionedModel, 'LossFun', 'ClassifError');

yfit = ModeloIntegral.predictFcn(Tabla1)
```