



UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE QUITO
CARRERA DE INGENIERÍA AUTOMOTRIZ

ANÁLISIS DEL ESTILO DE CONDUCCIÓN DE UN VEHÍCULO CON MOTOR MPI
MEDIANTE EL CICLO DE EMISIONES REALES RDE PARA DETERMINAR SU
INFLUENCIA EN EL CONSUMO DE COMBUSTIBLE EN LA CIUDAD DE QUITO-
ECUADOR

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

AUTORES: DIEGO MATEO OLALLA NACIMBA
RICARDO ISAÍAS PARRA BAÑO

TUTOR: PAUL ANDRÉS MOLINA CAMPOVERDE

Quito - Ecuador
2023

CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Nosotros, Diego Mateo Olalla Nacimba con documento de identificación N°1726536640 y Ricardo Isaías Parra Baño con documento de identificación N°1722876222 manifestamos que:

Somos los autores y responsables del presente trabajo; y, autorizamos a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Quito, 18 de septiembre del año 2023

Atentamente,



Diego Mateo Olalla Nacimba
1726536640



Ricardo Isaías Parra Baño
1722876222

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

Nosotros, Diego Mateo Olalla Nacimba con documento de identificación No. 1726536640 y Ricardo Isaías Parra Baño con documento de identificación No. 1722876222, expresamos nuestra voluntad y por medio del presente documento cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del Proyecto Técnico: “Análisis del estilo de conducción de un vehículo con motor MPI mediante el ciclo de emisiones reales RDE para determinar su influencia en el consumo de combustible en la ciudad de Quito-Ecuador”, el cual ha sido desarrollado para optar por el título de Ingenieros Automotrices, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

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

Quito, 18 de septiembre del año 2023

Atentamente,



Diego Mateo Olalla Nacimba

1726536640



Ricardo Isaías Parra Baño

1722876222

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Paul Andrés Molina Campoverde con documento de identificación N° 0104948104, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: ANÁLISIS DEL ESTILO DE CONDUCCIÓN DE UN VEHÍCULO CON MOTOR MPI MEDIANTE EL CICLO DE EMISIONES REALES RDE PARA DETERMINAR SU INFLUENCIA EN EL CONSUMO DE COMBUSTIBLE EN LA CIUDAD DE QUITO-ECUADOR, realizado por Diego Mateo Olalla Nacimba con documento de identificación N° 1726536640 y por Ricardo Isaías Parra Baño con documento de identificación N° 1722876222, obteniendo como resultado final el trabajo de titulación bajo la opción: Proyecto Técnico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 18 de septiembre del año 2023

Atentamente,



Ing. Paul Andrés Molina Campoverde, MSc
0104948104

DEDICATORIA

El perenne paso del tiempo, la impredecible naturaleza humana y la aleatoriedad de los sucesos que pueden surgir del leve aleteo de una mariposa, son el origen de este caos y armonía que llamamos vida. Cada momento, esfuerzo y sacrificio invertidos en este estudio, y dentro del contexto de su realización, están dedicados a mi familia, quienes me han enseñado a contemplar el caos como un firmamento estrellado, la armonía como un refugio confortable, la aleatoriedad como un abanico de posibilidades y el tiempo como una oportunidad para ser memorable.

Ricardo Isafas Parra Baño

El presente trabajo va dedicado a Dios por acompañarme en cada paso que doy en la búsqueda de ser una mejor persona y profesional. También se la dedico a mis padres, Diego y Verónica, por su constante apoyo en este camino, a mis hermanos, quienes siempre me han brindado un apoyo incondicional y espero que mi ejemplo les sirva de inspiración.

Diego Mateo Olalla Nacimba

AGRADECIMIENTO

Quiero expresar mis más sinceros agradecimientos al MSC. Paul Molina, cuya dedicación, interés e iniciativa fueron fundamentales para el planteamiento y desarrollo de esta investigación. Su pedagogía, profesionalismo y pasión por la enseñanza han sido esenciales en mi crecimiento tanto profesional como personal durante mis estudios. También deseo expresar mi eterna gratitud al PhD. Felipe Grijalva, Dios pone ángeles en la vida...

Ricardo Isafías Parra Baño

Quiero expresar mi más sincero agradecimiento al MSC. Paul Molina, cuya dedicación, interés e iniciativa fueron fundamentales para el planteamiento y desarrollo de esta investigación. Su pedagogía, profesionalismo y pasión por la enseñanza han sido esenciales en mi crecimiento tanto profesional como personal durante mis estudios. Además, deseo expresar mi eterna gratitud al PhD. Felipe Grijalva y a todos los docentes de la carrera, quienes compartieron sabias palabras y brindaron conocimientos rigurosos y precisos. A ustedes, mis queridos profesores, les debo mis conocimientos. También quiero reconocer el apoyo incondicional de mis padres, quienes siempre han sido el motor que impulsa mis sueños y esperanzas, acompañándome en los momentos más difíciles durante mis horas de estudio. Han sido mis mejores guías de vida. Hoy, al concluir mis estudios, dedico a ustedes este logro, amados padres, como una meta más conquistada. Estoy orgulloso de haberlos elegido mis padres y de contar con su apoyo en este momento tan importante.

Diego Mateo Olalla Nacimba

ÍNDICE GENERAL

INTRODUCCIÓN	1
PROBLEMA	2
Objetivo General.....	5
Objetivos Específicos.	5
Marco teórico	5
CAPÍTULO I ESTUDIO DEL COMPORTAMIENTO DE VARIABLES QUE INCIDEN EN EL ESTILO DE CONDUCCION.....	8
1.1 Estado del arte.....	8
1.2 Índices o factores de comportamiento	10
1.2.1 Ciclo de emisiones reales (RDE).....	10
1.2.2 Aceleración positiva relativa (RPA).....	12
1.2.3 $V \cdot A+$ (velocity times positive acceleration).....	13
1.3 Aprendizaje supervisado, aprendizaje no supervisado	15
1.3.1 T-SNE (Incrustación de vecinos estocásticos distribuidos en T)	15
1.3.2 Árbol de decisiones DT	17
CAPÍTULO II METODOLOGÍA PARA LA CLASIFICACIÓN DE TIPOS DE CONDUCTOR SEGÚN SU ESTILO DE CONDUCCIÓN.....	19
2.1 Adquisición de las Señales del OBD	20
2.1.1 Freematics ONE+	20
2.1.2 Tipo de vehículo	21
2.1.3 Acondicionamiento del vehículo para las pruebas experimentales	22
2.1.4 Pruebas de ruta para la adquisición de datos	22
2.2 Cálculo de señales de parámetros de interés.....	25
2.2.1 Índices de comportamiento.....	25
2.3 Extracción de estadísticas por señal en tiempo.....	26
2.4 Análisis exploratorio	28
2.4.1 Análisis de correlación en una ruta normal	28
2.4.2 Análisis de correlación en una ruta agresiva	30
2.4.3 Tsne del estilo de conducción.....	31
2.5 Modelo de clasificación	32
CAPITULO III ESTUDIO COMPARATIVO DEL CONSUMO DE COMBUSTIBLE EN DIFERENTES MODOS DE CONDUCCIÓN.....	35
3.1 Análisis de regresión lineal múltiple	35
3.2 Boxplot de variables de interés en función del estilo de conducción	37
3.2.1 Flujo de combustible	37
3.2.2 RPM.....	37
3.2.3 RPA	38

3.2.4	VA Percentil 95	39
3.2.5	Aceleración.....	39
3.2.6	Diferencias en consumo de combustible	40
CAPÍTULO IV ALGORITMO DE CLASIFICACIÓN DEL ESTILO DE CONDUCCION DE ACUERDO CON EL CONSUMO DE COMBUSTIBLE.....		42
4.1	Generación del algoritmo.....	42
4.2	Prueba del modelo clasificador en una ruta normal.....	46
4.3	Prueba del modelo clasificador en un RDE	47
CONCLUSIONES		51
RECOMENDACIONES		53
REFERENCIAS BIBLIOGRÁFICAS		54

ÍNDICE DE FIGURAS

Figura 1.1:	Densidad velocidad por aceleración positiva.	15
Figura 1.2:	Visualización de T-SNE.....	16
Figura 1.3:	Organización de un árbol de decisiones.	18
Figura 2.1:	Metodología.....	19
Figura 2.2:	Freematics One+.....	20
Figura 2.3:	Matriz de correlación.....	29
Figura 2.4:	Matriz de correlación.....	30
Figura 2.5:	T-sne.....	32
Figura 3.1:	Boxplot flujo de combustible.....	37
Figura 3.2:	Boxplot RPM.....	38
Figura 3.3:	Boxplot RPA.....	38
Figura 3.4:	Boxplot VA 95 percentil	39
Figura 3.5:	Boxplot aceleración	40
Figura 4.1:	Classification Learner	42
Figura 4.2:	Tipos de modelo.....	43
Figura 4.3:	Hiperparámetros	44
Figura 4.4:	Matriz de confusión.....	45
Figura 4.5:	Exportación del modelo.....	46
Figura 4.6:	Árbol de decisión.....	47
Figura 4.7:	Ruta RDE.....	48
Figura 4.8:	Ejecución del modelo	49

ÍNDICE DE TABLAS

Tabla 1.1: Especificaciones de viaje RDE.....	11
Tabla 2.1: Ficha técnica.....	21
Tabla 2.2: Rutas de prueba.....	23
Tabla 2.3: Variables de entrada.....	25
Tabla 2.4: Características estadísticas.....	27
Tabla 2.5: Ciclo RDE.....	33
Tabla 2.6: Predictores.....	34
Tabla 3.1: Predictores.....	36
Tabla 3.2: t-test consumo de combustible.....	40
Tabla 4.1: Ruta de prueba.....	46
Tabla 4.2: Características de la ruta RDE.....	48
Tabla 4.3: Ruta de prueba RDE.....	49

ÍNDICE DE ECUACIONES

Ec. (1.1)	13
Ec. (1.2)	13
Ec. (1.3)	14
Ec. (1.4)	14
Ec. (3.1)	36

RESUMEN

En la ciudad de Quito, Ecuador, el crecimiento del parque automotor y los altos precios de los combustibles han generado una creciente preocupación por reducir el consumo de combustible y disminuir las emisiones asociadas. Si bien existen diversas perspectivas para abordar esta inquietud, como el filtrado de aire, el octanaje del combustible, características del motor, etc., uno de los factores más influyentes en el elevado consumo de combustible es el estilo de conducción.

El estilo de conducción, que se caracteriza por factores como el uso frecuente del freno y el acelerador, cambios de marcha inoportunos y un tiempo de ralentí prolongado, ha sido identificado como un factor determinante en el consumo de combustible. En este proyecto, se lleva a cabo un análisis exhaustivo de las características que están correlacionadas con el consumo de combustible, centrándose en su influencia en el estilo de conducción, ya sea normal o agresivo.

Los resultados revelan que las revoluciones del motor, la velocidad, la posición de la mariposa y la presión absoluta del múltiple son aspectos críticos que convergen en el impacto sobre el consumo promedio de combustible junto con aquellos factores que varían según el comportamiento del conductor. Estas variables muestran una fuerte relación con el estilo de conducción y su influencia en la eficiencia del consumo de combustible.

Además, se propone el desarrollo de un modelo de machine learning que clasifica el estilo de conducción en función de las condiciones de la ruta, según el ciclo RDE, y se relaciona con el consumo de combustible en cada etapa del ciclo: urbano, rural y carretera. Los resultados obtenidos indican que un estilo de conducción más agresivo se asocia con un aumento en el consumo de combustible.

Palabras clave: ciclo RDE, estilo de conducción, consumo de combustible, machine learning

ABSTRACT

In the city of Quito, Ecuador, the growth of the automotive fleet and high fuel prices have raised increasing concerns about reducing fuel consumption and decreasing associated emissions. While there are various perspectives to address this concern, such as air filtering, fuel octane rating, engine characteristics, etc., one of the most influential factors in high fuel consumption is driving style.

Driving style, characterized by factors such as frequent use of brakes and accelerator, untimely gear shifts, and extended idling time, has been identified as a determining factor in fuel consumption. In this project, a comprehensive analysis is conducted on the characteristics that are correlated with fuel consumption, focusing on their influence on driving style, whether it is normal or aggressive.

The results reveal that engine revolutions, speed, throttle position, and absolute manifold pressure are critical aspects that converge in their impact on average fuel consumption, along with other factors that vary according to driver behavior. These variables show a strong relationship with driving style and its influence on fuel consumption efficiency.

Additionally, the development of a machine learning model is proposed to classify driving style based on road conditions according to the RDE cycle, and its relationship with fuel consumption in each stage of the cycle: urban, rural, and highway. The obtained results indicate that a more aggressive driving style is associated with an increase in fuel consumption.

Keywords: RDE cycle, driving style, fuel consumption, machine learning

INTRODUCCIÓN

El presente estudio se enfoca en el análisis del estilo de conducción de un piloto y cómo este afecta el consumo de combustible. Para ello, se utiliza una estructura jerárquica de decisiones basada en un árbol de decisión. Este árbol de decisión toma en cuenta las características de la carretera, condiciones de altitud, condiciones del tráfico y la forma de conducción del piloto dichas decisiones convergen en la toma de una decisión con respecto a la clasificación del estilo de conducción (agresivo-normal) y por consiguiente su consumo de combustible.

El estudio se divide en cuatro capítulos principales:

Capítulo 1: estudio del comportamiento de variables que inciden en el estilo de conducción, en este capítulo se lleva a cabo una revisión del estado actual del conocimiento en relación con el comportamiento del conductor. Se estudian índices o factores de comportamiento como el ciclo de emisiones reales (RDE), el índice RPA (relative positive acceleration) y $V \cdot A$ (Velocity Times Positive acceleration). Además, se exploran técnicas de aprendizaje supervisado y no supervisado, incluyendo el uso de árboles de decisiones (DT).

Capítulo 2: metodología para la clasificación de tipos de conductor según su estilo de conducción, en este capítulo se describe la metodología utilizada para la adquisición de señales del OBD (On-Board Diagnostics) y se detalla el proceso de acondicionamiento del vehículo para las pruebas experimentales. También se explica cómo se calculan los parámetros de interés y los índices de comportamiento.

Capítulo 3: estudio comparativo del consumo de combustible en diferentes modos de conducción, en este capítulo se realiza un análisis de regresión lineal múltiple para predecir el flujo medio en diferentes rutas. Además, se utilizan diagramas de cajas y bigotes para comparar variables de interés en función del estilo de conducción, como el flujo de combustible, las RPM y la RPA.

Capítulo 4: modelar un algoritmo que clasifique el estilo de conductor y su consumo de combustible, en este capítulo se explica el procedimiento para generar un modelo clasificador del estilo de conducción y su consumo de combustible. Se realizan pruebas del modelo en rutas normales y en rutas con conducción agresiva.

PROBLEMA

La manera en que se conduce un vehículo influye en el consumo de combustible, aunque también se deben tener en cuenta otras variables como el tipo de vehículo, el motor y el combustible utilizado. El patrón de conducción se define comúnmente como el perfil de velocidad del vehículo, pero puede ampliarse para incluir otros aspectos del comportamiento de conducción, como el cambio de marcha, aceleraciones súbitas, etc. Es importante destacar que el concepto de patrón de conducción no abarca la generación de viajes, la elección del modo de viaje o la ruta elegida, sin embargo, estos son factores que también influyen para evaluar el consumo de combustible (Ericson, 2001). En un estudio llevado a cabo en la ciudad de Georgia, Estados Unidos, se analizaron más de 100,000 km de datos de operaciones de autobuses en dos tipos de servicios: uno de transporte urbano local con paradas frecuentes y otro de servicio expreso con altas velocidades sostenidas. Los resultados demostraron que se puede reducir el consumo de combustible en un 5 % en el servicio de tránsito local y en un 7 % en el servicio de autobús expreso al cambiar el estilo de conducción, modificando factores como la aceleración, el uso del freno, el cambio de marcha o el tiempo de ralentí, entre otros (Hussein & Panwai , 2016).

Otras investigaciones han identificado que las características de conducción durante la aceleración son responsables del 56,5% del consumo total de combustible, mientras que la desaceleración solo contribuye con menos del 5,7% del consumo total. El estilo de conducción agresivo, caracterizado por aceleraciones bruscas y altas revoluciones del motor, aumenta significativamente el consumo de combustible, al conducir de manera más eficiente, se puede reducir la cantidad de recursos necesarios para impulsar el automóvil (Ma y otros, 2015).

La importancia del estudio del comportamiento de conducción no solamente se limita a analizar cómo afecta al consumo de combustible, además, también existe la preocupación por la contaminación ambiental causada por las emisiones de gases de efecto invernadero causadas por la combustión (Meseguer y otros, 2015). Es importante mencionar que las emisiones del transporte son una fuente importante y en aumento de la contaminación del aire por partículas, según la Organización Mundial de la Salud. En las ciudades europeas, representan el 30 % de las emisiones de partículas (PM), mientras que, en los países de la OCDE, llegan al 50 %; además, un estudio encontró que la contaminación ambiental por

partículas PM 2,5 provocó alrededor de 1,03 millones de muertes en las 74 ciudades más grandes de China en 2013, lo que equivale al 32 % de todas las muertes notificadas, las consecuencias ambientales derivadas del sector automotriz están estrechamente ligadas a conductas o comportamientos negativos al momento de conducir. Sin embargo, es importante destacar que la conducción eficiente también puede ayudar a reducir la emisión de gases de los vehículos, y por ende la disminución la contaminación del aire (Ping y otros, 2019).

Delimitación del problema. -

El uso de un ciclo RDE (Real Driving Emissions) al tomar señales en un vehículo tiene la ventaja de proporcionar mediciones más precisas y realistas de las emisiones del vehículo en situaciones de conducción reales en la carretera. Esto es importante porque las pruebas de laboratorio no siempre son representativas de las condiciones reales de conducción. Puede haber diferencias significativas entre las emisiones y el consumo de combustible medidos en el laboratorio y los valores obtenidos en la carretera. Un estudio realizado en Europa ha demostrado esta disparidad al comparar los datos obtenidos en laboratorio con las pruebas realizadas en condiciones reales. Los resultados revelaron que existe una diferencia informada del 30 al 40% en relación con las cifras oficiales y las estimaciones basadas en situaciones reales en cuanto al rendimiento de los vehículos. El mencionado artículo examina el impacto de diversos elementos que inciden en el consumo de combustible y las emisiones de CO₂ tanto en condiciones de conducción real como en entornos de laboratorio, y destaca que factores como el estilo de conducción, la configuración del vehículo y las condiciones del tráfico tienen un fuerte impacto. Además, se señalan factores subestimados que podrían tener un impacto considerable en el consumo de combustible durante la conducción en condiciones reales., dichos factores son el mantenimiento adecuado del vehículo, la gestión del peso, la optimización de la aerodinámica, la consideración de las condiciones de conducción, la adopción de un estilo de conducción eficiente y el uso consciente del sistema de climatización. Según el artículo, se plantea la idea de que la implementación de un nuevo procedimiento de prueba podría solucionar alrededor de la mitad de la discrepancia existente entre los resultados obtenidos en el laboratorio y los observados en condiciones reales (Fontaras y otros, 2017).

En Latinoamérica también existe un creciente interés en estudiar la influencia de los patrones de conducción en el desempeño del vehículo, tal es el caso que, en Bogotá, Colombia, se llevaron a cabo pruebas en un circuito urbano de 10 km en la ciudad que incluyó diferentes tipos de carreteras y condiciones de tráfico; en donde dos conductores profesionales manejaron los vehículos de prueba compuestos por 78 vehículos en total, 64 motores de gasolina y 14 vehículos modificados con gasolina y GNC. El objetivo de este estudio fue examinar las emisiones de los vehículos en una amplia variedad de condiciones de tráfico y tipos de carreteras mediante su relación con variables como velocidad, aceleración y carga del vehículo (Rodríguez y otros, 2016).

En Ecuador, se han llevado a cabo investigaciones similares que se enfocan en analizar aspectos relacionados con el comportamiento de conducción. Un estudio destacado es el realizado en la ciudad de Cuenca, donde se utilizó el tipo de ruta FTP (Procedimiento Federal de Pruebas) que simula un recorrido urbano con paradas regulares. El análisis se divide en dos etapas: una fase inicial desde cero y otra de estabilización. Durante estas etapas, se registraron señales como las revoluciones del motor, la posición del pedal del acelerador, la presión absoluta del colector de admisión, entre otras variables, con el objetivo de determinar su impacto en el consumo de combustible y las emisiones de gases (Bermeo & Figueroa, 2020).

De acuerdo con el más reciente informe de la Secretaría de Movilidad, se ha observado un considerable aumento en el parque automotor de la ciudad de Quito en los últimos años. Esto ha resultado en un incremento en el número de vehículos circulando por las calles. Se estima que aproximadamente 17,539 vehículos son añadidos al parque automotor de Quito cada año, lo cual representa un crecimiento promedio anual del 4.9% (Movilidad, 2015).

Este aumento en el parque automotor tiene un impacto significativo en la sostenibilidad ambiental y en el consumo de combustible en la ciudad. Cada vehículo adicional en la flota incrementa la demanda de combustible y aumenta la emisión de gases de efecto invernadero, lo cual afecta al medio ambiente en general (Movilidad, 2015).

Objetivo General.

Analizar el estilo de conducción de un vehículo con motor MPI mediante el ciclo de emisiones reales RDE para determinar su influencia en el consumo de combustible en la localidad de Quito, situada en Ecuador.

Objetivos Específicos.

- Estudiar el conjunto de teorías que explique cómo se determina el estilo de conducción de un piloto.
- Clasificar los tipos de conductor según su estilo de conducción mediante las señales PID'S tomadas a través de un OBD II.
- Inferir las diferencias de consumo de combustible de cada estilo de conducción y cuál es el más eficiente.
- Establecer un algoritmo que identifique al tipo conductor y su consumo de combustible

Marco teórico

El sistema de diagnóstico vehicular conocido como OBD (On Board Diagnostics) es una tecnología estándar en los vehículos modernos. Este sistema utiliza una combinación de sensores y computadoras a bordo del vehículo para monitorear y controlar diversos aspectos del funcionamiento del vehículo; el OBD recopila estos datos a través de una serie de sensores distribuidos en diferentes partes del vehículo. Estos sensores miden variables como la posición del acelerador, la velocidad de giro del motor, la temperatura del refrigerante, la presión del sistema de admisión, entre otros. La información recopilada se procesa en tiempo real por la unidad de control electrónica del vehículo, que utiliza algoritmos y programas para interpretar los datos y tomar decisiones basadas en ellos. (Huang Chen y otros, 2015).

El estilo de conducción puede ser determinado por una combinación de señales tomadas en tiempo real por el OBD. Aunque la importancia de cada señal puede variar según el enfoque y el modelo específico utilizado, algunas señales comunes que se consideran relevantes para determinar el estilo de conducción incluyen: la aceleración, el frenado o deceleración, las revoluciones del motor, la posición del acelerador, la velocidad del vehículo y el tiempo en

ralentí; además, de ser estas señales parámetros que dentro del funcionamiento del vehículo tienen una influencia ya sea positiva o negativa dentro de consumo de combustible (Thakallapelli y otros, 2016).

Se pueden utilizar distintos criterios para clasificar el comportamiento de conducción en base a las señales analizadas, por ejemplo, procesos estocásticos o estableciendo un umbral de un valor específico para cada señal, pero es este caso se considera la clusterización; el algoritmo de clustering examina estas señales y evalúa la similitud entre ellas en función de las características mencionadas. Por ejemplo, dos señales que tienen una velocidad similar, una posición de acelerador alta y un régimen de revoluciones del motor elevado pueden considerarse más similares entre sí que otras señales con valores diferentes en estas variables. El objetivo es que el algoritmo agrupe las señales en clusters donde los elementos compartan características similares en relación con el estilo de conducción. Por ejemplo, un cluster puede contener señales que indican un estilo de conducción agresivo, con altas velocidades, posiciones de acelerador y revoluciones del motor, mientras que otro cluster puede agrupar señales que indican un estilo de conducción normal, con velocidades y aceleraciones más moderadas. (Liimatainen, 2011).

Así mismo, el t-SNE (t-Distributed Stochastic Neighbor Embedding) es una técnica de reducción de dimensionalidad que permite visualizar datos de alta dimensión en un espacio de menor dimensión. Se utiliza el t-SNE para analizar y representar gráficamente la relación entre diferentes variables, como la velocidad, la aceleración y la eficiencia del combustible. Esta visualización ayuda a identificar patrones y tendencias en los datos recolectados durante la conducción, lo cual contribuye a mejorar el entrenamiento de las redes neuronales y la toma de decisiones (Liimatainen, 2011).

Una vez que las señales han sido clasificadas y agrupadas utilizando técnicas de clustering, se pueden utilizar como entrada para entrenar un árbol de decisión en MATLAB. El árbol de decisión es un algoritmo de aprendizaje supervisado que utiliza un conjunto de datos de entrada para construir un modelo que realiza decisiones basadas en reglas jerárquicas. En el caso de las señales del OBD, se pueden utilizar como características de entrada para el árbol de decisión los valores de las señales relevantes, como la velocidad, el régimen del motor, la posición del acelerador, entre otros. Cada señal se asocia a una etiqueta de clasificación

correspondiente al grupo o cluster al que ha sido asignada en el paso de clustering (Hussein & Panwai , 2016).

El árbol de decisión se entrena utilizando un conjunto de datos de entrenamiento que contiene tanto las señales de entrada como las etiquetas de clasificación correspondientes. Durante el entrenamiento, el árbol de decisión aprende a tomar decisiones basadas en las características de las señales para clasificar nuevas señales en los grupos definidos. Una vez que el árbol de decisión ha sido entrenado, se puede utilizar para clasificar nuevas señales del OBD y determinar su estilo de conducción correspondiente, ya sea agresivo o normal. Esto permite automatizar el proceso de clasificación de las señales y utilizar el modelo entrenado para realizar predicciones en tiempo real (Chen y otros, 2015).

Los datos utilizados para el entrenamiento del modelo pueden ser separados separados utilizando el criterio RDE (Real Driving Emissions) que establece límites de velocidades para diferentes tipos de vías, como rutas urbanas, rurales y de autopista. El criterio RDE es utilizado para simular condiciones de conducción realistas y evaluar las emisiones de los vehículos en diferentes entornos. Dentro de cada tipo de vía, se definen límites específicos de velocidad que representan las condiciones típicas de conducción en ese entorno. En el caso del entrenamiento del árbol de decisión, se toman datos de diferentes rutas urbanas, rurales y de autopista, y se separan en conjuntos de datos correspondientes a cada tipo de ruta según el criterio RDE. Esto significa que los datos utilizados para entrenar el árbol de decisión en MATLAB se basan en las velocidades límite establecidas para cada tipo de ruta (Garcia y otros, 2021).

Al separar los datos en función de los límites de velocidad del criterio RDE, se busca capturar las características específicas de conducción de cada entorno y mejorar la capacidad del árbol de decisión para clasificar las señales del OBD en los diferentes estilos de conducción según el tipo de vía. Esta separación de datos según el criterio RDE permite entrenar el árbol de decisión de manera más específica para cada tipo de vía, lo que potencialmente mejora la precisión del modelo en la clasificación del estilo de conducción en diferentes entornos viales.

CAPÍTULO I

ESTUDIO DEL COMPORTAMIENTO DE VARIABLES QUE INCIDEN EN EL ESTILO DE CONDUCCION.

3.1 Estado del arte

Para analizar el comportamiento del conductor es necesario recopilar una cantidad significativa de datos de conducción reales. Estudios del Programa de Investigación de Carreteras Estratégicas (SHRP2) realizados en Estados Unidos, han recopilado grandes cantidades de datos de conducción de conductores reales. Estos datos han ayudado a los investigadores a comprender las causas de los accidentes y a desarrollar medidas efectivas de prevención (Dingus y otros, 2006). También existen otros proyectos de investigación que recopilan datos de conducción realista, como la prueba operativa de campo europea (euroFOT) y UDRIVE, partiendo de esto, se han aplicado con éxito técnicas estadísticas de aprendizaje automático para modelar el comportamiento del conductor basado en datos. Se debe mencionar que los programas o estudios enfocados en la toma de datos reales de conducción son muy relevantes e importan dentro del desarrollo de modelos de predicción o determinación de comportamiento del conductor. Se han utilizado diversas técnicas estadísticas de aprendizaje automático para analizar el comportamiento del conductor. Por ejemplo, mediante la utilización de redes bayesianas se han realizado investigaciones para estudiar el comportamiento de frenado, mientras que para predecir el comportamiento del conductor se han utilizado modelo gráfico dinámico basado en un modelo oculto de Markov y aprendizaje profundo. También en la misma área de estudio sirven herramientas como la mezcla de distribuciones gaussianas (GMM) y sistemas dinámicos híbridos (HDS) para comprender el comportamiento de seguimiento y la toma de decisiones del conductor durante el seguimiento del automóvil, respectivamente. Además, se ha demostrado que una red neuronal recurrente (RNN) tiene un mejor rendimiento en la predicción del comportamiento de conducción que otros modelos como los modelos ocultos de Markov (HMM) y los dispositivos de vectores de soporte (SVM) (Miyajima & Takeda, 2016).

Los primeros modelos de comportamiento de conducción tenían como objetivo reducir la cantidad de accidentes de tránsito, razón por la cual, se centraban en la acción de seguir a un vehículo delantero, asumiendo que el vehículo de seguimiento reaccionaría a las acciones del líder. Sin embargo, con la aparición de modelos microscópicos de simulación de tráfico, se han desarrollado modelos más generales de aceleración que también consideran el

comportamiento de los conductores que no siguen de cerca a sus líderes, y modelos de cambio de carril para capturar las decisiones de aceleración y cambio de carril en diversas situaciones de conducción (Toledo y otros, 2007).

Con el paso de los años los modelados con respecto a los estilos de conducción fueron adquiriendo un enfoque más abierto y a su vez se realizaban a través de variables más específicas del vehículo; un ejemplo de esto es el estudio de la identificación del estilo de conducción a través del gráfico de velocidad realizado en Silesia. En dicho estudio, se emplearon registros obtenidos de discos tacógrafos analógicos para analizar los parámetros de conducción durante un periodo de más de 24 horas. Estos discos tacógrafos contienen tres gráficos independientes: el gráfico de velocidad, el gráfico de carretera y el gráfico del estado del conductor. En este estudio, se focalizó en el gráfico de velocidad para obtener información sobre la aceleración y frenado del vehículo (Signoretti y otros, 2020).

Con el objetivo de procesar el gráfico de velocidad analógico y convertirlo en datos digitales, se desarrolló una aplicación semiautomática. Esta aplicación utilizó los puntos de máxima y mínima del gráfico para calcular la velocidad a lo largo del tiempo y la posición en el eje temporal. Como resultado, se observaron cambios significativos en las características del perfil de velocidad del conductor, como un aumento en las maniobras de frenado y una clara identificación del número de cambios de aceleración después de un período de detención (Rygula , 2009).

Los métodos de investigación actuales para el análisis del comportamiento de conducción involucran tres técnicas principales: recopilación de datos de conducción, algoritmos de modelado de conducción y aplicaciones. La recopilación de datos de conducción se puede realizar a través de la captura de video automotriz, sensores montados en el automóvil y el diagnóstico a bordo (OBD); recientemente, se ha propuesto un nuevo método de análisis del comportamiento de conducción que utiliza los algoritmos OBD del vehículo y AdaBoost. Este método recopila información de funcionamiento del vehículo, como la velocidad del vehículo, las RPM del motor, la posición del acelerador y la carga del motor calculada, y utiliza AdaBoost para mejorar la precisión de los resultados. Este método se puede utilizar para detectar patrones en el comportamiento de conducción y prevenir accidentes de tráfico (Chen y otros, 2015). Así mismo otras metodologías incluyen los modelos de aprendizaje automático (ML, por sus siglas en inglés). Estos modelos pueden simular el proceso de

aprendizaje humano y mejorar las tareas de análisis de datos en tiempo real recopilados de varios vehículos. Los modelos de ML utilizan algoritmos guiados por datos para extraer información clasificada en tiempo real, como el aprendizaje supervisado, semisupervisado, no supervisado o de refuerzo, entre otros. Esto permite extraer información valiosa sin necesidad de instrucciones codificadas por programadores con experiencia parcial o total en el comportamiento al volante (Malik & Nandal, 2021).

3.2 Índices o factores de comportamiento

En la regulación RDE (Real Driving Emissions) se establecen límites para las emisiones de los vehículos durante la conducción en condiciones reales en carretera. Para ello, se han establecido tres parámetros relacionados con la dinámica de conducción que se miden durante la prueba: el $V \cdot A_{95}$ la RPA y la PEG (Triantafyllopoulos, 2018).

El parámetro $V \cdot A_{95}\%$ se refiere al producto de la velocidad y la aceleración positiva en el percentil 95 de los datos de conducción, lo que representa la aceleración más alta experimentada durante el 5% del tiempo de la prueba. Por otro lado, la RPA (Real-World-Driving Pattern Acceleration) se refiere a la ganancia de velocidad media durante las fases de aceleración, y la PEG (Positive Elevation Gain) representa la ganancia de altura media durante las fases de aceleración (Indrajuana y otros, 2020).

Estos parámetros se utilizan para cuantificar la dinámica de conducción y asegurar que las pruebas RDE se realicen en condiciones reales de conducción. Según la regulación RDE, los límites para estos parámetros deben ser cumplidos durante las partes urbanas, rurales y de autopista de la prueba.

3.2.1 Ciclo de emisiones reales (RDE)

Al evaluar las pruebas de emisiones en condiciones reales, es importante tener en cuenta una variedad de factores. Estos elementos engloban desde tácticas de variación de marchas, la fricción en la rodadura, la resistencia al aire, el modo de conducción, las condiciones del entorno y los cambios de altitud experimentados por el vehículo en superficies planas. No considerar estos factores puede afectar la precisión de las pruebas, lo que las hace menos confiables (Benavides Lima & Montenegro Nagua, 2023).

El organismo de investigación conjunto de la Comisión Europea llevó a cabo pruebas utilizando un dispositivo de medición de emisiones instalados en el vehículo, denominado como PEMS. Uno de estos experimentos, se enfocó en automóviles livianos y permitió medir las emisiones efectivas tanto en entornos de conducción de carretera como en entornos de laboratorio (Donateo & Giovinazzi, 2017).

El análisis reveló que existían notables disparidades entre ambos ensayos. Una de las causas de estas disparidades se relaciona con una directiva emitida en el año 2016 por la entidad supranacional europea, identificada como la normativa de la Comisión (UE) 2016/427. Esta directiva establece determinadas regulaciones para el ciclo RDE, que es cuando un vehículo se emplea como una forma de desplazamiento individual. Las regulaciones determinan la trayectoria, la velocidad, la distancia y la duración específicas de cada sesión, así como los aspectos del entorno, como condiciones climáticas, incluyendo la temperatura y la humedad, que deben ser considerados (Donateo & Giovinazzi, 2017).

Tabla 3.1: Especificaciones de viaje RDE

Parámetro	Viaje			Unidad
	URBANO	RURAL	AUTOPISTA	
Duración	01:30:00 ... 02:00:00			hh:mm:ss
Diferencia de altitud	<100			M
	URBANO	RURAL	AUTOPISTA	
Velocidad	<60	$60 \leq 90$	>90	km/h
Velocidad promedio	$15 \leq 40$	-	-	km/h
Distancia mínima	>16	>16	>16	Km
Porcentaje de distancia	$29 \leq 44$	$23 \leq 33$	$23 \leq 33$	%
Para el tiempo	>10	-	-	%
Tiempo a $v > 100$ km/h	-	-	>300	s

Parámetros del ciclo RDE, Fuente: (Garcia y otros, 2021)

En áreas urbanas, se aconseja mantener como velocidad limite 60 km/h , mientras que la velocidad promedio ideal debería situarse entre 15 y 30 km/h . Además, la distancia recorrida en la ruta debe ser superior a 16 km , y se espera que esta distancia represente entre el 28% y el 43% del total del recorrido, sin exceder o caer por debajo de estos límites. Por último, se sugiere que la duración de las paradas en esta ruta sea al menos del 10% del tiempo total de viaje (Benavides Lima & Montenegro Nagua, 2023).

En una ruta rural o interurbana, se recomienda mantener una velocidad que oscile entre los 60 y los 90 km/h, con un promedio de velocidad similar a las velocidades utilizadas en ese tipo de ruta. Asimismo, es importante que la distancia total del recorrido sea superior a 16 km. De manera similar a la ruta urbana, se espera que el porcentaje de distancia recorrida en esta ruta rural o interurbana esté comprendido entre el 23% y el 43% del recorrido total (Benavides Lima & Montenegro Nagua, 2023).

En una ruta de autopista, se recomienda mantener una velocidad mínima de 90 *km/h* el promedio de velocidad debe ser igual o mayor a 90 km/h, cabe destacar que, en este tipo de ruta, no es relevante el promedio de velocidad total, ya que las condiciones de la autopista no permiten mantener una velocidad constante superior a 90 km/h durante períodos prolongados. En cuanto a la distancia recorrida, se espera que esté comprendida entre el 23% y el 43% del total de la ruta establecida (Benavides Lima & Montenegro Nagua, 2023).

3.2.2 Aceleración positiva relativa (RPA)

Si bien la mayoría de los parámetros son comprensibles por sí mismos, es necesario realizar un análisis más detallado de ciertos parámetros especiales. Uno de los parámetros ampliamente utilizado es la Aceleración Positiva Relativa (RPA, por sus siglas en inglés). RPA es usado como un promedio relacionado con la velocidad de la aceleración y es comúnmente empleada para describir la frecuencia de aceleraciones que demandan grandes cantidades de energía. Su cálculo implica sumar los productos de la aceleración y la velocidad en cada segundo, y luego se divide esta suma por la longitud del segmento analizado. Cabe destacar que la RPA solo considera los valores de aceleración positiva, excluyendo las desaceleraciones (Braun & Rid, 2016).

En síntesis, las RPA proporcionan una medida cuantitativa de la intensidad de la aceleración positiva durante un período de tiempo o segmento de conducción determinado. Al centrarse solo en la aceleración positiva, la atención se enfoca en las aceleraciones que requieren un mayor empleo de energía y pueden afectar significativamente el consumo de combustible y las emisiones. Al comprender y analizar la RPA, se puede discernir mejor cómo el estilo de conducción afecta el rendimiento del vehículo y la eficiencia energética (Farinago & Santana, 2021). La expresión está representada en la Ecuación 1.1

$$RPA = \frac{\int_0^T (v_i \times a_i^+)}{x}, \left(\frac{m}{s^2}\right) \quad \text{Ec. (3.1)}$$

T= Tiempo total del ciclo (s).

x=Distancia total del recorrido (m).

v_i =Velocidad instantánea $\left(\frac{m}{s}\right)$.

a_i =Aceleración positiva instantánea $\left(\frac{m}{s^2}\right)$.

El RPA se define como un indicador clave de la variación en los patrones de velocidad de un vehículo. Además, se puede entender como la cantidad de energía requerida para todas las aceleraciones del vehículo en un ciclo determinado con el fin de recorrer una distancia específica. La expresión física que representa este parámetro se muestra en la Ecuación 1.2 (Farinago & Santana, 2021).

$$RPA = \frac{E_m}{m_v \cdot d}, \left(\frac{KWs}{Kgkm}\right) \quad \text{Ec. (3.2)}$$

E_m = Energía mecánica (KWs).

m_v =Masa del vehículo (Kg).

d= Distancia recorrida (Km).

3.2.3 $V \cdot A+$ (velocity times positive acceleration).

La operación $V \cdot A+$ (velocidad por aceleración positiva) consiste en multiplicar la velocidad del vehículo por la aceleración, pero solo se consideran los valores de aceleración que son positivos. Esta variable es ampliamente utilizada para evaluar y validar el comportamiento de conducción en pruebas de emisiones, ya que permite distinguir entre perfiles de conducción agresivos y más suaves (Diaz, 2020).

Esta variable se utiliza específicamente para evaluar la seguridad de la conducción, buscando minimizar la frecuencia de aceleraciones bruscas y demandantes de energía. Esto nos permite comprender mejor cómo los comportamientos de conducción agresivos pueden afectar tanto la eficiencia energética como la seguridad vial. Sería beneficioso adoptar un enfoque integral que tome en cuenta tanto los aspectos ambientales como los de seguridad, con el fin de fomentar una conducción responsable y eficiente desde un enfoque energético. Al analizar el percentil 95 de (VA) junto con la variable $V \cdot A+$, se obtiene una visión más completa del comportamiento de conducción (Bodisco y otros, 2019).

La manera de conducir un vehículo tiene un impacto significativo en las emisiones que se generan posteriormente. Por lo tanto, es crucial analizar los resultados de las pruebas de emisiones en carretera en conjunto con la forma en que se conduce. Con relación a la distancia recorrida, al establecer un umbral de $0,1 \text{ m/s}^2$, se puede calcular la proporción de tiempo dedicado a la desaceleración, el cruce y la aceleración. La expresión de aceleración está representada en la Ecuación 3 (Bodisco y otros, 2019).

$$a_i = \frac{v_{i+1} - v_{i-1}}{2 \times 3.6} \quad \text{Ec. (3.3)}$$

a =es la aceleración del vehículo (m/s).

v =es la velocidad del vehículo (km/ h).

i = es el i -ésimo paso de tiempo y está contenido entre 2 y $N - 1$,

donde N representa el número total de muestras, teniendo en cuenta que la frecuencia de muestreo es de 1 Hz y $a_0 = a_n = 0$ (Bodisco y otros, 2019).

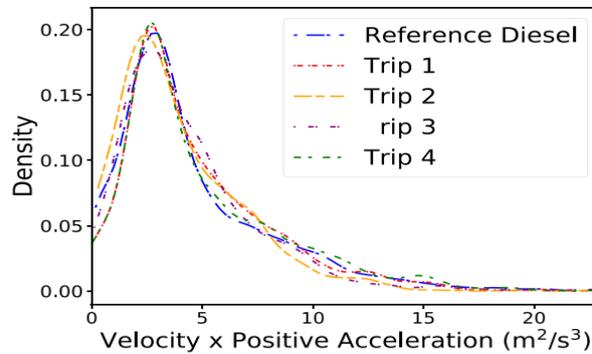
Ecuación 4, velocidad por aceleración.

$$VA_I = \begin{cases} \frac{a_i \times v_i}{3.6} & a_i > 0.1 \\ 0 & a_i \leq 0.1 \end{cases} \quad \text{Ec. (3.4)}$$

Al graficar la distribución de la velocidad por aceleración, se pueden visualizar los valores excluyendo las aceleraciones iguales o inferiores a $0,1 \text{ m/s}^2$. Los valores más elevados de velocidad por aceleración pueden indicar una conducción agresiva, mientras que los valores

más bajos pueden señalar una conducción más moderada. Como se puede visualizar en la figura 1.1 (Bodisco y otros, 2019),

Figura 3.1: Densidad velocidad por aceleración positiva.



Distribución de la velocidad por aceleración, Fuente: (Bodisco y otros, 2019)

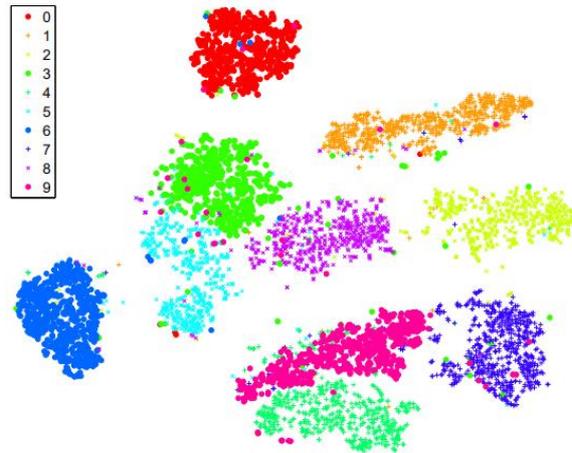
3.3 Aprendizaje supervisado, aprendizaje no supervisado

3.3.1 T-SNE (Incrustación de vecinos estocásticos distribuidos en T)

Es un método de reducción dimensional conocido como técnica de incrustación de vecinos estocásticos distribuidos en t, comúnmente denominado t-SNE (t-distributed stochastic neighbor embedding), desarrollado en 2008 por van der Maaten y Hinton. Esta técnica se ha extendido en el ámbito del aprendizaje automático debido a su capacidad sorprendente para generar representaciones visuales en dos dimensiones de datos con una gran cantidad de dimensiones, resultando en mapas visualmente persuasivos (Wattenberg y otros, 2016).

El objetivo consiste en obtener una representación precisa de un conjunto de puntos en un espacio de alta dimensión, pero en una dimensión más reducida, como el plano 2D. El algoritmo utilizado no es lineal y se ajusta a los datos originales mediante transformaciones distintas en diferentes regiones. Sin embargo, estas variaciones pueden generar cierta confusión en la interpretación de los resultados (Wattenberg y otros, 2016). En la figura 1.2 se puede apreciar una representación del T-SNE.

Figura 3.2: Visualización de T-SNE



Visualización de varios datos, Fuente: (Van der Maaten & Hinton, 2008)

Otra característica destacada de t-SNE es la presencia de un parámetro ajustable llamado "perplejidad", el cual permite equilibrar la atención entre los aspectos locales y globales de los datos. Este parámetro es una estimación aproximada de la cantidad de vecinos cercanos que cada punto tiene, dicho parámetro tiene un impacto complejo en las imágenes generadas. Sin embargo, la situación es más matizada que eso, ya que aprovechar al máximo t-SNE podría implicar analizar múltiples gráficos con diferentes valores de perplejidad (Wattenberg y otros, 2016).

El parámetro conocido como learning rate o tasa de aprendizaje, es el encargado de determinar la velocidad a la que un algoritmo aprende de los datos. Si se elige un valor alto para el learning rate, el algoritmo aprenderá de manera más rápida y se adaptará velozmente a los datos. Sin embargo, se debe tener precaución, ya que un learning rate excesivamente alto podría ocasionar que el algoritmo pase por alto soluciones importantes (Van der Maaten & Hinton, 2008).

Por lo tanto, resulta fundamental encontrar el learning rate adecuado. Este debe ser lo suficientemente alto como para aprender rápido, pero no tanto como para perder información importante. Este tampoco debe ser muy bajo porque de ser así el algoritmo demorará demasiado en aprender (Van der Maaten & Hinton, 2008).

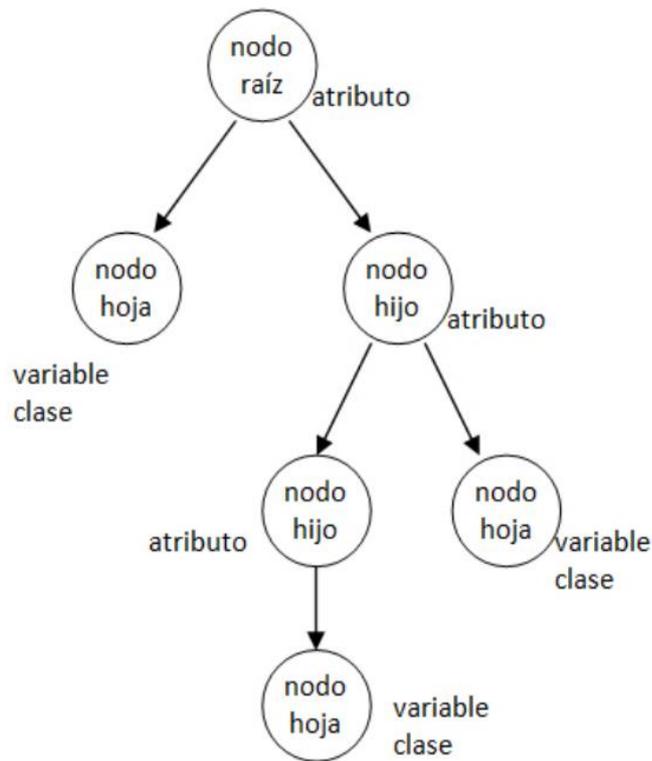
3.3.2 Árbol de decisiones DT

Un árbol de decisión es un modelo que utiliza el aprendizaje inductivo a partir de observaciones y lógica. Estos modelos son idénticos a los sistemas de predicción basados en condiciones, que clasifican y representan condiciones sucesivas para solucionar problemas. Los árboles de decisión son ampliamente utilizados y aceptados como modelos de clasificación. La información obtenida durante el proceso de aprendizaje se evidencia en la estructura del árbol (Barrientos Martínez y otros, 2009).

Un árbol se forma por nodos, hojas y ramas. La raíz del árbol de decisión es la etapa principal que marca el inicio de la clasificación. Los nodos internos son preguntas sobre cosas específicas del problema; cada pregunta se representa como un nodo secundario, y las ramas que salen de estos nodos tienen etiquetas con posibles respuestas. Las hojas son decisiones importantes sobre el problema que queremos resolver (ver Figura 1.3).

Este enfoque se basa en una narrativa descriptiva del problema, ya que proporciona una representación visual de la toma de decisiones. Describe las variables que se examinan, las acciones que deben realizarse y el orden en que se ejecutarán las decisiones. Cada vez que este modelo se implementa, sigue un camino único que depende del valor actual de la variable analizada. En este tipo de modelos, las variables pueden clasificarse en dos categorías: discretas o continuas (Barrientos Martínez y otros, 2009).

Figura 3.3: Organización de un árbol de decisiones.



Partes de un árbol de decisión, Fuente: (Barrientos Martínez y otros, 2009)

El proceso de construcción del árbol comienza con un nodo principal, en donde se elige un atributo de prueba y se divide el conjunto de entrenamiento en subconjuntos, de esta etapa se generan nodos adicionales para cada subconjunto y se repite este proceso. Si un nodo tiene diferentes tipos de objetos, se crea un nodo interno. Si un nodo tiene solo objetos de una categoría específica, se crea una hoja con la etiqueta correspondiente. En la segunda etapa, los nuevos objetos se clasifican utilizando el árbol de decisión. Se sigue el camino del árbol para determinar la categoría y la clase del objeto. Las decisiones en los nodos internos se basan en el atributo de prueba y guían el camino en el árbol (Solarte Martínez & Soto Mejía, 2011).

CAPÍTULO II METODOLOGÍA PARA LA CLASIFICACIÓN DE TIPOS DE CONDUCTOR SEGÚN SU ESTILO DE CONDUCCIÓN

Para el procedimiento de ensayo de datos de conducción y entrenamiento de un modelo de clasificación de estilo de conducción y consumo de combustible propuesto en este estudio, se siguen varias etapas, las cuales se describen en la Figura 2.1.

Figura 4.1: Metodología.

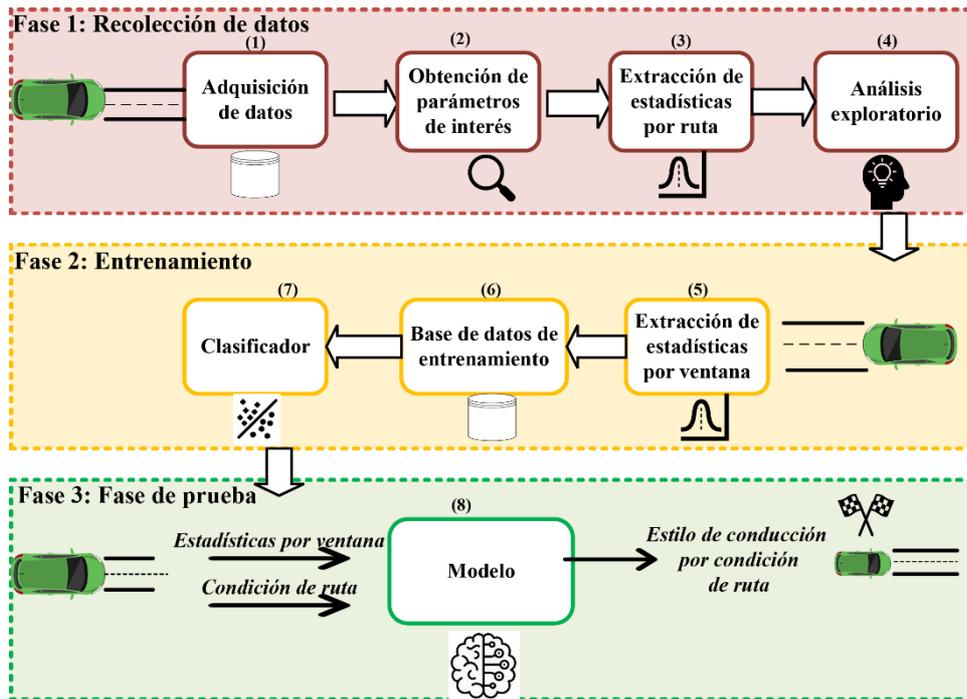


Diagrama de flujo de la metodología, Fuente: Autores

Los datos son adquiridos mediante un dispositivo data logger denominado Freematics One+; posteriormente con la información obtenida los datos son preprocesados para obtener parámetros significantes de la investigación de acuerdo con métricas estadísticas obtenidas de señales como la aceleración, velocidad, revoluciones por minuto, flujo de combustible por hora, posición de la mariposa de admisión, presión absoluta del múltiple de admisión y velocidad por aceleración positiva.

Una vez obtenidas las señales de interés, se procede a extraer características estadísticas específicas de cada señal en tiempo.

Posteriormente, se realiza un análisis exploratorio utilizando varias métricas estadísticas obtenidas de las señales. En este análisis, se examinan características estadísticas en función del etiquetado manual del estilo de conducción.

Luego, se procede a la extracción de estadísticas por ventana ; en esta etapa se junta la información de todas las rutas en una sola matriz, dicha información se divide en un segmentos de diez segundos, en donde de cada segmento se extraen características estadísticas de las señales en tiempo de interés, a las que posteriormente se las agrupa de acuerdo con el rango de velocidades propias del ciclo RDE, esto con el fin de establecer una base de datos amplia y consistente para entrenar el modelo de clasificación.

Una vez entrenado el modelo de clasificación, este es capaz clasificar el estilo de conducción en base a las condiciones del ciclo RDE (urbano, rural y autopista) indicando como se condujo en cada etapa y el consumo de combustible que existió en las mismas.

4.1 Adquisición de las Señales del OBD

4.1.1 Freematics ONE+

Las señales capturadas por el Freematics One+ (Ver figura 2.2) se toman en formato digital. El dispositivo utiliza el protocolo de comunicación OBD II (On-Board Diagnostics II) para acceder a los datos del vehículo. Este protocolo está estandarizado y define un conjunto de códigos y comandos que permiten la lectura de las señales del vehículo.

Los datos capturados por el Freematics One+ se envían en forma de tramas o paquetes de bytes, cada byte contiene información específica sobre una señal particular, como la velocidad, las RPM del motor, la temperatura, etc (DFRobot, 2014).

Figura 4.2: Freematics One+



Dispositivo de toma de datos, Fuente: (DFRobot, 2014).

Para procesar y utilizar estos datos, generalmente se realiza un proceso de decodificación y análisis de las tramas recibidas. Esto implica interpretar los bytes recibidos y extraer la información correspondiente a cada señal (Signoretti y otros, 2020).

Cabe destacar que el formato específico de los datos puede variar dependiendo de los protocolos de comunicación utilizados por el vehículo y el dispositivo Freematics One+.

El archivo CSV resultante contendrá las distintas señales capturadas, como velocidad, RPM del motor, temperatura, etc., con cada señal en una columna separada por comas.

Estos datos son transformados al formato del programa utilizado, para el acceso rápido y eficiente a los mismos.

4.1.2 Tipo de vehículo

El vehículo utilizado para la adquisición de datos y posterior prueba del modelo clasificador es el Changan CS15 SUV 4X2, el cual es un vehículo producido por el fabricante automotriz chino Changan Motors cuyas especificaciones técnicas se pueden ver detalladas en la Tabla 2.1; es importante tener en cuenta que Changan Motors es una marca emergente en el mercado automotriz global y van expandiendo su presencia en varios países, incluido Ecuador (Auto, 2022).

Tabla 4.1: Ficha técnica.

Modelo	Changan cs15 suv 4x2
Año	2021
Motor	Blue core 1.5l 16v dohc vvt euro v
Velocidad máxima	161 km/h
Potencia	105 HP
Torque	145 N-m

Transmisión	Manual 5 velocidades + reversa
Dimensiones y capacidades	Largo (mm) 4135
	Ancho (mm) 1740
	Alto (mm) 1630
	Distancia entre ejes (mm) 2520
	Capacidad de baúl (L) 375
	Peso en vacío (kg) 1210
Llantas	205/50 R17 (Aros de aluminio)
Tipo de distribución	Cadena
Suspensión	Delantera: independiente tipo McPherson Posterior: semindependiente con barra de torsión

Especificaciones técnicas del vehículo de pruebas, Fuente: (Auto, 2022)

4.1.3 Acondicionamiento del vehículo para las pruebas experimentales

Para asegurar la precisión en la toma de datos, es indispensable realizar un mantenimiento preventivo en el vehículo para garantizar condiciones óptimas de funcionamiento. Acorde a las recomendaciones del fabricante y su kilometraje se procede a realizar al cambio del aceite del motor y su respectivo filtro, y también sustituir el filtro de aire y de cabina para garantizar un flujo de aire limpio hacia el motor. Además, se verifica el estado de los neumáticos, verificando que se encuentren en óptimas condiciones, parámetros como presión de inflado de los neumáticos, así como del estado de los amortiguadores para garantizar un buen desempeño del vehículo.

4.1.4 Pruebas de ruta para la adquisición de datos

Para la adquisición de datos, se ha realizado un estudio en el Distrito Metropolitano de Quito, que abarca diferentes sectores como el norte, sur y los valles. Estas rutas incluyeron una variedad de condiciones de tráfico, carreteras y autopistas para capturar una amplia gama de situaciones de conducción, en donde el objetivo principal es recopilar datos representativos de diferentes estilos de conducción.

En el manejo del vehículo en los sectores mencionados, se implementa un enfoque en el que se condiciona al piloto para replicar comportamientos tanto de un estilo de conducción normal, así como de uno más agresivo

Para el estilo de conducción normal, se instruye al piloto para que mantenga un comportamiento típico en términos de aceleraciones y frenados suaves, un uso moderado del acelerador y una conducción en general más calmada y controlada, por otro lado, para el estilo de conducción agresivo, que se mantenga enfoque más dinámico y en ocasiones más agresivo, esto implicar realizar aceleraciones y frenados bruscos, utilizar el acelerador de manera más intensa y, en general, exhibir un estilo de conducción más enérgico.

Estos estilos de conducción se caracterizan por parámetros específicos que pueden ser medidos y analizados, como la magnitud y la frecuencia de las aceleraciones y frenados, la respuesta del acelerador y otros indicadores relacionados con el comportamiento del conductor

Al recopilar datos en estas condiciones y con estos estilos de conducción, se logra obtener una muestra más completa y representativa de las diferentes situaciones que se pueden presentar en un contexto de conducción cotidiano realista. Esto proporciona un conjunto de datos consistente para el análisis y la evaluación de las señales capturadas, permitiendo un estudio más detallado de los diferentes estilos de conducción y sus efectos en el rendimiento del vehículo y otros aspectos relacionados.

La cantidad de rutas, así como la distancia y el estilo de conducción que se mantuvo en cada una de ellas se encuentra detalla en la Tabla 2.2.

Tabla 4.2: Rutas de prueba.

Nº Ruta	Etiqueta/Estilo	Distancia [Km]	Nº Ruta	Etiqueta/Estilo	Distancia [Km]

1	'Agresivo'	14,612958	25	'Agresivo'	28,521057
2	'Normal'	19,109997	26	'Normal'	14,606273
3	'Normal'	3,9347948	27	'Agresivo'	14,713938
4	'Normal'	1,9095278	28	'Agresivo'	29,319884
5	'Normal'	3,4835639	29	'Normal'	19,058341
6	'Normal'	14,135069	30	'Normal'	0,3829012
7	'Normal'	0,9215988	31	'Agresivo'	1,9110941
8	'Agresivo'	13,824117	32	'Normal'	19,080656
9	'Agresivo'	27,876727	33	'Normal'	3,0743565
10	'Normal'	2,3186698	34	'Normal'	17,197881
11	'Normal'	19,092128	35	'Agresivo'	29,32821
12	'Normal'	11,80442	36	'Normal'	12,877124
13	'Normal'	19,215375	37	'Normal'	18,954299
14	'Normal'	0,3591867	38	'Normal'	299,33312
15	'Normal'	14,967982	39	'Agresivo'	20,247298
16	'Agresivo'	22,78302	40	'Agresivo'	19,59889
17	'Agresivo'	27,705523	41	'Normal'	2,7202194
18	'Normal'	19,402744	42	'Agresivo'	20,026005
19	'Normal'	5,2916929	43	'Normal'	0,8300864
20	'Normal'	19,130477	44	'Normal'	0,4431728
21	'Normal'	0,8819799	45	'Agresivo'	13,900537
22	'Normal'	1,969321	46	'Normal'	13,046304
23	'Agresivo'	19,98579	47	'Normal'	1,3365062
24	'Normal'	19,098662	Distancia total		904,32348

Características de las rutas de prueba, Fuente: Autores

Los datos tomados de las rutas descritas se almacenan en una matriz multidimensional, lo que permite un acceso rápido a elementos individuales y operaciones vectorizadas. Además, con el uso de MATLAB una herramienta para procesar y analizar datos, al convertir los datos en formato CSV a formato MAT, se pueden importar fácilmente las operaciones matemáticas, análisis estadístico, visualización de datos, etc (Signoretti y otros, 2020).

4.2 Cálculo de señales de parámetros de interés

Una variable de entrada es aquella que se utiliza como predictor o causa en un modelo o experimento. Es decir, es una variable que se considera como influyente en la variable de salida o respuesta que se desea analizar. En el caso de este estudio se consideran de interés aquellos parámetros detallados en la tabla 2.3, los cuales definen el estilo de conducción y que fueron extraídos de cada una de las rutas tomadas.

Tabla 4.3: Variables de entrada.

Variable de entrada (señales en tiempo)	Sensor	Unidad de medida
Velocidad	VSS	<i>Km/h</i>
Posición del acelerador	TPS	%
Revoluciones del motor	CKP	<i>rpm</i>
Presión absoluta en el colector	MAP	<i>kPa</i>
Aceleración	Calculada	<i>m/s²</i>
Flujo de combustible	Calculada	<i>l/h</i>
VPA	Calculada	$\frac{m^2}{s^3}$

Variables consideradas para el análisis, Fuente: Autores.

Las señales de las variables mencionadas dependen del tiempo y proporcionan información crítica que permite ajustar, adaptar o estudiar el funcionamiento del vehículo en tiempo real.

4.2.1 Índices de comportamiento

Otro parámetro calculado que se considera de interés para la investigación es el RPA (Relative Positive Acceleration), el cual es un índice que puede proporcionar indicios sobre

la agresividad de conducción. Para realizar de manera correcta el análisis del RPA resulta crucial establecer un umbral para su análisis y evaluación. Esto se debe a que la mayoría de las aceleraciones registradas durante toda la ruta son o tienden a ser cercanas a cero. Por lo tanto, se ha considerado fijar un umbral en aceleraciones mayores a 0.1 para distinguir y analizar las aceleraciones positivas más significativas (Barlow y otros, 2009).

Al establecer un umbral de 0.1, se busca filtrar y considerar únicamente aquellas aceleraciones que superen dicho valor. Esto permite identificar las aceleraciones relevantes en relación con la conducción, al tiempo que se descartan las variaciones de velocidad insignificantes o causadas por fluctuaciones normales.

Este enfoque en las aceleraciones positivas más destacadas, que tienen un impacto más relevante en la dinámica de conducción permite detectar un estilo de conducción más agresivo o enérgico, al establecer el umbral se logra una evaluación más precisa y significativa de la agresividad de conducción.

4.3 Extracción de estadísticas por señal en tiempo

En el análisis exploratorio de las señales en tiempo se obtienen características estadísticas como la media, desviación estándar y simetría, sin embargo, no es posible o útil calcular dichas características de todas las variables de interés, lo mencionado se encuentra detallado en la Tabla 2.4.

Estas estadísticas son obtenidas de cada una de las rutas y proporcionan información valiosa sobre las características y comportamiento de las señales, lo que contribuye a comprender mejor el estilo de conducción.

- **Media.** - En el contexto del estilo de conducción, comparar las medias entre diferentes segmentos de la ruta o diferentes estilos de conducción puede ayudar a identificar diferencias significativas en el comportamiento de conducción.
- **Desviación estándar.** - En el análisis exploratorio, la desviación estándar de las señales en tiempo puede proporcionar información sobre la estabilidad y la consistencia del estilo de conducción. Una desviación estándar alta puede indicar cambios bruscos y variabilidad en la velocidad, posición del acelerador, revoluciones

del motor y presión absoluta en el colector, lo que podría sugerir una conducción más agresiva o errática.

- **Simetría.** - La simetría es una medida que indica si una distribución de datos es simétrica o asimétrica. En el contexto del estilo de conducción, la simetría de las señales en tiempo puede revelar patrones de aceleración y desaceleración. Una distribución simétrica puede indicar una conducción más equilibrada, mientras que una distribución asimétrica puede indicar cambios bruscos y diferencias en la aceleración y desaceleración. El análisis de la simetría de las señales puede proporcionar información sobre la suavidad y la consistencia en el control del vehículo.

Tabla 4.4: Características estadísticas

Acrónimo	Variable	Promedio	Desviación estándar	Simetría
MAP	Presión Absoluta del Múltiple	✓	✓	✓
RPM	Revolución por minuto	✓	✓	✓
TPS	Posición de la mariposa	✓	✓	✓
VA	Velocity Times Positive acceleration	✓	✓	✓
VSS	Velocidad	✓	✓	✓
ACC	Aceleración	-	✓	✓
FLU	Flujo de combustible	✓	✓	✓

Información de las estadísticas de las señales en tiempo, Fuente: Autores.

La media de la aceleración por ruta es cero o tiende a cero en la mayoría de los casos, ya que gran parte del tiempo el acelerador no se encuentra presionado. Por lo tanto, calcular esta estadística no aporta nada al análisis y en este caso es omitida.

Además, se obtiene el cálculo del percentil 95 de VPA (Velocity Positive Acceleration), debido a que es útil en el análisis del estilo de conducción ya permite identificar las aceleraciones positivas más altas y destacadas en relación con la velocidad. Al calcular el percentil 95 de la velocidad por aceleración positiva, se seleccionan aquellos valores de velocidad que corresponden al 5% más alto de las aceleraciones positivas. Estos valores representan las situaciones en las que se ha alcanzado una velocidad notablemente alta durante las aceleraciones, lo cual puede indicar una conducción más agresiva o enérgica (Mouzouras, 2022).

En el caso de la variable RPA, al ser un índice calculado por ruta en lugar de ser una señal en tiempo no es posible obtener medidas estadísticas como la media, la desviación estándar o la simetría directamente.

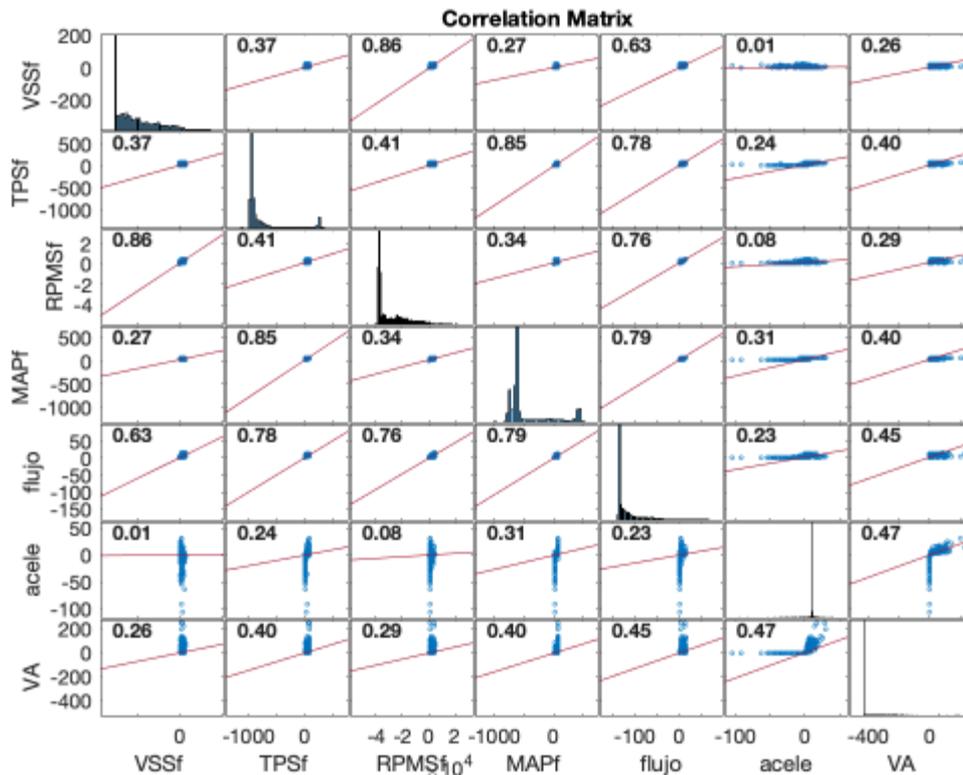
4.4 Análisis exploratorio

Realizar un estudio de correlación entre las señales en tiempo de las variables de interés es crucial para analizar los datos y determinar si existe una relación lineal entre dos variables, así como para cuantificar la fuerza y dirección de dicha relación. Esto nos ayuda a comprender si las variables dependen o son independientes entre sí. Al analizar la correlación entre las señales de interés y el consumo de combustible, podemos determinar si hay una relación significativa entre ellos. (Kohonen, 2012).

4.4.1 Análisis de correlación en una ruta normal

En esta etapa, se examina el nivel de correlación entre los parámetros más relevantes y el consumo de combustible tanto en una ruta normal como en una ruta agresiva. Para la ruta normal, se presentan los resultados de la matriz de correlación en la Figura 2.3. Esta matriz muestra las relaciones entre las variables de interés con el consumo de combustible (denominado flujo en la matriz) en una ruta con un estilo de conducción normal.

Figura 4.3:Matriz de correlación



Matriz de correlación de una ruta normal, Fuente: Autores.

Al analizar la matriz de correlación en base al consumo de combustible, se pueden observar la siguiente relación entre las variables y el consumo de combustible:

El sensor VSS y las RPM tienen una correlación positiva moderada con el consumo de combustible, esto indica que a medida que la velocidad del vehículo y las revoluciones del motor aumentan, también tiende a aumentar el consumo de combustible.

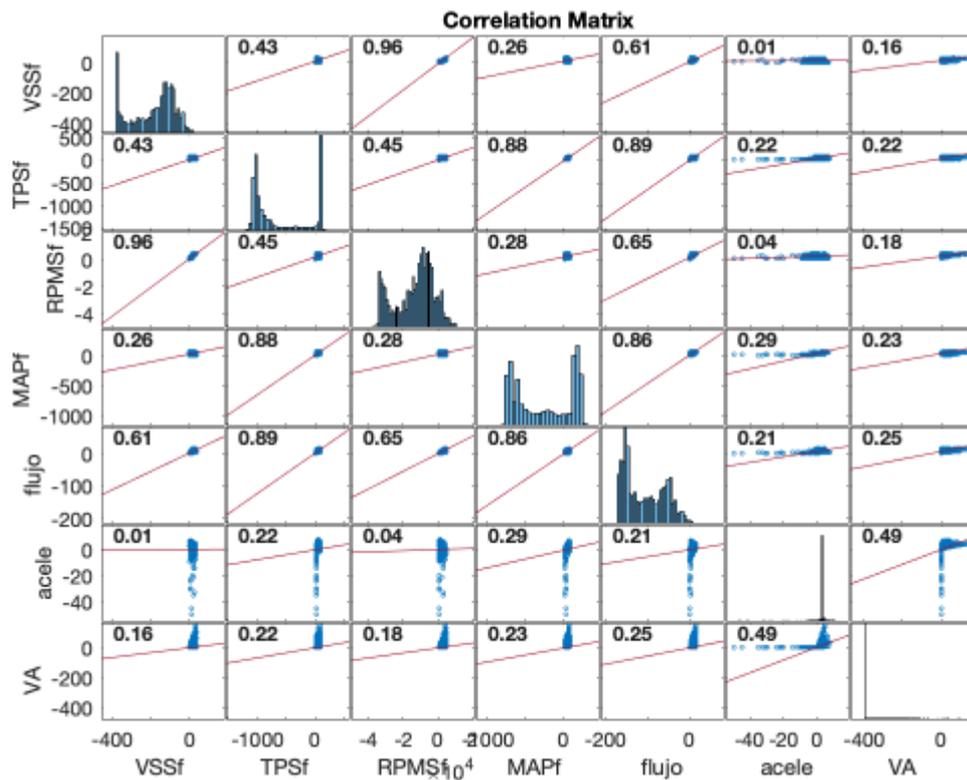
El sensor MAP y TPS muestran una correlación positiva alta con el consumo de combustible, esto indica que a medida que la presión en el colector y la posición del acelerador aumentan, también tiende a aumentar el consumo de combustible.

En el caso de la aceleración y la variable VA existe un nivel bajo de correlación con respecto al consumo de combustible, esto significa que los valores de estas variables no están relacionados con el consumo y que no hay una tendencia clara de cambio conjunto; un nivel bajo de correlación implica que los cambios en el consumo de combustible no se pueden predecir o explicar por los cambios en la aceleración y la variable VA.

4.4.2 Análisis de correlación en una ruta agresiva

Se lleva a cabo un análisis de correlación de las variables de interés con el flujo de combustible en una ruta agresiva. Esto se realiza con el propósito de contrastar la información y determinar si existen cambios en el nivel de correlación al modificar el estilo de conducción. Los resultados de la matriz de correlación para una ruta con un estilo de conducción agresivo se muestran en la Figura 2.4. Estos resultados proporcionan una visión detallada de del índice de correlación entre las variables de interés y su asociación con el flujo de combustible en la ruta agresiva.

Figura 4.4: Matriz de correlación



Matriz de correlación de una ruta agresiva, Fuente: Autores

Al examinar la matriz de correlación para la ruta agresiva en relación con el consumo de combustible, se pueden identificar las siguientes relaciones entre las variables y el consumo de combustible:

El sensor VSS y las RPM muestran una correlación moderada positiva con el flujo de combustible, lo que indica que a medida que la velocidad del vehículo y las revoluciones del motor aumentan, tiende a aumentar el consumo de combustible.

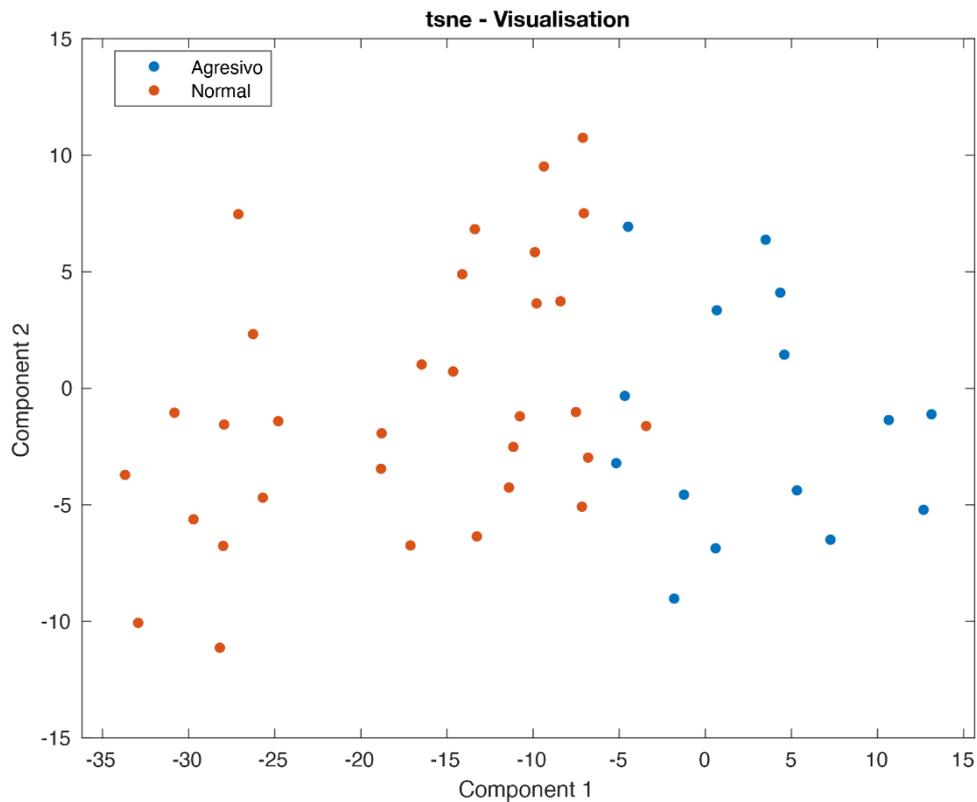
El sensor TPS y el sensor MAP presentan una correlación alta con el flujo de combustible, lo que sugiere que a medida que la posición del acelerador y la presión en el colector aumentan, también tiende a aumentar el consumo de combustible.

La aceleración y el VA (Velocity times Positive Acceleration) muestran una correlación débil con el consumo de combustible, lo que indica que estos parámetros no tienen un impacto significativo en la cantidad de combustible utilizado durante la conducción. La baja correlación sugiere que los cambios en la aceleración o en la velocidad multiplicada por la aceleración no están directamente relacionados con variaciones en el consumo de combustible.

4.4.3 Tsne del estilo de conducción

La visualización del t-SNE en la Figura 2.5 revela una clara agrupación de las estadísticas de las rutas según el estilo de conducción normal y agresivo. Esto confirma que las medidas estadísticas calculadas por ruta desempeñan un papel crucial en la diferenciación entre conducción agresiva y conducción normal.

Figura 4.5: T-sne



Agrupación de datos mediante técnica T-sne, Fuente: Autores.

4.5 Modelo de clasificación

Una vez realizado el análisis exploratorio, se recopilan todas las rutas utilizadas para construir una base de datos que servirá como entrada para un modelo de clasificación. Este modelo determinará el estilo de conducción, ya sea normal o agresivo, en diferentes condiciones de RDE, como urbano, rural y autopista.

Con este propósito, la base de datos se conforma de estadísticas de señales en tiempo registradas en segmentos de 10 segundos. Dentro de cada segmento, se calculan la desviación estándar y la media de variables que fueron determinadas como relevantes en el análisis exploratorio, el flujo de combustible, la aceleración, las RPM, TPS, MAP y VA; al extraer estas características estadísticas, se obtiene información más concisa y resumida que puede ser utilizada para entrenar el modelo de clasificación. Estas características representan aspectos importantes del comportamiento del vehículo durante esos intervalos de tiempo y pueden ser utilizadas como atributos o variables predictoras en el modelo.

El objetivo de este proceso es enriquecer la base de datos y proporcionar más información cuantitativa que permita al modelo de clasificación aprender patrones y características distintivas de cada estilo de conducción (normal o agresivo). Al incluir estas características estadísticas, se brinda al modelo una perspectiva más completa y se mejora su capacidad para realizar predicciones precisas y distinguir entre los estilos de conducción.

Una vez que se ha construido la base de datos general y se han extraído las características relevantes de las señales en tiempo, se procede a aplicar las condiciones de ruta dadas por el ciclo RDE (Real Driving Emissions) a esta base de datos.

El objetivo de aplicar estas condiciones de ruta del ciclo RDE a la base de datos es simular un escenario de prueba más cercano a las condiciones reales de conducción. Esto permite evaluar el desempeño del modelo de clasificación en situaciones más representativas y garantizar su capacidad para clasificar rutas que cumplan con las características del ciclo RDE.

Tabla 4.5: Ciclo RDE

Parámetro	Viaje			Unidad
	URBANO	RURAL	AUTOPISTA	
Duración	01:30:00 ... 02:00:00			hh:mm:ss
Diferencia de altitud	<100			M
Velocidad	<60	$60 \leq 90$	>90	km/h
Velocidad promedio	$15 \leq 40$	-	-	km/h
Distancia mínima	>16	>16	>16	Km
Porcentaje de distancia	$29 \leq 44$	$23 \leq 33$	$23 \leq 33$	%
Para el tiempo	>10	-	-	%
Tiempo a $v > 100$ km/h	-	-	>300	s

Condiciones del ciclo RDE, Fuente: (Garcia y otros, 2021).

Finalmente, es importante mencionar que se ha añadido un predictor adicional a la base de datos, que corresponde a la condición RDE de cada segmento, de acuerdo con su velocidad media y las condiciones especificadas en la Tabla 2.5; la etiqueta de salida del modelo es normal o agresivo. La Tabla 2.6 resume los predictores utilizados para entrenar el árbol de decisión

Tabla 4.6: Predictores

N.º	Predictor	N.º	Predictor
1	Media de la velocidad	9	Media del TPS
2	Desviación estándar de la velocidad.	10	Desviación estándar del TPS
3	Media del flujo	11	Media del VA
4	Desviación estándar del flujo	12	Desviación estándar del VA
5	Media del MAP	13	Media de la aceleración
6	Desviación estándar del MAP	14	Desviación estándar de la aceleración
7	Media del RPM	15	Condición RDE
8	Desviación estándar del RPM		

Predictores por cada segmento usados para entrenar el árbol de decisión, Fuente: Autores

En la etapa de prueba, el modelo de clasificación se verifica utilizando una ruta que cumplan con las condiciones del ciclo RDE. Esto permitirá evaluar su capacidad para clasificar correctamente estas rutas de acuerdo con el estilo de conducción (normal o agresivo), y proveer información del consumo de combustible en las secciones urbano, rural y autopista y determinar si es capaz de generalizar y adaptarse a diferentes escenarios de conducción. Es importante mencionar que la ruta de prueba no se utilizó para entrenar el modelo de clasificación.

CAPITULO III

ESTUDIO COMPARATIVO DEL CONSUMO DE COMBUSTIBLE EN DIFERENTES MODOS DE CONDUCCIÓN

5.1 Análisis de regresión lineal múltiple

La regresión lineal múltiple es una técnica estadística utilizada para predecir una variable dependiente a partir de múltiples variables independientes o predictores, los coeficientes obtenidos en el procedimiento de regresión lineal múltiple proporcionan información sobre la relación entre cada predictor y la variable de interés. Es importante destacar que los coeficientes de regresión deben interpretarse en relación con los otros predictores incluidos en el modelo. Esto se debe a que la regresión lineal múltiple tiene en cuenta las relaciones simultáneas entre los predictores y la variable dependiente. Por lo tanto, el impacto de un predictor puede modificarse por la presencia y las interacciones con los demás predictores (Rodríguez & Mora, 2021).

En este caso, se aplicó la regresión lineal múltiple para predecir el flujo de combustible utilizando varios predictores: RPM medio, desviación estándar de la aceleración, TPS medio, MAP medio, VA medio, VA 95 percentil, VSS medio y RPA.

Al analizar los coeficientes asociados a cada predictor, podemos interpretar su impacto relativo en la predicción del flujo medio de combustible. Un coeficiente positivo indica una relación positiva entre el predictor y el flujo medio de combustible, lo que significa que a medida que el valor del predictor aumenta, se espera que el flujo medio de combustible también aumente. Por otro lado, un coeficiente negativo indica una relación negativa, lo que implica que a medida que el valor del predictor aumenta, se espera que el flujo medio disminuya.

Al conocer los coeficientes asociados a cada predictor, visualizados en la Tabla 3.1, podemos identificar qué variables tienen una mayor influencia en la predicción del flujo medio en una ruta. Esto nos permite comprender mejor las variables que afectan el consumo de combustible y nos brinda información útil para tomar decisiones y optimizar el rendimiento de los vehículos en términos de eficiencia de combustible.

Tabla 5.1: Predictores

Coefficiente de regresión	Predictor
RPM Media	0.3497
Desviación estándar Aceleración	-0.0334
TPS Media	0.1382
MAP Media	0.3069
VA Media	-0.0847
VA 95 Percentil	0.0835
VSS Media	0.2969
RPA	0.0358

Predictores de la regresión lineal múltiple, Fuente: Autores

Al analizar los coeficientes de regresión mostrados en la tabla 3.1, se puede observar que algunas variables tienen una influencia positiva sobre el flujo de combustible, lo que significa que a medida que aumentan, el flujo de combustible tiende a aumentar también. Por otro lado, hay variables que presentan una influencia negativa, lo que indica que a medida que aumentan, el flujo de combustible tiende a disminuir.

En la regresión lineal múltiple se puede construir una ecuación que relacione los predictores con la variable de respuesta, por tanto, de acuerdo con la regresión múltiple, el flujo medio estimado está dado por la siguiente ecuación:

$$\begin{aligned} \text{flujo}_{medio} = & 0.3497 \cdot RPM_{medio} - 0.0334 \cdot ACC_{std} + 0.1382 \cdot TPS_{medio} \quad \text{Ec. (5.1)} \\ & + 0.3069 \cdot MAP_{medio} - 0.0847 \cdot VA_{medio} + 0.0835 \\ & \cdot VA_{95percentile} + 0.0358 \cdot RPA \end{aligned}$$

En este estudio, se asume que todas las variables están normalizadas utilizando su respectivo z-score. El z-score se calcula restando el valor individual de la media de la distribución y dividiendo el resultado por la desviación estándar. La regresión lineal múltiple se

implementó utilizando la función "mvregress", mientras que el cálculo del z-score se realizó utilizando la función "zscore" de MATLAB.

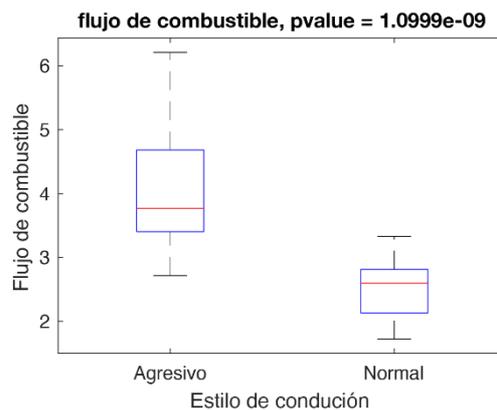
5.2 Boxplot de variables de interés en función del estilo de conducción

A continuación, se realiza un análisis estadístico de las variables de interés donde se verifica si existe diferencia estadística con un nivel de significancia del 0.05 entre los grupos agresivo y normal

5.2.1 Flujo de combustible

Se observa una diferencia estadísticamente significativa en el flujo de combustible entre la conducción agresiva y la conducción normal. La diferencia promedio es de 1 litro por hora.

Figura 5.1: Boxplot flujo de combustible

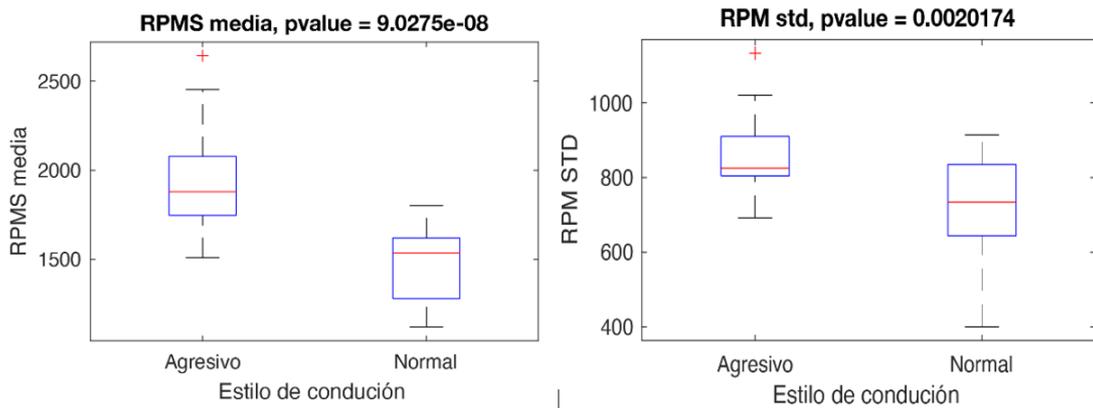


Boxplot consumo de combustible vs estilo de conducción, Fuente: Autores

5.2.2 RPM

Se identifica una diferencia estadísticamente significativa entre el promedio y la desviación estándar de las revoluciones del motor y los estilos de conducción agresiva y normal. Esta diferencia es relevante en el contexto del consumo de combustible, ya que el análisis de correlación previo reveló una fuerte relación entre las RPM y el consumo.

Figura 5.2: Boxplot RPM

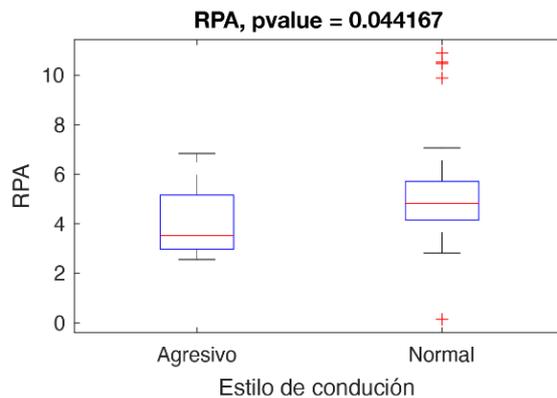


Boxplot RPM vs estilo de conducción, Fuente: Autores.

5.2.3 RPA

En el caso del índice RPA, no se encontró una diferencia estadísticamente significativa entre los estilos de conducción normal y agresivo. Esto indica que no hay una diferencia considerable en las muestras de este índice entre ambos estilos de conducción. Esta conclusión se alinea con el análisis de correlación lineal, donde se evidenció que no existe una relación entre el RPA y el consumo de combustible.

Figura 5.3: Boxplot RPA

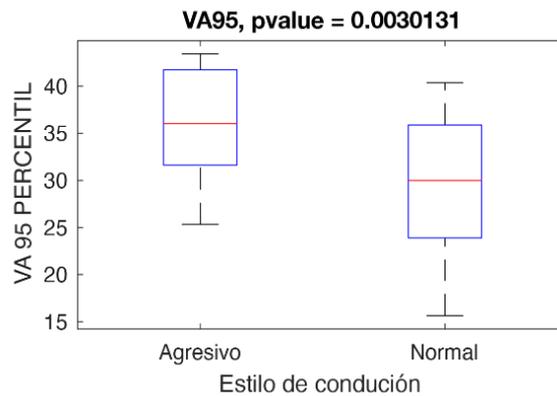


Boxplot RPA vs estilo de conducción, Fuente: Autores.

5.2.4 VA Percentil 95

El análisis muestra que hay una diferencia estadísticamente significativa en el percentil 95 del índice VA entre los estilos de conducción normal y agresivo, evidenciado por un p-value bajo, esto es importante en el contexto del consumo de combustible debido a la correlación encontrada anteriormente entre esta variable y el consumo de combustible.

Figura 5.4: Boxplot VA 95 percentil

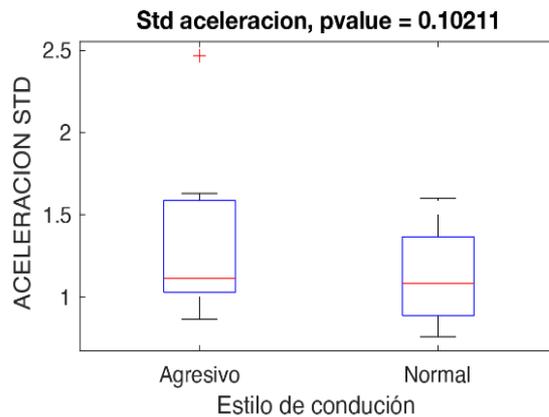


Boxplot VA 95 percentil vs estilo de conducción, Fuente: Autores.

5.2.5 Aceleración

La desviación estándar de la aceleración no presenta una diferencia estadísticamente significativa entre los estilos de conducción agresivo y normal. Esto se debe a que la desviación estándar de la aceleración se ve atenuada debido a que la mayoría de los valores tienden a cero.

Figura 5.5: Boxplot aceleración



Desviación estándar de la aceleración vs estilo de conducción, Fuente: Autores

5.2.6 Diferencias en consumo de combustible

En la etapa final del estudio, se realizó un t-test con la finalidad de analizar si existía una diferencia significativa en términos estadísticos en el consumo medio de combustible entre las rutas de conducción agresiva y las rutas de conducción normal. Este análisis se realizó teniendo en cuenta las diferentes velocidades asociadas a cada una de las condiciones del ciclo RDE y utilizando el consumo medio calculado por segmento de 10 segundos. En la tabla 3.2 se pueden apreciar los resultados.

Tabla 5.2: t-test consumo de combustible

Condición RDE	Consumo medio de combustible según estilo de conducción		Diferencia en consumo	p-value
	Agresivo	Normal		
URBANO	3.101	2.344	0.757	0
RURAL	5.813	5.169	0.644	2,73E-146
AUTOPISTA	4.593	4.511	-	0.1833

Consumo de combustible por estilo de conducción y condición RDE, Fuente: Autores

En la etapa urbana, se observa que el consumo medio de combustible del estilo de conducción agresivo es significativamente mayor que el consumo medio del estilo de conducción normal, siendo esta diferencia de aproximadamente 0.757 l/h , como también se puede confirmar por el p-value inferior a 0.05.

En la etapa rural, también se evidencia que el consumo medio de combustible del estilo de conducción agresivo es mayor que el consumo medio del estilo de conducción normal, con una diferencia aproximada de 0.644 l/h, lo cual se verifica mediante un p-value menor a 0.05.

En la etapa de autopista, el análisis estadístico muestra que no hay una diferencia significativa en el consumo medio de combustible entre el estilo de conducción agresivo en comparación al estilo de conducción normal, esto debido a que, a altas velocidades, las diferencias en el comportamiento de conducción se atenúan debido a la dificultad de mantener un patrón de conducción constante.

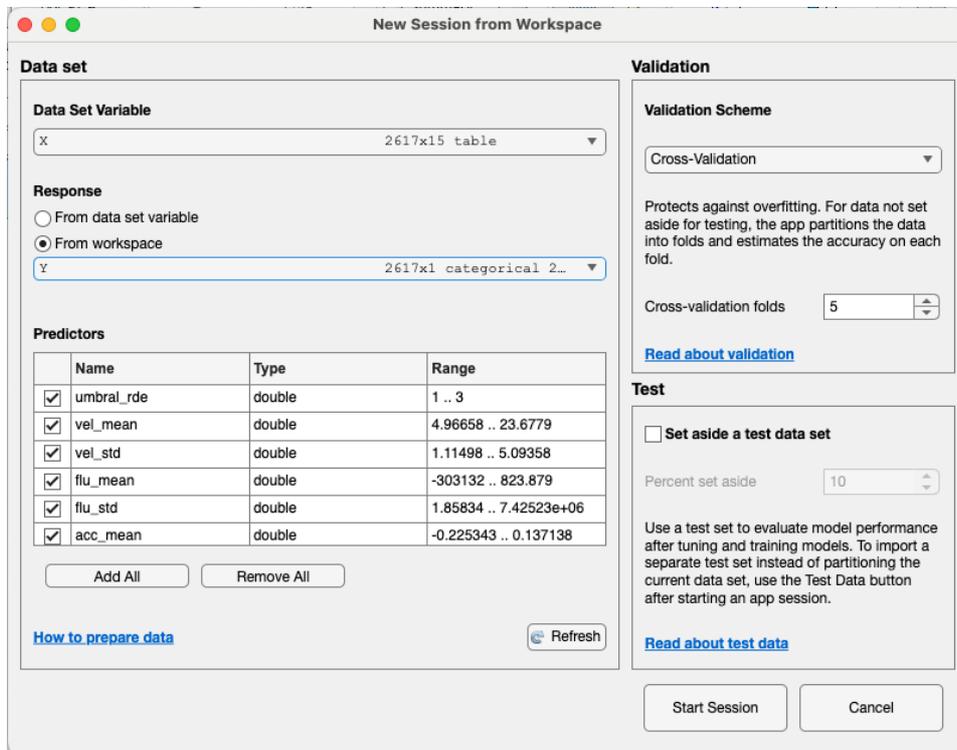
CAPÍTULO IV

ALGORITMO DE CLASIFICACIÓN DEL ESTILO DE CONDUCCION DE ACUERDO CON EL CONSUMO DE COMBUSTIBLE

6.1 Generación del algoritmo

Para entrenar el árbol de decisión, se hizo uso de una base de datos que contiene los predictores mencionados en la Tabla 2.6. Estos predictores fueron calculados para cada segmento de 10 segundos de las rutas, y también se incluyó la condición RDE (urbano, rural, autopista) como un predictor adicional. La implementación se llevó a cabo en el software "Classification Learner" de Matlab, cuya pantalla de inicio se muestra en la Figura 4.1. Es importante mencionar que este software requiere que se indique la variable que contiene la base de datos con los predictores, así como la variable de salida o respuesta. Para validar el modelo, se utilizó un enfoque de validación cruzada conocido como 5-fold, que divide los datos en 5 grupos. La validación cruzada con k-fold es una técnica utilizada en el campo del aprendizaje automático y la estadística para evaluar el rendimiento del modelo de manera más precisa y robusta. El objetivo de esta técnica es utilizar los datos disponibles de manera eficiente y evitar problemas como el sobreajuste o el subajuste del modelo (Maleki, 2017).

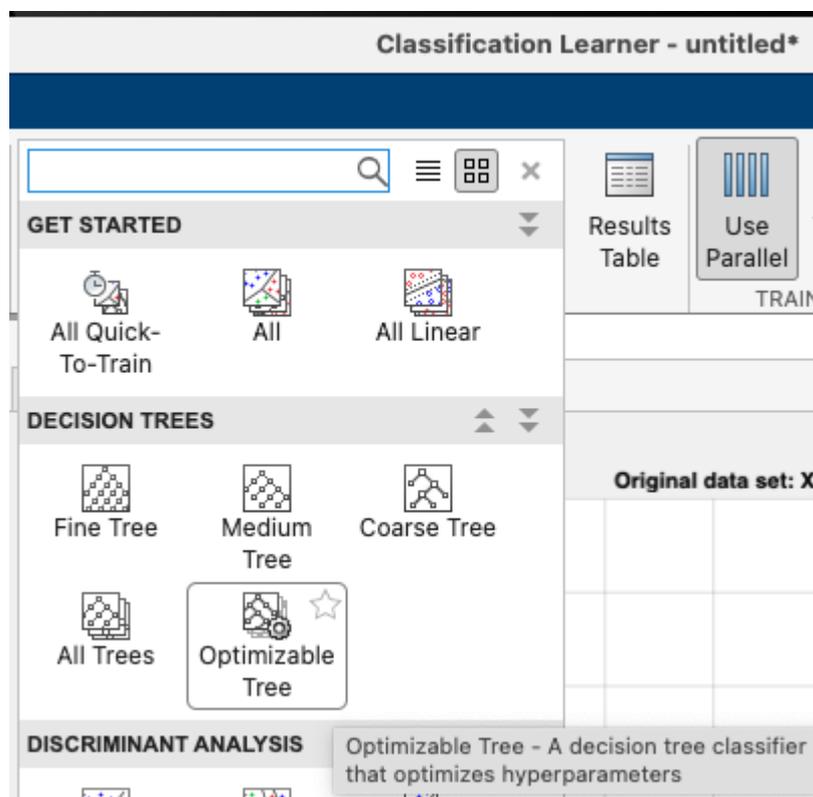
Figura 6.1: Clasification Learner



Herramienta de aprendizaje supervisado, Fuente: Autores.

A continuación, se procede a seleccionar el modelo de árbol de decisión con hiperparámetros optimizables, denominado "Optimizable Tree" en la Figura 4.2. Un hiperparámetro es un parámetro externo al modelo de aprendizaje automático que debe ser establecido antes del proceso de entrenamiento. A diferencia de los parámetros del modelo, que se aprenden durante el entrenamiento, los hiperparámetros son ajustes que controlan la forma en que se entrena el modelo y afectan su rendimiento y capacidad de generalización (Gohil y otros, 2023).

Figura 6.2:Tipos de modelo



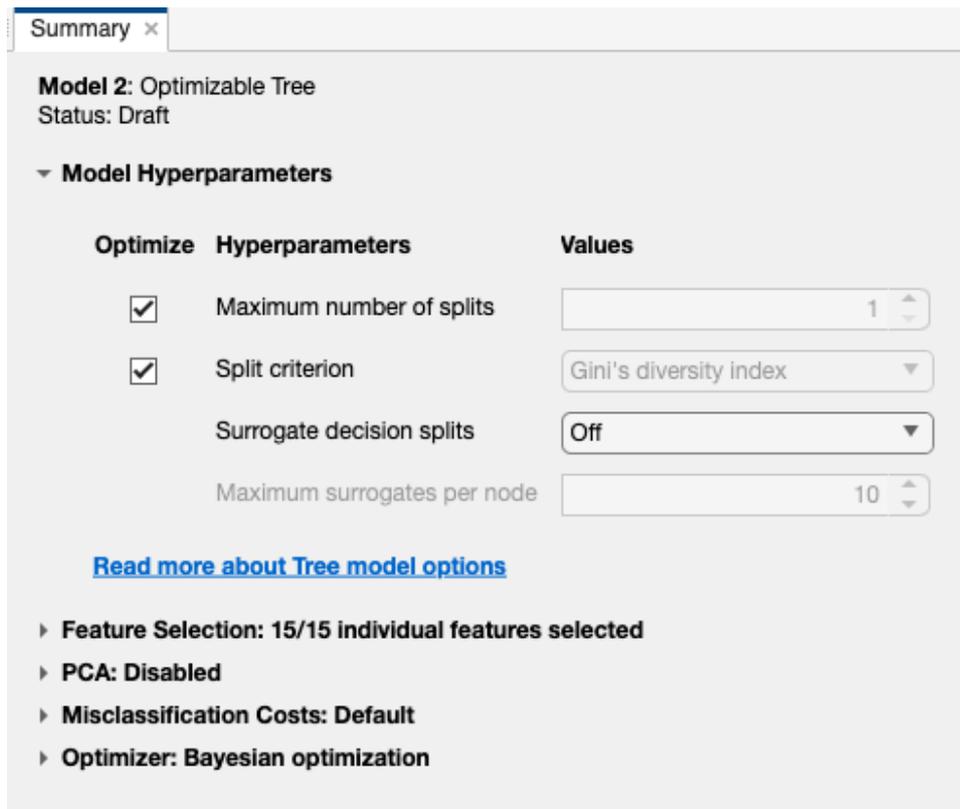
Selección del modelo "Decision Tree", Fuente: Autores

En el modelo de árbol de decisión seleccionado, se pueden ajustar mediante optimización bayesiana dos hiperparámetros: el número máximo de divisiones y el criterio de división ("Maximum number of splits" y "Split criterion" en la Figura 4.3, respectivamente). En los árboles de decisión, el número máximo de divisiones establece el límite de cuántas veces se pueden dividir los datos en cada nodo del árbol. Este hiperparámetro controla la profundidad o complejidad del árbol y ayuda a evitar el sobreajuste.

El criterio de división es una medida utilizada para evaluar qué atributo es el mejor para dividir los datos en cada nodo. Los criterios más comunes son el índice de Gini y la ganancia de información. Ambos hiperparámetros influyen en la construcción del árbol de decisión y afectan su rendimiento y capacidad de generalización (Maleki, 2017).

La optimización de hiperparámetros implica encontrar los mejores valores para los ajustes externos al modelo de aprendizaje automático. Consiste en seleccionar los hiperparámetros relevantes, definir su rango de valores, buscar eficientemente en ese espacio, evaluar el rendimiento del modelo con cada combinación de hiperparámetros y seleccionar la mejor opción. Esto es crucial para mejorar el rendimiento y la capacidad de generalización del modelo. Concretamente, en este trabajo se utilizó la optimización bayesiana que utiliza el teorema de Bayes para buscar la mejor combinación de hiperparámetros de un modelo de aprendizaje automático.

Figura 6.3:Hiperparámetros

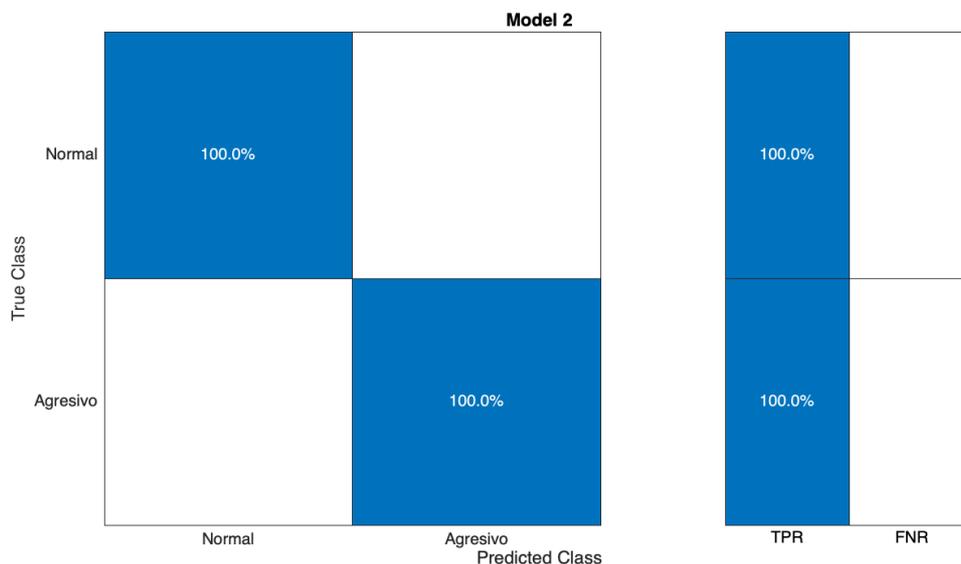


Optimización de hiperparámetros, Fuente: Autores.

Una vez que se ha entrenado el modelo óptimo, se procede a calcular la matriz de confusión, la cual se presenta en la Figura 4.4. La matriz de confusión es una tabla que muestra las predicciones correctas e incorrectas realizadas por un modelo de clasificación. En ella se incluyen los verdaderos positivos (TP), los falsos positivos (FP), los falsos negativos (FN) y los verdaderos negativos (TN) (Talbot y otros, 2009).

La tasa de verdaderos positivos (TPR) o sensibilidad se refiere a la proporción de casos positivos que son correctamente clasificados por el modelo. Por otro lado, la tasa de falsos negativos (FNR) indica la proporción de casos positivos que son incorrectamente clasificados por el modelo (Maleki, 2017). En la Figura 4.4 se observa que nuestro modelo tiene 100 por ciento de TPR.

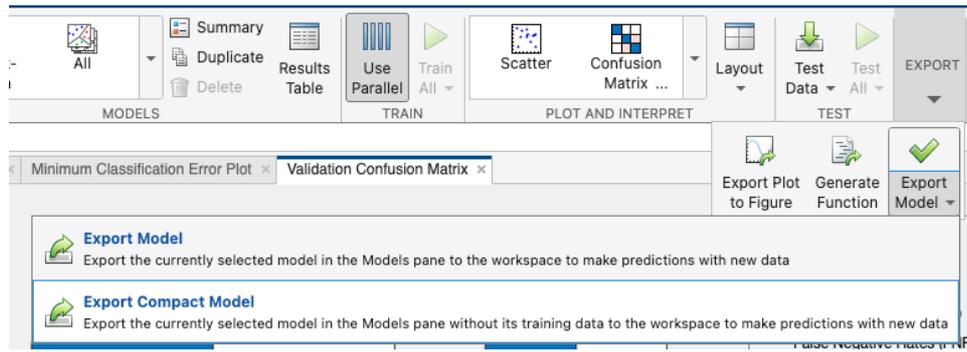
Figura 6.4: Matriz de confusión



Cálculo de la matriz de confusión, Fuente: Autores.

Finalmente, se exporta el modelo entrenado como se muestra en la Figura 4.5. Este modelo entrenado será usado posteriormente para hacer predicciones para nuevas rutas que no fueron utilizadas en el proceso de entrenamiento.

Figura 6.5: Exportación del modelo



Modelo clasificador guardado, Fuente: Autores.

6.2 Prueba del modelo clasificador en una ruta normal

Para evaluar la efectividad del modelo, se seleccionó una ruta que no fue utilizada durante su entrenamiento. Los resultados de la clasificación del estilo de conducción y el consumo de combustible en cada etapa de la ruta, según las condiciones establecidas por el ciclo RDE, se presentan en la Tabla 4.1.

Tabla 6.1:Ruta de prueba

Ruta de prueba		Etapas del ciclo		
Parámetro	Unidad de medida	URBANO	RURAL	AUTOPISTA
Estilo de conducción	Normal/Agresivo	Agresivo	Normal	Agresivo
Promedio de consumo de combustible	<i>l/h</i>	3.277	7.159	7.222
Distancia total de la ruta	<i>Km</i>	28,87998		

Verificación del modelo con una ruta de prueba, Fuente: Autores.

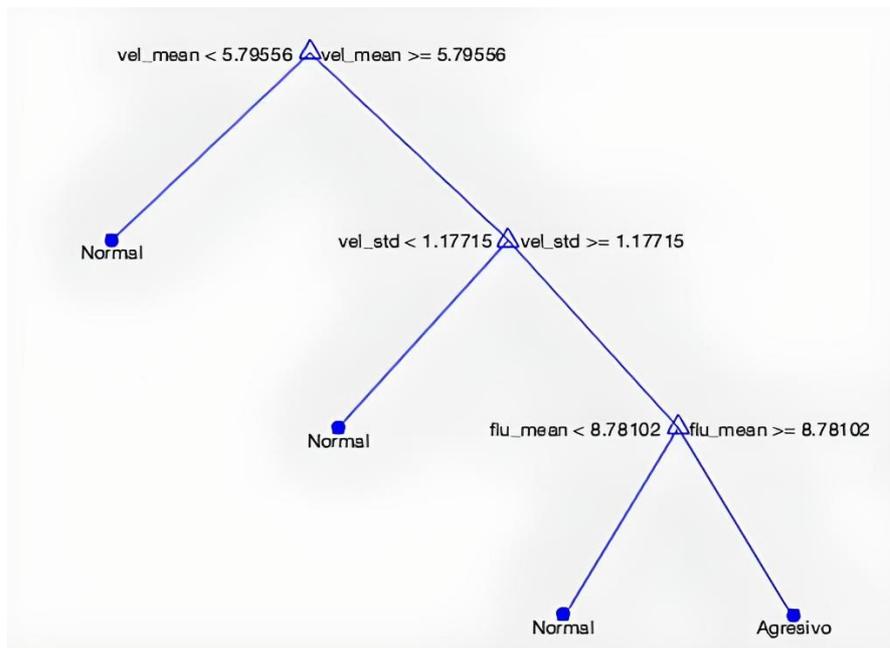
El modelo clasificador identificó correctamente el estilo de conducción en cada etapa de la ruta de prueba. En la etapa urbana, se clasificó como agresivo, mientras que en la etapa rural se identificó como normal y en la etapa de autopista se clasificó como agresivo. Esto indica que el modelo pudo distinguir entre estilos de conducción más agresivos y normales con una precisión razonable.

En relación con el consumo de combustible, se observó que el consumo medio varió según el estilo de conducción y la etapa del ciclo. En la etapa urbana, donde se identificó una forma

de conducción agresiva, el consumo medio de combustible fue de 3.277 litros por hora. En la etapa rural, con un estilo de conducción normal, el consumo medio fue de 7.159 litros por hora. En la etapa de autopista, nuevamente con un estilo de conducción agresivo, el consumo medio fue de 7.222 litros por hora. Estos resultados demuestran que un estilo de conducción más agresivo tiende a resultar en un mayor consumo de combustible en comparación con un estilo de conducción normal.

En la figura 4.6 se ilustra el proceso de clasificación del árbol de decisión. El criterio de clasificación comienza con el valor medio de la velocidad, si este valor es menor a 5.79 m/s , se clasifica el estilo de conducción como normal, en caso contrario, se examina la desviación estándar de la velocidad. Si la desviación estándar es menor a 1.17 m/s , se clasifica como normal. Si no cumple esta condición, se analiza la media del consumo de combustible. Si la media del consumo es menor a 8.78 l/h^2 , se clasifica el estilo de conducción como normal, de lo contrario, se clasifica como agresivo.

Figura 6.6: Árbol de decisión.

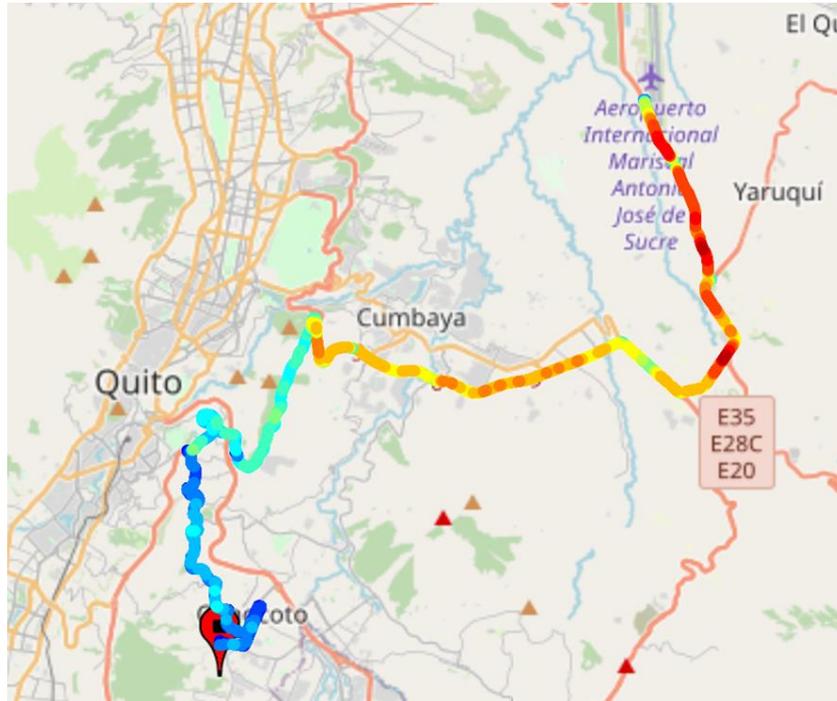


Árbol de decisión y nodos generados por Matlab, Fuente: Autores

6.3 Prueba del modelo clasificador en un RDE

Se utilizó el modelo de clasificación para determinar el estilo de conducción en cada una de las etapas de una ruta RDE diseñada en el distrito metropolitano de Quito, esta ruta fue trazada desde el sector de Conocoto hasta el Aeropuerto Internacional Mariscal Antonio José de Sucre, como se puede visualizar en la figura 4.3.

Figura 6.7: Ruta RDE



Ubicación de la ruta RDE, Fuente: Autores

En la tabla 4.2 se muestran las propiedades de la ruta RDE empleada para la recopilación de datos, donde se puede observar si se satisfacen las condiciones del ciclo.

Tabla 6.2: Características de la ruta RDE

Parámetro	Etapa			Unidad
	URBANO	RURAL	AUTOPISTA	
Distancia	16.399	17.663	16.889	km
Porcentaje de distancias	32.234	34.717	33.039	%
Porcentaje de parada	28.32	-	-	%
Velocidad Promedio	15.77	63.84	75.61	km/h
Duración Total	01:32:14			hh: mm: ss

Cumplimiento de las condiciones RDE, Fuente: Autores

Los resultados de la clasificación del estilo de conducción y el consumo de combustible promedio en cada etapa del ciclo RDE de la ruta de prueba se presentan en la Tabla 4.3. La ejecución y funcionamiento del modelo se puede apreciar en la Figura 4.7.

Tabla 6.3: Ruta de prueba RDE

Ruta de prueba		Etapa del ciclo		
Parámetro	Unidad de medida	URBANO	RURAL	AUTOPISTA
Estilo de conducción	Normal/Agresivo	Normal	Normal	Agresivo
Promedio de consumo de combustible	<i>l/h</i>	2.380	6.258	6.812
Distancia total de la ruta	<i>Km</i>	50.876		

Uso del modelo en una ruta RDE, Fuente: Autores

Figura 6.8: Ejecución del modelo

```

107 % Decision tree
108 load('trainedModel7.mat')
109 load('./test/1.mat')
110
111 tutoria;
112 Xtest = get_features_all_win(VSSf', flujohr', ...
113     aceleracion', RPMSf', TPSf', MAPf', ...
114     VA', th_urb, th_rur,w);
115 Ypred = trainedModel7.predictFcn(Xtest);

```

Command Window

New to MATLAB? See resources for Getting Started.

Distancia 50876.5988
Urbano Normal, consumo 2.380736
Rural Normal, consumo 6.258154
Carretera Agresivo, consumo 6.812068

Uso del modelo en MatLab, Fuentes: Autores.

En la etapa urbana, el modelo clasifica el estilo de conducción como normal, lo que indica que el conductor adopta un enfoque más moderado y controlado en su manejo. Además, el consumo promedio de combustible durante esta etapa es de 2.380 litros por hora.

En la etapa rural, nuevamente se clasifica el estilo de conducción como normal, lo que sugiere que el conductor mantiene un comportamiento similar al de la etapa urbana, adaptándose a las condiciones de la carretera en áreas menos urbanizadas. El consumo promedio de combustible en esta etapa es de 6.258 litros por hora, sin embargo, en la etapa de autopista, el modelo clasifica el estilo de conducción como agresivo, lo que implica que

el conductor adopta un enfoque más dinámico y de mayor velocidad en su manejo. Como resultado, se observa un aumento en el consumo promedio de combustible durante esta etapa, llegando a 6.812 litros por hora.

CONCLUSIONES

- Del análisis de regresión lineal múltiple, se determinó que ciertas variables tienen una influencia positiva en el flujo de combustible, como las revoluciones del motor, la posición del pedal del acelerador, la presión absoluta del colector de admisión, la velocidad, y los índices RPA y VA; a medida que estas variables aumentan, también lo hace el flujo de combustible. Sin embargo, se observó que otras variables, como la desviación estándar de la aceleración y el valor promedio del índice V·A, tienen una influencia negativa, lo que indica que su incremento está asociado a una disminución en el flujo de combustible.
- El análisis realizado indica que el estilo de conducción tiene un efecto significativo en el consumo de combustible. Se observa una diferencia estadísticamente significativa en las revoluciones del motor y en el percentil 95 del índice V·A entre los estilos de conducción normal y agresivo. Esto confirma la relación entre estas variables y el consumo de combustible. Por otro lado, no se encontraron diferencias significativas en el índice RPA ni en la desviación estándar de la aceleración. Estos hallazgos resaltan la importancia de considerar el estilo de conducción al analizar el consumo de combustible.
- En la etapa urbana, el estilo de conducción agresivo muestra un consumo medio aproximadamente un 15% mayor que el estilo de conducción normal, respaldado por una diferencia de 0.757 l/h y un p-value inferior a 0.05. En la etapa rural, la diferencia es de aproximadamente un 13% con un consumo medio mayor en el estilo de conducción agresivo de 0.644 l/h y un p-value menor a 0.05. Sin embargo, en la etapa de autopista, no se encontró una diferencia significativa en el consumo medio de combustible entre ambos estilos de conducción. Estos hallazgos destacan la importancia de considerar el estilo de conducción para promover prácticas más eficientes y reducir el consumo de combustible y las emisiones asociadas.
- Se entrenó un modelo de árbol de decisión optimizado mediante validación cruzada y optimización bayesiana de hiperparámetros. El modelo alcanzó una tasa de verdaderos positivos del 100% en la matriz de confusión. El modelo entrenado se exportó y se utilizará para hacer predicciones en nuevas rutas.

- El modelo utilizado para clasificar el estilo de conducción y predecir el consumo de combustible ha demostrado ser efectivo y preciso. El modelo fue capaz de identificar correctamente el estilo de conducción en cada etapa de la ruta de prueba, distinguiendo entre estilos agresivos y normales con una precisión razonable. Además, se pudo comprobar que un estilo de conducción más agresivo está asociado con un mayor consumo de combustible en comparación con un estilo de conducción normal.

RECOMENDACIONES

- Es recomendable utilizar micro rutas o segmentos de ruta más cortos en la toma de datos para obtener un mejor criterio en la clasificación del estilo de conducción y su relación con el consumo de combustible. En rutas largas, algunos parámetros relevantes, como la aceleración, se atenúan y dificultan la identificación precisa del comportamiento agresivo.
- Para obtener una perspectiva más amplia y representativa en el entrenamiento de un modelo de clasificación de estilo de conducción, es recomendable aumentar el número de conductores y considerar diferentes clases de vehículos. Al incluir variedad con respecto a conductores y vehículos en el conjunto de información de entrenamiento, se caracterizan mejor los estilos de conducción y se obtiene un modelo más robusto y generalizable.
- Se puede considerar una amplia gama de variables y características que influyan en el estilo de conducción y el promedio de consumo de combustible. Además de las variables tradicionales como aceleración y velocidad también incorporar otras variables como la carga del vehículo, un acelerómetro que determine de la carretera, el estado del tráfico, entre otros.
- El desarrollo de micro rutas que abarquen distintos estilos de conducción se considera una práctica recomendable en el entrenamiento de algoritmos. Por ende, se sugiere llevar a cabo trayectos cortos donde se simule una conducción agresiva, desafiando al vehículo y generando una demanda significativa. Asimismo, se aconseja generar pequeños recorridos en los cuales se adopte una conducción extremadamente pasiva.

REFERENCIAS BIBLIOGRÁFICAS

- Auto, C. (2022). *Changan Ecuador*. Changan Ecuador: <https://changanecuador.com/wp-content/uploads/changan-Ficha-tecnica-CS15.pdf>
- Barlow, T., Latham, S., & McCrae, I. (Junio de 2009). *A reference book of driving cycles for use in the measurement of road vehicle emissions*. https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/4247/ppr-354.pdf
- Barrientos Martínez, R. E., Cruz Ramírez, N., Acosta Mesa, H. G., Rabatte Suárez, I., Gogeoascoechea Trejo, M., Pavón León, P., & Blázquez Morales, S. (18 de Septiembre de 2009). *Instituto de Ciencias de la Salud, Universidad Veracruzana, Xalapa, Veracruz, México. Árboles de decisión como herramienta en el diagnóstico*: http://www.soprote.uv.mx/rm/num_anteriores/revmedica_vol9_num2/articulos/arboles.pdf
- Benavides Lima, K. F., & Montenegro Nagua, F. I. (16 de Febrero de 2023). *UNIVERSIDAD POLITÉCNICA SALESIANA. ANÁLISIS DE LOS PARÁMETROS DE FUNCIONAMIENTO DE UN MOTOR MPI VARIANDO LAS CARACTERÍSTICAS DE FILTRADO Y TIPO DE GASOLINA PARA MEJORAR EL RENDIMIENTO DE CONSUMO DE COMBUSTIBLE MEDIANTE CICLO DE EMISIONES REALES RDE EN LA CIUDAD DE QUITOECUADOR.*: <https://dspace.ups.edu.ec/bitstream/123456789/24250/1/TTS1151.pdf>
- Bermeo, O., & Figueroa, J. (Noviembre de 2020). *ANÁLISIS DEL ESTILO DE CONDUCCIÓN DE UN VEHÍCULO CHEVROLET AVEO MEDIANTE EL ESTUDIO DE SEÑALES PID'S PARA LA DETERMINACIÓN DE SU INFLUENCIA EN LAS EMISIONES CONTAMINANTES EN LA CIUDAD DE CUENCA*. Dspace: <https://dspace.ups.edu.ec/bitstream/123456789/19619/4/UPS-CT008914.pdf>
- Bodisco, T., Rahman, A., Farhad, H., & Brown, R. (Noviembre de 2019). *On-road NOx emissions of a modern commercial light-duty diesel vehicle using a blend of tyre oil and diesel*. Science Direct: <https://www.sciencedirect.com/science/article/pii/S2352484718303639>
- Braun, A., & Rid, W. (Septiembre de 2016). *The influence of driving patterns on energy consumption in electric car driving and the role of regenerative braking*. Science Direct: <https://www.sciencedirect.com/science/article/pii/S235214651730159X>
- Chen, S.-H., Pan, J.-S., & Lu, K. (20 de Marzo de 2015). *Driving Behavior Analysis Based on Vehicle OBD Information and AdaBoost Algorithms*. IAEng: https://www.iaeng.org/publication/IMECS2015/IMECS2015_pp102-106.pdf
- Chung, J., Lee, B., Kim, D., Park, J., & Goo, Y. (19 de Abril de 2021). *STUDY ON ANALYSIS OF REAL ROAD DRIVING CHARACTERISTICS OF HEAVY-DUTY GAS DELIVERY TRACTOR*. Springer: <https://link.springer.com/article/10.1007/s12239-021-0149-5>
- DFRobot. (2014). *DFRobot*. DFRobot: https://wiki.dfrobot.com/Freematics_OBD-II_Emulator_MK2_SKU_TEL0099
- Díaz, A. (Septiembre de 2020). *Desarrollo y validación de modelos de vehículos para el análisis energético de sistemas propulsivos aplicados al transporte ligero por carretera*. RIULL - Repositorio Institucional: <https://riull.ull.es/xmlui/handle/915/28779>

- Dingus, T., Klauer, S., Neale, V., Petersen, A., Lee, S., Sudweeks, J., Perez, M., Hankey, J., & Ramsey, D. (Abril de 2006). *The 100-car naturalistic driving study, Phase II: Results of the 100-car*. National Highway Traffic Safety Administration, Washington, DC,: <https://www.nhtsa.gov/sites/nhtsa.gov/files/100carmain.pdf>
- Donateo, T., & Giovinazzi, M. (2017). *ScienceDirect*. Bulding a cycle for real driving emissions: [https://pdf.sciencedirectassets.com/277910/1-s2.0-S1876610217X00222/1-s2.0-S1876610217338213/main.pdf?X-Amz-Security-Token=IQoJb3JpZ2luX2VjEL7%2F%2F%2F%2F%2F%2F%2F%2F%2F%2FwEaCXVzLWVhc3QtMSJHMEUCIQDN4zETv7MOxshq6QP4O16ZQSLLkYlka3KazxhmrCKRwIgKyqEJ%2FRlho](https://pdf.sciencedirectassets.com/277910/1-s2.0-S1876610217X00222/1-s2.0-S1876610217338213/main.pdf?X-Amz-Security-Token=IQoJb3JpZ2luX2VjEL7%2F%2F%2F%2F%2F%2F%2F%2F%2F%2F%2FwEaCXVzLWVhc3QtMSJHMEUCIQDN4zETv7MOxshq6QP4O16ZQSLLkYlka3KazxhmrCKRwIgKyqEJ%2FRlho)
- Ericson, E. (05 de Septiembre de 2001). *Independent driving pattern factors and their influence on fuel-use and exhaust emission factors*. ScienceDirect: <https://www.sciencedirect.com/science/article/abs/pii/S1361920901000037>
- Farinago, R., & Santana, A. (2021). *DETERMINACIÓN DE LA ACELERACIÓN POSITIVA RELATIVA (RPA) PARA UN VEHÍCULO ELÉCTRICO CON BASE EN EL CICLO DE MANEJO WLTC3 CONSIDERANDO VARIACIONES DE PENDIENTE*. Tecnológico de Monterrey: <https://repositorio.tec.mx/handle/11285/648807>
- Fontaras , G., Zacharof, N., & Ciuffo, B. (Mayo de 2017). *Fuel consumption and CO2 emissions from passenger cars in Europe – Laboratory versus real-world emissions*. ScienceDirect: <https://www.sciencedirect.com/science/article/pii/S0360128516300442>
- Garcia, R., Soriano, J., Fernandez, P., Sanchez , L., Mata, C., Gomez, A., Armas, O., & Cárdenas, D. (01 de Marzo de 2021). *Impact of regulated pollutant emissions of Euro 6d-Temp light-duty diesel vehicles under real driving conditions*. ScienceDirect: <https://www.sciencedirect.com/science/article/abs/pii/S0959652620349714?via%3Dihub>
- Gohil, A., Lee, J., & Don-Seong, K. (23 de Febrero de 2023). *Optimal Tree Bayesian for the Characterization of Ciphred Network Communication Traffic*. IEEE Explore: <https://ieeexplore.ieee.org/abstract/document/10067102>
- Huang Chen, S., Shyang Pan, J., & Lu, K. (18 de Marzo de 2015). *Proceedings of the International MultiConference of Engineers and Computer Scientists*. Driving Behavior Analysis Based on Vehicle OBD Information and AdaBoost Algorithms : https://www.iaeng.org/publication/IMECS2015/IMECS2015_pp102-106.pdf
- Hussein, D., & Panwai , S. (04 de Febrero de 2016). *Impact of Driving Behaviour on Emissions and Road Network Performance*. IEEE Xplore: <https://ieeexplore.ieee.org/document/7396526>
- Indrajana, A., Ligterint, N., & Van der Mark, P. (25 de Marzo de 2020). *Monitoring-based assessment of the NOx-emissions of a Renault Talisman and a Volkswagen Caddy*. Monitoring-based assessment of the NOx-emissions of a Renault Talisman and a Volkswagen Caddy: <https://repository.tudelft.nl/islandora/object/uuid:c664c85f-a0b1-4550-b3e4-48f6a292952f/datastream/URL/download>
- Kohonen, T. (Enero de 2012). *Correlation Matrix Memories*. IEEE Xplore: <https://ieeexplore.ieee.org/abstract/document/5008975/authors#authors>
- Liimatainen, H. (4 de Diciembre de 2011). *IEEE*. Utilization of Fuel Consumption Data in an Ecodriving Incentive System for Heavy-Duty Vehicle Drivers: <https://bibliotecas.ups.edu.ec:2095/stamp/stamp.jsp?tp=&arnumber=5765691>

- Ma, H., Xie, H., Huang, D., & Xiong, S. (20 de Octubre de 2015). *Effects of driving style on the fuel consumption of city buses under different road conditions and vehicle masses*. ScienceDirect: [sciencedirect.com/science/article/abs/pii/S1361920915001558](https://www.sciencedirect.com/science/article/abs/pii/S1361920915001558)
- Maleki, M. (18 de Mayo de 2017). *Application of PLSR with a comparison of MATLAB classification learner app in using BCI*. IEEE Explorer: <https://ieeexplore.ieee.org/abstract/document/7960534>
- Malik, M., & Nandal, R. (Julio de 2021). *A framework on driving behavior and pattern using On-Board diagnostics (OBD) tool*. ScienceDirect: <https://www.sciencedirect.com/science/article/abs/pii/S2214785321052354>
- Mehrdad , H., Ghodrattollah , S., & Morteza , R. (Noviembre de 2013). *Application of decision tree and discrete wavelet transform for an optimized intelligent-based islanding detection method in distributed systems with distributed generations*. ScienceDirect: <https://bibliotecas.ups.edu.ec:2230/science/article/pii/S1364032113004383>
- Meseguer, J., Calafate, C., Cano, J., & Manzoni, P. (16 de Julio de 2015). *Assessing the impact of driving behavior on instantaneous fuel consumption*. IEEE Xplorer: <https://ieeexplore.ieee.org/document/7158016>
- Miyajima, C., & Takeda, K. (Noviembre de 2016). *Driver-Behavior Modeling Using On-Road Driving Data: A new application for behavior signal processing*. IEEE Xplorer: <https://ieeexplore.ieee.org/abstract/document/7736125>
- Mouzouras, M. (Enero de 2022). *New methodologies for assessing the behavior of vehicles under real driving emissions testing regimes*. https://purehost.bath.ac.uk/ws/portalfiles/portal/236904364/Marios_Mouzouras_PhD_thesis_corrected.pdf
- Movilidad, S. d. (02 de Febrero de 2015). *Gobierno Autonomo Descentralizado del Distrito Metropolitano de Quito*. <https://gobiernoabierto.quito.gob.ec/wp-content/uploads/documentos/interactivos/movilidad/files/assets/downloads/publication.pdf>
- Ping, P., Qin, W., Xu, Y., Miyajima, C., & Takeda, K. (03 de Junio de 2019). *Impact of Driver Behavior on Fuel Consumption: Classification, Evaluation and Prediction Using Machine Learning*. IEEE Xplorer: <https://ieeexplore.ieee.org/document/8727915>
- Rodríguez, M., & Mora, R. (Julio de 2021). *Análisis de regresión múltiple*. Repositorio Institucional de la Universidad de Alicante: <https://rua.ua.es/dspace/handle/10045/12077>
- Rodríguez, R., Virguez, E., Rodríguez, P., & Behrentz, E. (Marzo de 2016). *Influence of driving patterns on vehicle emissions: A case study for Latin American cities*. ScienceDirect: <https://www.sciencedirect.com/science/article/abs/pii/S1361920915002187>
- Rygula , A. (26 de Junio de 2009). *Driving Style Identification Method Based on Speed Graph Analysis*. IEEE Xplorer: <https://ieeexplore.ieee.org/document/5223255>
- Shahariar, H., Mojibu, S., Suara, K., Jahirul , M., Chu-Van, T., Ristovski, Z., Brown, R., & Bodisco, T. (Junio de 2022). *On-road CO2 and NOx emissions of a diesel vehicle in urban traffic*. ScienceDirect: <https://www.sciencedirect.com/science/article/abs/pii/S1361920922001547>
- Signoretto, G., Silva, M., Araujo, J., Guedes, L., Silva, I., Sisinni, E., & Ferrari, P. (03 de Junio de 2020). *Performance Evaluation of an evolving data compression*

- algorithm embedded into an OBD-II edge device*. IEEE Xplore:
<https://ieeexplore.ieee.org/abstract/document/9138270>
- Solarte Martínez, G. R., & Soto Mejía, J. (Diciembre de 2011). *Universidad Tecnológica de Pereira, Pereira, Colombia*. Arboles de decisiones en el diagnóstico de enfermedades cardiovasculares: <https://www.redalyc.org/pdf/849/84922625018.pdf>
- Talbot, J., Lee, B., Kapoor, A., & Desney, T. (04 de Abril de 2009). *EnsembleMatrix: interactive visualization to support machine learning with multiple classifiers*. ACM Digital Library: <https://dl.acm.org/doi/abs/10.1145/1518701.1518895>
- Thakallapelli, A., Ghosh, S., & Kamalasadana, S. (2016). *Power and Energy Society General Meeting*. Real-time Frequency Based Reduced Order Modeling of Large Power Grid: <https://arxiv.org/ftp/arxiv/papers/1907/1907.10273.pdf>
- Toledo, T., Koutsopolous, H., & Ben-Akiva, M. (20 de Febrero de 2007). *Integrated driving behavior modeling*. ScienceDirect:
<https://www.sciencedirect.com/science/article/abs/pii/S0968090X07000046>
- Triantafyllopoulos, G. (Diciembre de 2018). *ASSESSMENT OF TECHNOLOGIES TO REDUCE FUEL CONSUMPTION AND POLLUTANT EMISSIONS OF MODERN PASSENGER CARS IN REAL-WORLD DRIVING CONDITIONS*. ASSESSMENT OF TECHNOLOGIES TO REDUCE FUEL CONSUMPTION AND POLLUTANT EMISSIONS OF MODERN PASSENGER CARS IN REAL-WORLD DRIVING CONDITIONS:
https://web.archive.org/web/20211211155648id_/https://ikee.lib.auth.gr/record/303596/files/GRI-2019-23880.pdf
- Van der Maaten, L., & Hinton, G. (2008). *Visualizing Data using t-SNE*. Tilburg University:
<https://www.jmlr.org/papers/volume9/vandermaaten08a/vandermaaten08a.pdf>
- Wattenberg, Viégas, M., & Johnson, F. (2016). *How to Use t-SNE Effectively*. Distill:
https://distill.pub/2016/misread-tsne/?_ga=2.135835192.888864733.1531353600-1779571267.1531353600