

**UNIVERSIDAD POLITÉCNICA DE MADRID**  
Escuela Técnica Superior de Ingeniería de Sistemas Informáticos



**Aplicación Android para la Clasificación  
del Estilo de Conducción mediante OBD-II,  
Sensores Móviles y Machine Learning**

**PROYECTO FIN DE GRADO**

**Yushetf López Jiménez**  
Grado en Sistemas de Información

Madrid, 2025



UNIVERSIDAD POLITÉCNICA DE MADRID  
Escuela Técnica Superior de Ingeniería de  
Sistemas Informáticos

**Grado en Sistemas de Información**

**Aplicación Android para la Clasificación  
del Estilo de Conducción mediante OBD-II,  
Sensores Móviles y Machine Learning**

**PROYECTO FIN DE GRADO**

**Yushetf López Jiménez**  
Grado en Sistemas de Información

Bajo la dirección de:  
Dr. Javier García Martín

Madrid, 2025

Título: Aplicación Android para la Clasificación del Estilo de Conducción mediante OBD-II, Sensores Móviles y Machine Learning

Autor: Yushetf López Jiménez

Grado en Sistemas de Información

Dirección: Dr. Javier García Martín



# Agradecimientos

Quiero agradecer a todas las personas que han estado presentes no solo en esta última etapa y proyecto, sino a lo largo de toda mi carrera universitaria. Gracias a mi tutor, Javier García Martín, quien, además de ser el tutor de este Trabajo de Fin de Grado, me ha guiado y aconsejado en todo momento para poder llevar a cabo este proyecto. Su implicación y disponibilidad han sido clave para avanzar en cada fase. Agradezco también a todos los profesores que me han formado académicamente, preparándome para afrontar mi futuro profesional y motivándome a seguir aprendiendo. Y, por encima de todo, gracias a mi familia y amigos, por su apoyo incondicional, por estar ahí tanto en los buenos como en los malos momentos y por hacerme crecer como persona cada día.

## **Abstract**

This project develops a mobile application to analyze and classify driving styles in real-time using OBD-II technology, integrated mobile device sensors, and machine learning algorithms. The solution aims to optimize fuel consumption, reduce pollutant emissions, and promote safe driving practices.

The system collects relevant vehicle data, such as speed, engine revolutions per minute (RPM), and throttle position, complemented by information from mobile sensors (accelerometer and gyroscope) to identify aggressive maneuvers. Using a machine learning model implemented in Azure, the driving style is classified into three categories: calm, normal, and aggressive. Results and personalized recommendations are presented through an intuitive and accessible graphical interface.

Tests conducted under real conditions demonstrated reliable Bluetooth connectivity (90% success rate) and high classification model accuracy (91.13%). Despite limitations, such as dependency on external APIs and precision in detecting certain events, the system offers an innovative and accessible tool to encourage more sustainable driving habits.

This work lays the foundation for future improvements, including compatibility with electric vehicles, enhanced personalization, and commercial deployment. Overall, it represents a significant advancement in telematics and sustainability in transportation.

# Resumen

El presente proyecto desarrolla una aplicación móvil para analizar y clasificar estilos de conducción en tiempo real mediante el uso de tecnología OBD-II, sensores integrados en dispositivos móviles y algoritmos de machine learning. La solución busca optimizar el consumo de combustible, reducir emisiones contaminantes y promover prácticas de conducción seguras.

El sistema recoge datos relevantes del vehículo, como velocidad, revoluciones por minuto y posición del acelerador, complementados con información de los sensores del móvil (acelerómetro y giroscopio) para identificar maniobras agresivas. Mediante un modelo de machine learning implementado en Azure, se clasifica el estilo de conducción en tres categorías: tranquilo, normal y agresivo. Los resultados y recomendaciones personalizadas se presentan en una interfaz gráfica intuitiva y accesible.

Las pruebas realizadas en condiciones reales han demostrado una conexión Bluetooth confiable (90% de éxito) y una alta precisión del modelo de clasificación (91,13%). A pesar de limitaciones como la dependencia de APIs externas y la precisión en ciertos eventos, el sistema ofrece una herramienta innovadora y accesible para fomentar hábitos de conducción más sostenibles.

Este trabajo sienta las bases para futuras mejoras, incluyendo la compatibilidad con vehículos eléctricos, mayor personalización y despliegue comercial. En conjunto, representa un avance significativo en el ámbito de la telemetría y la sostenibilidad en el transporte.

# Índice

<b>Capítulo 1.....</b>	<b>1</b>
<b>Introducción.....</b>	<b>1</b>
1.1. Motivación.....	1
1.2. Relevancia del problema.....	2
1.3. Estado del arte.....	3
1.3.1. Tecnología OBD-II.....	3
1.3.2. Aplicaciones basadas en OBD-II.....	4
1.3.3. Limitaciones en las soluciones actuales.....	6
1.3.4. Tabla comparativa.....	7
Tabla comparativa de las principales aplicaciones utilizadas en el mercado y la propuesta desarrollada.....	7
1.3.5. Ventajas de la propuesta desarrollada.....	7
1.3.6. Impacto del estilo de conducción en el consumo y el medio ambiente.....	8
1.3.7. Oportunidad de mejora con este proyecto.....	8
1.4. Objetivos.....	9
1.4.1. Objetivo general.....	9
1.4.2. Objetivos específicos.....	9
1.4.3. Alcance del proyecto.....	9
Límites del alcance.....	10
Exclusiones.....	10
1.5. Particularidades y ventajas del sistema propuesto.....	11
Particularidades del sistema.....	11
Ventajas del sistema propuesto.....	12
1.6. Metodología.....	13
1.6.1. Establecimiento del objetivo.....	13
1.6.2. Exploración de sensores y datos disponibles.....	14
1.6.3. Recolección de los primeros datos.....	14
1.6.4. Diseño de escenarios de conducción.....	15
1.6.5. Análisis exploratorios de los datos.....	15
1.7 Estructura de la memoria.....	16
<b>Capítulo 2.....</b>	<b>17</b>
<b>Contexto.....</b>	<b>17</b>
2.1. Contexto social y relevancia.....	17
2.2. Contexto tecnológico.....	17
2.3. Conceptos teóricos.....	18
2.4. Tecnologías utilizadas.....	18

2.5. Justificación de las tecnologías seleccionadas.....	19
2.5.1. Android y Kotlin.....	19
2.5.2. API OBD-II (kotlin-obd-api).....	19
2.5.3. Sensores del móvil.....	20
2.5.4. APIs de tráfico (Here Maps API).....	20
2.5.5. Excel y Microsoft Azure.....	21
2.5.6. Machine Learning.....	21
<b>Capítulo 3.....</b>	<b>22</b>
<b>Sistema desarrollado.....</b>	<b>22</b>
3.1. Descripción General del Sistema.....	22
3.2. Especificación de Requisitos.....	23
3.2.1. Requisitos Generales del Sistema.....	23
3.2.2. Requisitos Funcionales Específicos.....	24
3.2.3. Requisitos Funcionales Específicos.....	25
3.3. Diseño de alto nivel.....	25
3.3.1. Arquitectura general y Componentes Principales.....	25
3.3.2. Componentes principales.....	27
3.3.2. Comunicación entre componentes.....	28
3.4. Diseño detallado.....	29
3.4.1. Recolección de datos.....	29
3.4.2. Transformación y envío de datos.....	30
3.4.3. Visualización de resultados y recomendaciones.....	32
3.5. Almacenamiento y Análisis de datos.....	34
3.6. Clasificación del estilo de conducción.....	35
3.6.1. Modelo completo: Parámetros utilizados.....	35
3.6.2. Modelo refinado: Parámetros utilizados.....	36
Resultado de la Clasificación.....	43
<b>Capítulo 4.....</b>	<b>45</b>
<b>Resultados obtenidos.....</b>	<b>45</b>
4.1. Pruebas realizadas.....	45
4.1.1. Pruebas de conectividad Bluetooth.....	45
4.1.2. Pruebas de extracción de datos.....	45
4.1.3. Pruebas de clasificación de estilos de conducción.....	46
4.1.4. Pruebas de integración con sensores móviles.....	47
4.1.5. Pruebas de interfaz gráfica y facilidad de uso.....	47
4.2. Resultados obtenidos.....	48
4.2.1. Conectividad Bluetooth.....	48
4.2.2. Datos del OBD-II.....	48
4.2.3. Clasificación de Estilos de Conducción.....	48

4.2.4. Detección de Eventos con Sensores.....	53
4.2.5. Interfaz gráfica y facilidad de uso.....	54
4.3. Discusión de resultados.....	61
4.3.1. Interpretación de los resultados.....	61
4.3.2. Evaluación frente a las expectativas.....	62
4.3.3. Comparaciones entre pruebas y datos.....	62
4.3.4. Comparación con estudios previos.....	62
4.3.5. Aspectos concluyentes.....	62
4.3.6. Limitaciones identificadas.....	63
4.3.7. Mejoras propuestas y su implementación.....	63
4.3.8. Impacto del trabajo.....	64
<b>Capítulo 5.....</b>	<b>65</b>
<b>Impacto social y medioambiental.....</b>	<b>65</b>
5.1. Impacto social positivo.....	65
5.2. Impacto medioambiental positivo.....	66
5.3. Impacto potencial negativo.....	66
5.4. Reflexión final.....	67
5.5. Datos objetivos.....	67
5.6. Impacto práctico y aplicaciones potenciales.....	68
5.6.1. Integración en el mercado.....	68
5.6.2. Aplicación en iniciativas educativas.....	68
5.6.3. Aplicación en políticas gubernamentales.....	69
5.6.4. Impacto potencial en el futuro.....	70
<b>Capítulo 6.....</b>	<b>71</b>
<b>Planificación y presupuesto del proyecto.....</b>	<b>71</b>
6.1. Introducción.....	71
6.2. Planificación temporal.....	71
6.2.1. Fases del proyecto.....	71
6.2.2. Diagrama de Gantt.....	73
6.3. Presupuesto estimado.....	73
6.3.1. Recursos humanos.....	73
6.3.2. Recursos tecnológicos.....	74
6.3.3. Resumen general del presupuesto.....	75
6.4. Conclusión.....	76
<b>Capítulo 7.....</b>	<b>77</b>
<b>Conclusiones y trabajos futuros.....</b>	<b>77</b>
7.1. Logros alcanzados.....	77
7.2. Valoración de las tecnologías utilizadas.....	78

7.3. Trabajos futuros.....	79
<b>Bibliografía.....</b>	<b>81</b>

# Índice de figuras

- Figura 1.** Vehículos emitiendo gases contaminantes
- Figura 2.** Emisiones del CO<sub>2</sub> generadas por el transporte frente a otros sectores en España
- Figura 3.** Interfaz de la aplicación Torque Pro
- Figura 4.** Interfaz de la aplicación Dash Command
- Figura 5.** Imagen del dispositivo Xiaomi HUD
- Figura 6.** Dispositivo OBD utilizado
- Figura 7.** Interfaz de la aplicación en la que se muestran datos en tiempo real
- Figura 8.** Diagrama general del sistema desarrollado
- Figura 9.** Diagrama de componentes del sistema
- Figura 10.** Diagrama de flujo del sistema desarrollado
- Figura 11.** Diagrama de secuencia del sistema desarrollado
- Figura 12.** Estructura del archivo JSON que se envía a la nube para realizar la consulta sobre el estilo de conducción
- Figura 13.** Datos en tiempo real mostrados por la aplicación
- Figura 14.** Recomendaciones mostradas por la aplicación
- Figuras 15 y 16.** Gráficas de las métricas recogidas durante la conducción.
- Figura 17.** Matriz de confusión del modelo LightGBM entrenado en Azure ML.
- Figura 18.** Resultados ANOVA
- Figura 19.** Resultados del test de Welch
- Figura 20.** Resultados Games-Howell
- Figura 21.** Resultados conglomerados
- Figura 22.** Recorrido realizado durante las pruebas
- Figura 23.** Gráfico de líneas y barras del acelerómetro en los ejes X y Z para detección de acelerones, frenadas y giros.
- Figura 24.** Porcentaje de estilos de conducción detectados por la aplicación.
- Figura 25.** Relación entre la velocidad del vehículo y los valores del acelerómetro en el eje X (AccelX) para el análisis de giros bruscos
- Figura 26.** Relación entre la velocidad del vehículo y los valores del giroscopio en el eje Z (GyroZ) para el análisis de aceleraciones y frenadas bruscas
- Figura 27.** Diagrama de Gantt

# Capítulo 1

## Introducción

### 1.1. Motivación

En la sociedad actual, el uso del vehículo es prácticamente indispensable para millones de personas. Ya sea para desplazarse al trabajo, realizar actividades cotidianas o transportar mercancías, los automóviles desempeñan un papel clave en la vida diaria y en el funcionamiento económico. Este alto nivel de dependencia hace que cualquier mejora en la eficiencia energética y la sostenibilidad tenga un impacto significativo a nivel individual y colectivo.

En este contexto, el consumo de combustible y las emisiones de gases contaminantes, como el CO<sub>2</sub> y NO<sub>x</sub>, son dos de los principales problemas en el ámbito del transporte. Según estudios, el estilo de conducción tiene un impacto directo sobre estos factores: una conducción agresiva, caracterizada por aceleraciones bruscas y frenadas constantes, puede aumentar el consumo de combustible hasta un 30% [1], mientras que una conducción constante y tranquila resulta más eficiente.



Figura 1. Vehículos emitiendo gases contaminantes, extraído de [7]

Sin embargo, muchos conductores desconocen cómo sus hábitos de conducción afectan al consumo de combustible y al medio ambiente, en parte debido a la falta de herramientas accesibles que analicen sus hábitos y ofrezcan recomendaciones personalizadas. Esta carencia limita el potencial para optimizar tanto el impacto medioambiental como los gastos asociados al transporte.

Por otra parte, aunque los vehículos eléctricos se presentan como una alternativa más sostenible, su impacto ambiental depende en gran medida de la fuente de electricidad utilizada y del impacto de la fabricación de baterías. En regiones con alta dependencia de combustibles fósiles para la generación de electricidad, su sostenibilidad puede ser cuestionable.

En este panorama, los sistemas de diagnóstico a bordo como el OBD-II (On-Board Diagnostics) ofrecen una oportunidad única para recopilar datos en tiempo real sobre el consumo de combustible y otros parámetros del vehículo. Sin embargo, el uso de esta tecnología sigue siendo limitado debido a la complejidad de interpretación para usuarios no técnicos. Aprovechar estas herramientas para mejorar la eficiencia energética y reducir el impacto medioambiental podría marcar una diferencia significativa.

## 1.2. Relevancia del problema

El transporte es responsable de aproximadamente el 24% de las emisiones globales de CO<sub>2</sub> relacionadas con la energía, según datos de la Agencia Internacional de Energía (IEA) [2]. Estas emisiones contribuyen al cambio climático y afectan a la calidad del aire en las ciudades, perjudicando directamente la salud pública y aumentando los costos asociados con la atención sanitaria.




Figura 2. Emisiones del CO<sub>2</sub> generadas por el transporte frente a otros sectores en España, extraído de [10]

El estilo de conducción desempeña un papel crucial en esta problemática. Una conducción eficiente no solo reduce el consumo de combustible y las emisiones de gases contaminantes, sino que también contribuye a la sostenibilidad global. Sin embargo, el desconocimiento y la

falta de herramientas accesibles para evaluar y optimizar los hábitos de conducción dificultan la adopción de prácticas más responsables.

Aunque los vehículos eléctricos están ganando terreno como alternativa sostenible, su implementación a gran escala enfrenta retos relacionados con su fabricación y el origen de la electricidad utilizada. En regiones con alta dependencia de combustibles fósiles para la generación de electricidad, la sostenibilidad de los vehículos eléctricos puede ser cuestionable. [12]

Por lo tanto, cualquier avance en la mejora de los hábitos de conducción de vehículos de combustión interna, híbridos o eléctricos tiene un impacto significativo tanto ambiental como económico.

## **1.3. Estado del arte**

### **1.3.1. Tecnología OBD-II**

El sistema OBD-II fue implementado de forma obligatoria en vehículos desde 1996 en Estados Unidos y adoptado globalmente en años posteriores [3]. Se ha consolidado como un estándar en diagnóstico de vehículos. Este sistema permite monitorizar datos esenciales del vehículo, como revoluciones por minuto (RPM), velocidad, posición del acelerador o carga del motor, entre otros, mediante sensores integrados en el vehículo.

Su principal ventaja radica en la capacidad de ofrecer información en tiempo real sobre el estado del motor y otros componentes del vehículo, lo que resulta valioso tanto para el diagnóstico técnico como para el análisis de hábitos de conducción.

Sin embargo, el uso del OBD-II fuera del entorno profesional sigue siendo limitado. Las herramientas disponibles, como lectores OBD-II tradicionales o aplicaciones móviles conectadas a dispositivos como ELM327, permiten la recopilación de datos, pero la interpretación y análisis de estos requieren conocimientos técnicos que no están al alcance de todos los usuarios.

Este proyecto propone una solución innovadora que simplifica la interpretación de estos datos, ofreciendo recomendaciones claras y accesibles para mejorar los hábitos de conducción.

### 1.3.2. Aplicaciones basadas en OBD-II

En los últimos años, varias aplicaciones han comenzado a aprovechar el potencial del OBD-II para proporcionar datos útiles a los conductores. Entre las más relevantes se encuentran:

#### 1. Torque Pro:

Es una de las aplicaciones más populares en el ámbito del diagnóstico de vehículos. Permite monitorizar en tiempo real parámetros como velocidad, RPM, temperatura del motor y consumo de combustible [4]. Sin embargo, su enfoque principal es técnico, orientado a identificar problemas mecánicos, sin ofrecer un análisis detallado de hábitos de conducción o recomendaciones personalizadas.



Figura 3. Interfaz de la aplicación Torque Pro, extraído de [4]

## 2. DashCommand:

Esta aplicación combina el análisis de datos del OBD-II con información GPS para generar informes sobre consumos de combustible y hábitos de conducción. Aunque DashCommand ofrece algunas métricas útiles, no incluye cálculos avanzados como la marcha actual, lo que limita su capacidad para fomentar una conducción más sostenible.



Figura 4. Interfaz de la aplicación Dash Command, extraído de [8]

### 3. Xiaomi HUD:

Este dispositivo, lanzado en 2019, utiliza el dispositivo OBD-II para proyectar datos básicos en HUD (Head-Up Display). Aunque es más accesible visualmente para los conductores, está limitado a información básica como velocidad y RPM, sin integrar métricas avanzadas ni análisis relacionados con sostenibilidad o consumo de combustible.



Figura 5. Imagen del dispositivo Xiaomi HUD, extraído de [9]

#### 1.3.3. Limitaciones en las soluciones actuales

Las herramientas disponibles en el mercado, como Torque Pro, Dash y Xiaomi HUD, han facilitado el acceso a datos de vehículos mediante la tecnología OBD-II. Sin embargo, estas soluciones presentan varias limitaciones importantes:

- Falta de personalización: estas aplicaciones no ofrecen recomendaciones prácticas ni adaptadas al estilo de conducción específico del usuario.
- Integración limitada de datos: carecen de integración de sensores avanzados, como acelerómetros o giroscopios, que pueden proporcionar información muy importante sobre maniobras agresivas.
- Enfoque técnico: están diseñadas para usuarios con conocimientos técnicos, lo que dificulta su adopción por parte de conductores promedio.
- Ausencia de análisis sostenibles: no abordan de manera explícita la optimización del consumo de combustible ni la reducción de emisiones contaminantes.

### 1.3.4. Tabla comparativa

Características	Torque Pro	Dash-Command	Xiaomi HUD	Propuesta desarrollada
Recomendaciones personalizadas	No	No	No	Basados en estilos de conducción
Uso de acelerómetro y giroscopio	No	No	No	Para identificar maniobras agresivas
Cálculo de marcha actual	No	No	No	Basado en velocidad y RPM
Sostenibilidad y eficiencia	No	No	No	Optimización de consumo y emisiones
Usabilidad para conductores promedio	No	Sí	Sí	Interfaz gráfica intuitiva
Conectividad y almacenamiento	Tiempo real	Tiempo real	Tiempo real	Exportación a Excel y JSON, y análisis en la nube

Tabla comparativa de las principales aplicaciones utilizadas en el mercado y la propuesta desarrollada

### 1.3.5. Ventajas de la propuesta desarrollada

La solución desarrollada en este proyecto se posiciona como una herramienta innovadora, ya que:

1. Personalización y sostenibilidad: proporciona recomendaciones prácticas basadas en un análisis detallado del estilo de conducción, promoviendo la eficiencia en el consumo de combustible y la reducción de emisiones contaminantes.
2. Integración de datos avanzados: combina datos recogidos del dispositivo OBD-II con sensores móviles (acelerómetro y giroscopio), permitiendo detectar maniobras agresivas como frenadas bruscas o giros repentinos.
3. Accesibilidad: la interfaz gráfica es intuitiva y accesible, adecuada para conductores promedio sin necesidad de conocimientos técnicos avanzados.
4. Análisis en tiempo real y almacenamiento: exporta datos a formatos comunes como Excel o JSON, y permite su procesamiento en la nube para análisis avanzados

mediante Machine Learning, lo que proporciona información útil y accesible para mejorar los hábitos de conducción.

5. Sistema poco invasivo y fácil de instalar: el usuario utiliza su propio smartphone para la conexión con el OBD-II y la nube, sin necesidad de dispositivos adicionales. Esto convierte el sistema en una solución práctica, económica y de fácil implementación.

Estas características diferencian esta propuesta de las herramientas actuales, ofreciendo un enfoque más completo, accesible, sostenible y con un impacto positivo tanto en el medio cambiante como en el consumo de combustible.

### **1.3.6. Impacto del estilo de conducción en el consumo y el medio ambiente**

Estudios recientes han demostrado que el estilo de conducción tiene un impacto directo en el consumo de combustible y las emisiones de gases contaminantes. Por ejemplo, aceleraciones bruscas y frenadas constantes incrementan el consumo de combustible hasta en un 30% en comparación con una conducción suave y constante [13]. De igual manera, una conducción a bajas revoluciones por minuto y en marchas adecuadas puede reducir significativamente las emisiones de CO<sub>2</sub> y mejorar el consumo de combustible del vehículo.

El análisis de datos como la marcha actual, la posición del acelerador, la carga del motor o las variaciones en el giroscopio y acelerómetro del dispositivo móvil, permite obtener una visión más precisa de cómo los hábitos de conducción afectan el rendimiento del vehículo, contribuyendo a la optimización del consumo de combustible y la reducción de emisiones.

### **1.3.7. Oportunidad de mejora con este proyecto**

Este proyecto propone desarrollar una aplicación móvil que extrae datos en tiempo real del OBD-II, incluyendo parámetros como velocidad actual, revoluciones por minuto, posición del acelerador, carga del motor y ajuste corto del combustible. Además, integra datos de los sensores de giroscopio y acelerómetro de los dispositivos móviles, y obtiene información sobre la velocidad máxima permitida en las vías mediante una API externa (Here Maps API).

El sistema analizará el estilo de conducción del usuario para proporcionar recomendaciones prácticas y personalizadas, con el objetivo de optimizar el consumo de combustible y reducir el impacto ambiental. Al integrar todos estos datos de forma coherente, se pretende superar

las limitaciones de las aplicaciones existentes, brindando una herramienta accesible y educativa que ayude a los conductores a adoptar hábitos de conducción más sostenibles.

## **1.4. Objetivos**

### **1.4.1. Objetivo general**

El objetivo general de este proyecto es diseñar y desarrollar una aplicación móvil que se conecte a dispositivos OBD-II para analizar datos en tiempo real del vehículo y proporcionar recomendaciones prácticas para mejorar el estilo de conducción, optimizar el consumo de combustible y reducir el impacto medioambiental.

### **1.4.2. Objetivos específicos**

A lo largo de este proyecto se han definido una serie de objetivos que incluyen la implementación de la conexión Bluetooth con dispositivos OBD-II, la recopilación de datos como velocidad, revoluciones por minuto, posición del acelerador, carga del motor, y ajuste corto del combustible, así como la integración de sensores del dispositivo móvil (giroscopio y acelerómetro) para detectar maniobras agresivas.

También, se llevará a cabo un análisis exhaustivo del estilo de conducción, proporcionando recomendaciones personalizadas para reducir las emisiones y mejorar la eficiencia del consumo de combustible, con un enfoque particular en la sostenibilidad ambiental.

Además, se comparará el desempeño de dos modelos de clasificación: uno utilizando todas las variables disponibles y otro basado en un subconjunto de variables optimizadas.

### **1.4.3. Alcance del proyecto**

El alcance de este proyecto se centra en el desarrollo de una aplicación móvil que utiliza la tecnología OBD-II y los sensores del dispositivo móvil para analizar datos en tiempo real del vehículo, con el objetivo de optimizar el consumo de combustible y reducir el impacto ambiental mediante la mejora del estilo de conducción.

## **Límites del alcance**

### **1. Cálculo de la marcha actual ajustado a un vehículo específico**

El cálculo de la marcha actual ha sido optimizado para un modelo específico de vehículo, asegurando precisión en las pruebas realizadas. La metodología podría ser adaptada en trabajos futuros.

### **2. Datos obtenidos del OBD-II**

El análisis se limita a los datos disponibles en vehículos compatibles con el estándar OBD-II.

### **3. Velocidad máxima permitida**

La aplicación integra una API para obtener la velocidad máxima de la vía. No obstante, la cobertura de esta funcionalidad depende de la disponibilidad de datos en tiempo real proporcionada por la API.

### **4. Recomendaciones para el conductor**

El sistema ofrece recomendaciones prácticas para optimizar el consumo de combustible basadas en el estilo de conducción, pero no interviene de manera automática en el vehículo.

### **5. Interfaz y experiencia del usuario**

La aplicación cuenta con una interfaz gráfica diseñada para ser accesible y comprensible por cualquier conductor, permitiendo visualizar datos en tiempo real y recibir recomendaciones de manera intuitiva. Sin embargo, el diseño se centra en la funcionalidad básica y no incluye personalización avanzada para distintos perfiles de usuario.

## **Exclusiones**

La compatibilidad con vehículos eléctricos o híbridos fuera del alcance del estándar OBD-II no está incluida, y el análisis se centrará en el consumo de combustible y las emisiones de CO<sub>2</sub>, excluyendo otros factores como el desgaste del vehículo o los costos de mantenimiento.

## 1.5. Particularidades y ventajas del sistema propuesto

### Particularidades del sistema

#### 1. Conectividad bluetooth no invasiva

- El sistema no requiere modificaciones en el vehículo ni la instalación de hardware adicional, ya que utiliza un dispositivo OBD-II estándar y una conexión inalámbrica Bluetooth.
- Esto contrasta con soluciones que requieren cableado, instalación de dispositivos externos o intervención directa en la ECU del vehículo.

#### 2. Compatibilidad universal:

- Gracias al uso del estándar del OBD-II, el sistema es compatible con la mayoría de los vehículos modernos (posteriores a 1996 en Estados Unidos y 2000 en la Unión Europea). Esto lo hace adaptable a diferentes marcas y modelos sin necesidad de personalización adicional.

#### 3. Integración de sensores del móvil:

- Combina datos del OBD-II con los sensores del dispositivo móvil (acelerómetro y giroscopio) para enriquecer los análisis. Esto permite detectar eventos como frenazos bruscos o volantazos, proporcionando un contexto adicional que muchos sistemas comerciales no ofrecen.

#### 4. Cálculo innovador de la marcha actual:

- La determinación de la marcha actual de un vehículo a través del sistema OBD-II presenta ciertas particularidades:
  1. Disponibilidad de PIDs específicos: Aunque existe el PID 0xA4 denominado “ Transmission Actual Gear” según la documentación de OBD-II, su implementación no es uniforme en todos los vehículos. Algunos fabricantes pueden proporcionar la información de la marcha actual a través de PIDs específicos, mientras que otros no.
  2. Limitaciones del estándar OBD-II: El estándar OBD-II se centra principalmente en parámetros relacionados con emisiones y rendimiento del motor.
  3. Acceso a la información de la marcha: Normalmente, la marcha actual es un dato transmitido internamente a través del bus CAN del vehículo,

que conecta múltiples módulos electrónicos, incluida la transmisión. Sin embargo, el OBD-II accede solo a datos expuestos por la ECU del motor, por lo que no siempre permite obtener directamente la marcha sin usar herramientas avanzadas de diagnóstico que accedan al CAN de forma más profunda.

- Debido a estas limitaciones y a la falta de un PID estándar y universalmente implementado para obtener la marcha actual, se ha desarrollado un algoritmo que estima la marcha actual basándose en parámetros como la velocidad del vehículo, las revoluciones por minuto (RPM), la relación de la transmisión y la circunferencia de las ruedas. Este enfoque permite calcular la marcha en tiempo real sin depender de la disponibilidad de PIDs específicos, ofreciendo una solución más consistente y aplicable a una amplia gama de vehículos.

#### **5. Exportación de datos en tiempo real**

- Los datos capturados se exportan en formato JSON y Excel, un formato ampliamente compatible y fácil de manejar para el usuario final y para análisis posteriores.

### **Ventajas del sistema propuesto**

#### **1. Menor coste**

- El sistema utiliza un dispositivo OBD-II asequible y un smartphone, eliminando la necesidad de equipos especializados o suscripciones costosas a plataformas comerciales.

#### **2. Facilidad de uso**

- No requiere conocimientos avanzados para su instalación o configuración. El usuario solo necesita emparejar el dispositivo bluetooth con la app y comenzar a obtener datos.

#### **3. Portabilidad y flexibilidad**

- Al estar basado en un dispositivo móvil, el sistema es altamente portátil y puede utilizarse en distintos vehículos sin complicaciones.

#### **4. Mayor privacidad**

- Los datos permanecen bajo el control del usuario, ya que se capturan en el dispositivo móvil y solo se procesan en la nube, sin almacenarse en ella. Esto evita riesgos asociados a soluciones que transmiten datos automáticamente a servidores externos.

#### **5. Conducción segura y eficiente**

- Al incluir datos como las revoluciones por minuto, la marcha actual y velocidad máxima de la vía, el sistema puede ayudar al conductor a optimizar su conducción y mejorar la seguridad en carretera.

#### **6. Potencial para análisis avanzado**

- El sistema no solo captura datos en tiempo real, sino que también está diseñado para integrarse con plataformas como Azure para análisis avanzados. Esto lo diferencia de herramientas que solo ofrecen funcionalidades básicas de monitoreo.

## **1.6. Metodología**

### **1.6.1. Establecimiento del objetivo**

Tras el análisis exploratorio, el objetivo del proyecto se estableció como:

- Detectar y caracterizar los estilos de conducción mediante el uso de datos del OBD-II y sensores del móvil.
- Generar una base de datos con información rica y estructurada que pueda utilizarse para:
  - Evaluar patrones de conducción
  - Identificar hábitos de manejo ineficientes
  - Detectar eventos críticos, como frenadas de emergencia o giros peligrosos

## 1.6.2. Exploración de sensores y datos disponibles

El primer paso fue identificar las fuentes de datos relevantes para el sistema propuesto. Se decidió utilizar:

- **Dispositivo OBD-II:** para obtener información del vehículo, como velocidad, revoluciones por minuto, carga del motor, posición del acelerador y ajuste corto del combustible.
- **Sensores del móvil:** acelerómetro y giroscopio, que permitieron detectar frenadas bruscas, volantazos y maniobras repentinas


Además, se realizó una investigación para comprender las características de los datos proporcionados por el dispositivo OBD-II y su formato estándar.



Figura 6. Dispositivo OBD utilizado

## 1.6.3. Recolección de los primeros datos

Se desarrolló una aplicación móvil que permite capturar y almacenar los datos en tiempo real, tanto del OBD-II como de los sensores del móvil.



En las pruebas iniciales, se verificó la conectividad Bluetooth con el dispositivo OBD-II y se compararon los datos obtenidos con los valores del tablero del vehículo. Los resultados mostraron que el sistema era preciso en la captura de datos, aunque se ajustaron ciertos parámetros de sincronización para asegurar que los datos del OBD-II y los sensores móviles se integran sin problemas.

Estas pruebas iniciales ayudaron a ajustar el sistema y resolver posibles errores en la obtención o sincronización de datos.

Figura 7. Interfaz de la aplicación en la que se muestran datos en tiempo real

#### 1.6.4. Diseño de escenarios de conducción

Para realizar un análisis exploratorio representativo, se definieron 3 estilos de conducción distintos:

- **Conducción deportiva:** velocidades altas, revoluciones altas, aceleraciones rápidas y frenadas bruscas.
- **Conducción normal:** velocidades moderadas y comportamiento de conducción equilibrado.
- **Conducción tranquila:** velocidades bajas, aceleraciones suaves y frenadas progresivas.

Cada estilo de conducción se replicó con dos conductores diferentes en condiciones reales, lo que permitió obtener una muestra de datos variada. Las pruebas se realizaron en las mismas rutas para garantizar la fiabilidad de los datos al compararlos.

#### 1.6.5. Análisis exploratorios de los datos

Una vez recogidos los datos, se llevaron a cabo las siguientes acciones:

1. **Visualización inicial:** se generaron gráficos y tablas que mostraban patrones de revoluciones por minuto, velocidad, aceleraciones, marcha y giros para cada estilo de conducción.
2. **Identificación de patrones:** se observaron diferencias claras entre los estilos de conducción en variables como:
  - **RPM promedio:** más alto en conducción deportiva y más bajo en conducción tranquila.
  - **Número de frenadas bruscas:** más frecuentes en conducción deportiva.
  - **Consumo de combustible estimado:** más elevado en conducción deportiva, en comparación con conducción tranquila.
3. **Comparación entre conductores:** se analizaron las diferencias individuales en el mismo estilo de conducción, destacando cómo la personalidad o experiencia de cada conductor influye en los datos.

Este análisis ayudó a comprender cómo las diferentes condiciones y estilos de conducción impactan en los datos obtenidos.

## **1.7 Estructura de la memoria**

La memoria se estructura en siete capítulos.

El Capítulo 1: Introducción, presenta el contexto del proyecto, su motivación, objetivos y una revisión del estado del arte. En el Capítulo 2: Contexto, se analiza el entorno social y tecnológico, explicando conceptos clave como el sistema OBD-II, los sensores móviles y el machine learning. El Capítulo 3: Sistema desarrollado, detalla el diseño del sistema, su arquitectura, componentes principales, flujos de datos y funcionalidades. En el Capítulo 4: Resultados obtenidos, se presentan las pruebas realizadas, los datos recolectados y una discusión sobre la precisión de la eficacia del sistema. En el Capítulo 5: Impacto social y medioambiental, se analizan los efectos positivos y negativos del sistema en la conducción, la sostenibilidad y la seguridad. El Capítulo 6: Planificación y presupuesto describe las fases del proyecto, la planificación temporal y los recursos utilizados. Finalmente, el Capítulo 7: Conclusiones y trabajos futuros resume los resultados obtenidos y propone posibles líneas de investigación y desarrollo.

# Capítulo 2

## Contexto

### 2.1. Contexto social y relevancia

La preocupación por el impacto medioambiental de la conducción y la búsqueda de la eficiencia en el consumo de combustible se han convertido en temas de gran interés tanto para conductores individuales como para organismos reguladores. [\[14\]](#)

La creciente necesidad de reducir emisiones de gases contaminantes y optimizar la conducción tiene implicaciones económicas y ambientales a nivel global.

En este contexto, una herramienta que permita analizar el estilo de conducción de los usuarios y ofrecer recomendaciones personalizadas puede contribuir significativamente a reducir el impacto ambiental y mejorar la eficiencia de consumo en vehículos. Además, la popularización de dispositivos OBD-II facilita la extracción de información crítica del funcionamiento del vehículo, permitiendo evaluar parámetros como la velocidad, revoluciones por minuto o la carga del motor.

### 2.2. Contexto tecnológico

El proyecto se enmarca en la tendencia actual hacia la digitalización de la movilidad, donde la telemetría, los dispositivos conectados y las aplicaciones móviles juegan un papel clave. Los dispositivos OBD-II son estándares en los automóviles relativamente modernos y permiten la obtención de datos del sistema electrónico del control del vehículo.

Por otro lado, la disponibilidad de APIs y sensores integrados en dispositivos móviles, como el acelerómetro y el giroscopio, abre nuevas oportunidades para analizar la conducción con un alto nivel de precisión. Al combinar estas tecnologías con servicios en la nube como Microsoft Azure, es posible almacenar, procesar y analizar grandes volúmenes de datos para obtener información valiosa y realizar recomendaciones.

## 2.3. Conceptos teóricos

Para comprender la naturaleza del proyecto, es necesario definir ciertos conceptos clave:

- OBD-II (On-Board Diagnostics): sistema que proporciona acceso a la información del vehículo, como velocidad, revoluciones por minuto, posición del acelerador y carga del motor.
- Telemetría de conducción: obtención y envío de datos sobre el comportamiento del vehículo y su conductor.
- Sensores del móvil: el acelerómetro y giroscopio permiten detectar frenadas bruscas, aceleraciones y volantazos, elementos que resultan clave para analizar el estilo de conducción.
- Relación de marchas: cálculo aproximado de la marcha actual utilizando la velocidad del vehículo, las revoluciones por minuto y las características técnicas del vehículo, como por ejemplo tamaño del neumático.
- Eficiencia de combustible: indicador del consumo óptimo de carburante en función del estilo de conducción y las condiciones de manejo.

## 2.4. Tecnologías utilizadas

Para el desarrollo del proyecto se han seleccionado tecnologías clave, cuya combinación facilita la implementación y el éxito del sistema:

- Android y Kotlin: desarrollo de una aplicación móvil que permite la conexión con el dispositivo OBD-II mediante bluetooth. Se ha optado por utilizar el lenguaje de programación Kotlin especialmente por su seguridad, eficiencia y soporte de funciones modernas.
- API OBD-II (kotlin-obd-api): librería que facilita la extracción de parámetros del vehículo en tiempo real, como velocidad, revoluciones por minuto y otros datos relevantes.
- Sensores del móvil: uso de capacidades del acelerómetro y giroscopio para detectar maniobras agresivas (frenadas bruscas, aceleraciones y volantazos).
- APIs de tráfico (Here Maps API): acceso a información sobre límites de velocidad de las vías mediante una API externa.
- Excel y Microsoft Azure: los datos recopilados se almacenan inicialmente en un archivo Excel para posteriormente ser subidos a Azure y permitir un análisis exhaustivo en la nube.
- Machine Learning: análisis de datos mediante algoritmos de aprendizaje profundo para identificar patrones de conducción y generar recomendaciones personalizadas.

## 2.5. Justificación de las tecnologías seleccionadas

La selección de tecnologías para este proyecto ha sido guiada por criterios de accesibilidad, compatibilidad, escalabilidad y eficiencia, garantizando una solución robusta, funcional y fácil de implementar.

### 2.5.1. Android y Kotlin

- Accesibilidad y popularidad: Android es el sistema operativo móvil más extendido a nivel global, lo que abre un amplio mercado de usuarios potenciales. Además, Kotlin se alinea con la evolución tecnológica de Android, siendo el lenguaje recomendado por Google, lo que garantiza soporte a largo plazo y actualizaciones continuas. [\[15\]](#)
- Compatibilidad con hardware y sensores: los dispositivos Android cuentan con sensores como el acelerómetro y el giroscopio, fundamentales para la detección de maniobras bruscas (volantazos, frenazos y aceleraciones) por parte del conductor.
- Facilidad de integración con bluetooth: Android proporciona APIs nativas para la conexión bluetooth, lo cual permite una comunicación eficiente con dispositivos OBD-II.
- Rendimiento optimizado: Kotlin ofrece herramientas modernas como coroutines, que permiten gestionar múltiples procesos de forma eficiente sin bloquear la interfaz de usuario.

### 2.5.2. API OBD-II (kotlin-obd-api)

- Estandarización: la API kotlin-obd-api proporciona un acceso simplificado a los datos del dispositivo OBD-II, el cual sigue el estándar internacional ISO 15765-4. Este estándar permite la obtención de parámetros críticos como revoluciones por minuto, velocidad, posición del acelerador, ajuste de la centralita en el combustible inyectado y la carga del motor. Además, esta estandarización puede facilitar la ampliación futura del sistema a nuevas marcas y modelos de vehículos sin la necesidad de personalización adicional. [\[16\]](#)
- Fácil implementación: la biblioteca abstrae la complejidad de la comunicación con la ECU (Unidad de Control del Motor), permitiendo enviar comandos y recibir datos en tiempo real de forma sencilla.
- Optimización del rendimiento: la API está diseñada para funcionar eficientemente con Kotlin, reduciendo tiempos de respuesta y garantizando la actualización en tiempo real de los datos obtenidos.

### 2.5.3. Sensores del móvil

El uso de los sensores móviles para la captura de maniobras bruscas y otras características del estilo de conducción es una de las mayores ventajas del sistema:

- Alta precisión: los sensores integrados en los móviles, como el acelerómetro y el giroscopio, permite detectar maniobras bruscas con alta precisión, lo cual es fundamental para el análisis del estilo de conducción. Sin embargo, factores como el tipo de superficie o el estado de la carretera podría afectar a los datos recogidos.
- Sin coste adicional: al utilizar hardware ya presente en el dispositivo móvil, no se requiere hardware externo, reduciendo costes y mejorando la accesibilidad del sistema.
- Datos en tiempo real: los sensores permiten obtener mediciones continuas en milisegundos, lo que facilita un análisis dinámico de las acciones del conductor (frenazos y volantazos).

Sin embargo, los datos recogidos presentaron algunas deficiencias debido a ruidos en la señal y variaciones en la posición del móvil dentro del vehículo, lo que puede afectar la precisión del análisis. Es probable que el uso de un acelerómetro externo calibrado específicamente para este propósito proporcione mediciones más precisas y estables.

### 2.5.4. APIs de tráfico (Here Maps API)

- Información contextual adicional: el acceso a información sobre velocidades máximas permitidas en las vías mediante una API externa añade una capa de análisis adicional. Esta información permite evaluar si el conductor supera los límites establecidos, aportando datos críticos para determinar hábitos de conducción no seguros o ineficientes. [\[17\]](#)
- Actualización constante: al utilizar una API externa, los datos se actualizan automáticamente, garantizando información precisa y en tiempo real sin intervención del usuario.

### 2.5.5. Excel y Microsoft Azure

- Excel para almacenamiento temporal: inicialmente, los datos obtenidos se almacenan en un archivo Excel debido a su simplicidad y compatibilidad con otras herramientas de análisis. Excel permite organizar los datos recogidos de forma estructurada y accesible.

- Microsoft Azure para escalabilidad:
  - Almacenamiento en la nube: Azure ofrece servicios de almacenamiento en la nube que permiten guardar grandes volúmenes de datos de forma segura y escalable.
  - Procesamiento y análisis: Azure proporciona herramientas avanzadas para el procesamiento y análisis de datos [\[5\]](#), facilitando la implementación de algoritmos de Machine Learning para el análisis del estilo de conducción.
  - Accesibilidad global: la plataforma en la nube permite acceder a los datos desde cualquier ubicación, facilitando el análisis y las consultas remotas.
- Integración con herramientas analíticas: Azure facilita la integración con lenguajes como Python y bibliotecas como pandas y TensorFlow, permitiendo realizar análisis estadísticos avanzados y construir modelos predictivos.

### **2.5.6. Machine Learning**

- Análisis de patrones complejos: el uso de algoritmo de Machine Learning permite analizar grandes volúmenes de datos y detectar patrones complejos en el comportamiento de conducción que no son evidentes a simple vista.
- Recomendaciones personalizadas: los modelos de Machine Learning permiten clasificar el estilo de conducción de cada conductor, facilitando las sugerencias para mejorar la eficiencia del combustible y reducir el impacto ambiental.

## Capítulo 3

# Sistema desarrollado

Este capítulo describe en detalle el sistema desarrollado, que combina tecnologías móviles, procesamiento en la nube y APIs externas para recopilar, analizar y clasificar datos relacionados con el estilo de conducción.

### 3.1. Descripción General del Sistema

El sistema se compone de varios componentes interconectados que permiten la recopilación, análisis y visualización de datos relacionados con el comportamiento del conductor y las condiciones del vehículo. Los principales componentes son:

- Aplicación móvil (Android): se comunica con otros componentes como el dispositivo OBD-II mediante una conexión bluetooth, hace consultas a las API de Here Maps de manera constante para obtener información sobre la velocidad máxima de las vías, mostrarla en pantalla e integrarla con el procesamiento de datos en la nube de Azure AI mediante una consulta de API Rest de cliente a servidor de manera directa.




Figura 8. Diagrama general del sistema desarrollado

- Procesamiento en la nube: en Azure AI se utiliza el algoritmo Voting Ensemble [6] para analizar los datos recopilados. El algoritmo es fundamental para determinar el estilo de conducción (normal, tranquilo, agresivo) en función de parámetros como aceleración, frenado y maniobras bruscas. La nube facilita el procesamiento de grandes volúmenes de datos y la implementación de modelos de inteligencia artificial sin comprometer el rendimiento del dispositivo móvil.
- Consulta a Here Maps API: la integración de la API de Here Maps permite obtener en tiempo real la velocidad máxima de la vía por donde circula el conductor, lo que añade un gran valor al análisis. Esta información es vital para evaluar si el conductor respeta los límites de velocidad.
- Interfaz gráfica: la interfaz de usuario muestra los datos recogidos en tiempo real de manera clara y atractiva. Utilizando la librería com.github.mikephil, se crean gráficas dinámicas que representan el comportamiento del vehículo (por ejemplo, revoluciones por minuto o velocidad).
- Almacenamiento y Análisis de Datos: inicialmente, los datos se almacenan en un archivo Excel en el dispositivo móvil. Luego, estos datos se transforman a un formato JSON para que puedan ser utilizados por el API de Azure AI para un análisis más profundo. Este enfoque de almacenamiento facilita la gestión de grandes volúmenes de datos y su posterior procesamiento.

## 3.2. Especificación de Requisitos

En este apartado se detallan los requisitos que el sistema debe cumplir para garantizar su correcto funcionamiento. Se dividen en requisitos generales, que aplican a todo el sistema, y requisitos funcionales específicos, que detallan las funcionalidades esperadas por cada uno de los componentes del sistema.

### 3.2.1. Requisitos Generales del Sistema

Estos requisitos describen las funcionalidades esenciales que el sistema debe cumplir en su conjunto;

- Conexión OBD-II: la aplicación debe ser capaz de conectarse a un dispositivo OBD-II por bluetooth y recopilar datos en tiempo real como revoluciones por minuto, ajuste corto de combustible, velocidad, etc.
- Consulta a Here Maps: la aplicación debe consultar la API de Here Maps para obtener la velocidad máxima de la vía en tiempo real.

- Clasificación de estilo de conducción: utilizar un modelo de Inteligencia Artificial alojado en Azure para clasificar el estilo de conducción en categorías: normal, tranquilo y agresivo, basándose en los datos recolectados.
- Almacenamiento de datos: los datos recopilados deben ser almacenados en un archivo Excel localmente en el dispositivo móvil.
- Visualización en interfaz gráfica: los datos deben ser presentados de manera clara y comprensible en la interfaz gráfica, usando gráficas y métricas como RPM, velocidad y otros parámetros relevantes. Esto facilita la interacción del usuario con la aplicación y permite una evaluación intuitiva de su estilo de conducción.
- Recomendaciones personalizadas: la aplicación debe ofrecer recomendaciones personalizadas para mejorar el estilo de conducción y hacerlo más eficiente a partir de los datos recogidos, que ayuden al conductor a mejorar su estilo de conducción, optimizar el consumo de combustible y reducir su impacto medio ambiental.

### 3.2.2. Requisitos Funcionales Específicos

A continuación, se describen los requisitos funcionales organizados por cada componente del sistema:

1. Aplicación Móvil (Android):
  - Debe detectar y conectarse a dispositivos OBD-II cercanos con bluetooth.
  - Debe solicitar y obtener datos del OBD-II en intervalos regulares de tiempo.
  - Debe procesar los datos en tiempo real y enviarlos a la nube para su análisis.
  - Debe integrar la API de Here Maps para obtener la velocidad máxima de la vía en función de la ubicación del usuario.
  - Debe almacenar los datos en formato Excel y permitir su conversión a JSON para su uso en Azure AI.
  - Debe mostrar en la interfaz los datos en tiempo real.
  - Debe mostrar los datos recopilados durante la conducción mediante gráficos.
  - Debe enviar los datos recopilados a la nube (Azure) para su análisis.
2. Dispositivo OBD-II:
  - Debe proporcionar datos en tiempo real del vehículo.
  - Debe permitir la conexión vía Bluetooth con la aplicación móvil.
  - Debe enviar datos en un formato compatible con la API utilizada en la aplicación.

### 3. Azure AI

- Debe recibir datos en formatos JSON desde la aplicación móvil.
- Debe procesar los datos utilizando el algoritmo Voting Ensemble para clasificar el estilo de conducción.
- Debe devolver la clasificación del estilo de conducción a la aplicación móvil para su visualización.
- Debe garantizar una respuesta rápida para evitar retrasos en la interfaz de usuario.

### 4. API de Here Maps

- Debe recibir la ubicación del usuario y devolver la velocidad máxima permitida en la vía en tiempo real.
- Debe integrarse correctamente con la aplicación móvil mediante consultas API.
- Debe manejar errores de consulta.
- Debe actualizarse dinámicamente conforme el usuario cambia de ubicación.

## 3.2.3. Requisitos Funcionales Específicos

- Rendimiento: el sistema debe permitir la recopilación y procesamiento en tiempo real sin afectar el rendimiento del dispositivo móvil.
- Escalabilidad: el sistema debe permitir el procesamiento y almacenamiento de datos a medida que aumentan la cantidad de registros.
- Compatibilidad: el sistema debe ser compatible con dispositivos Android que soporten Bluetooth y la API de OBD-II.
- Seguridad: los datos deben ser almacenados y transmitidos de manera segura, especialmente los relacionados con la conducción del usuario.

## 3.3. Diseño de alto nivel

### 3.3.1. Arquitectura general y Componentes Principales

El sistema está basado en una arquitectura cliente-servidor, donde la aplicación móvil actúa como cliente y la nube (Azure AI) como servidor para el procesamiento de datos. A continuación, se describen los principales componentes y su interacción dentro del sistema.

## Arquitectura del Sistema

La aplicación móvil, desarrollada en Kotlin, se conecta al dispositivo OBD-II mediante bluetooth para recopilar en tiempo real datos del vehículo como revoluciones por minuto (RPM), velocidad, carga del motor y otros parámetros relevantes.

Posteriormente, consulta la API de Here Maps para obtener la velocidad máxima permitida en la vía, y almacena los datos en un archivo Excel en el dispositivo.

Estos datos se procesan mediante un modelo de Machine Learning alojado en Azure AI, el cual clasifica el estilo de conducción del usuario (normal, tranquilo o agresivo). Finalmente, la aplicación muestra los resultados y ofrece recomendaciones personalizadas para mejorar la conducción.

## Componentes del Sistema

1. Aplicación móvil (Cliente):
  - Desarrollada en Kotlin.
  - Se conecta con el dispositivo OBD-II por bluetooth.
  - Obtiene en tiempo real los datos del vehículo.
  - Realiza consultas a la API de Here Maps.
  - Muestra los resultados al usuario y ofrece recomendaciones.
  - Almacena los datos en un archivo Excel para análisis posteriores.
  
2. Dispositivo OBD-II:
  - Proporciona datos del vehículo a la aplicación móvil mediante bluetooth.
  
3. API Here Maps:
  - Se consulta en tiempo real para obtener la velocidad máxima de la vía.
  
4. Azure AI (Servidor y procesamiento en la nube):
  - Recibe los datos enviados desde la aplicación móvil.
  - Utiliza algoritmos de Machine Learning para clasificar el estilo de conducción.
  - Devuelve la clasificación correspondiente a la aplicación móvil.

A continuación, se presenta el diagrama de componentes que ilustra la relación entre estos elementos:

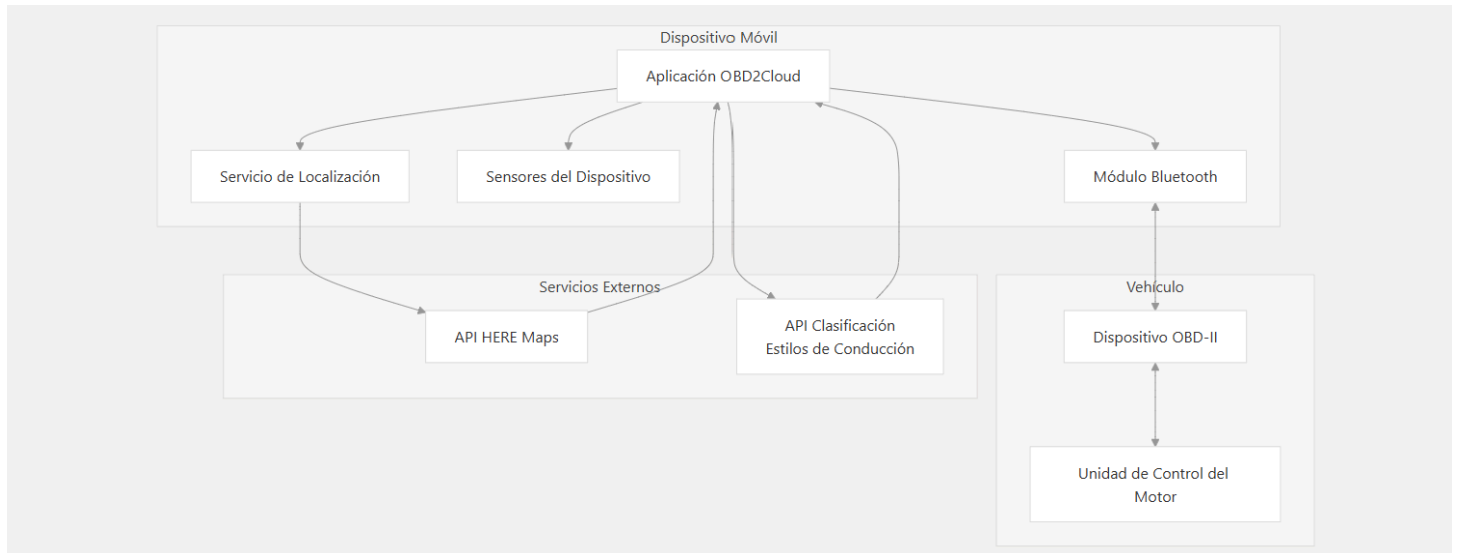


Figura 9. Diagrama de componentes del sistema

Este diseño modular permite la escalabilidad del sistema, facilitando el procesamiento en la nube sin afectar el rendimiento del dispositivo móvil y asegurando una interacción fluida con el usuario.

### 3.3.2. Componentes principales

Los componentes que conforman el sistema son los siguientes:

- **Aplicación móvil:** desarrollada en Kotlin, permite la conexión con el dispositivo OBD-II por bluetooth y la consulta en tiempo real de la API de HereMaps para obtener la velocidad máxima permitida en la vía. La aplicación muestra al usuario los resultados obtenidos y las recomendaciones personalizadas sobre su estilo de conducción.
- **API Here Maps:** se consulta en tiempo real para obtener la velocidad máxima permitida de la vía.
- **Azure AI:** procesa los datos enviados desde el móvil y devuelve la clasificación del estilo de conducción gracias a un algoritmo de Machine Learning.

- Almacenamiento local: los datos recopilados se almacenan inicialmente en un archivo Excel para su posterior análisis.

### **3.3.2. Comunicación entre componentes**

El flujo de datos en el sistema es el siguiente:

1. Recolección de datos: los datos se recogen en tiempo real desde el dispositivo OBD-II y los sensores móviles. También se realiza una consulta a OpenStreetMap para obtener la velocidad máxima permitida en la vía.
2. Transformación y envío: los datos recolectados se almacenan en un archivo Excel en el dispositivo móvil para su organización inicial. Posteriormente, el archivo Excel se convierte a JSON y se envía a Azure AI para su procesamiento.
3. Clasificación y respuesta: Azure AI procesa los datos y clasifica el estilo de conducción en las tres categorías mencionadas: normal, tranquilo o agresivo. Los resultados de la clasificación son devueltos al dispositivo móvil.
4. Visualización y retroalimentación: los resultados de la clasificación y las recomendaciones personalizadas se presentan visualmente al usuario en la interfaz gráfica de la aplicación, permitiéndole tomar decisiones para mejorar su estilo de conducción.

En el siguiente diagrama se muestra el flujo de comunicación entre los diferentes componentes:

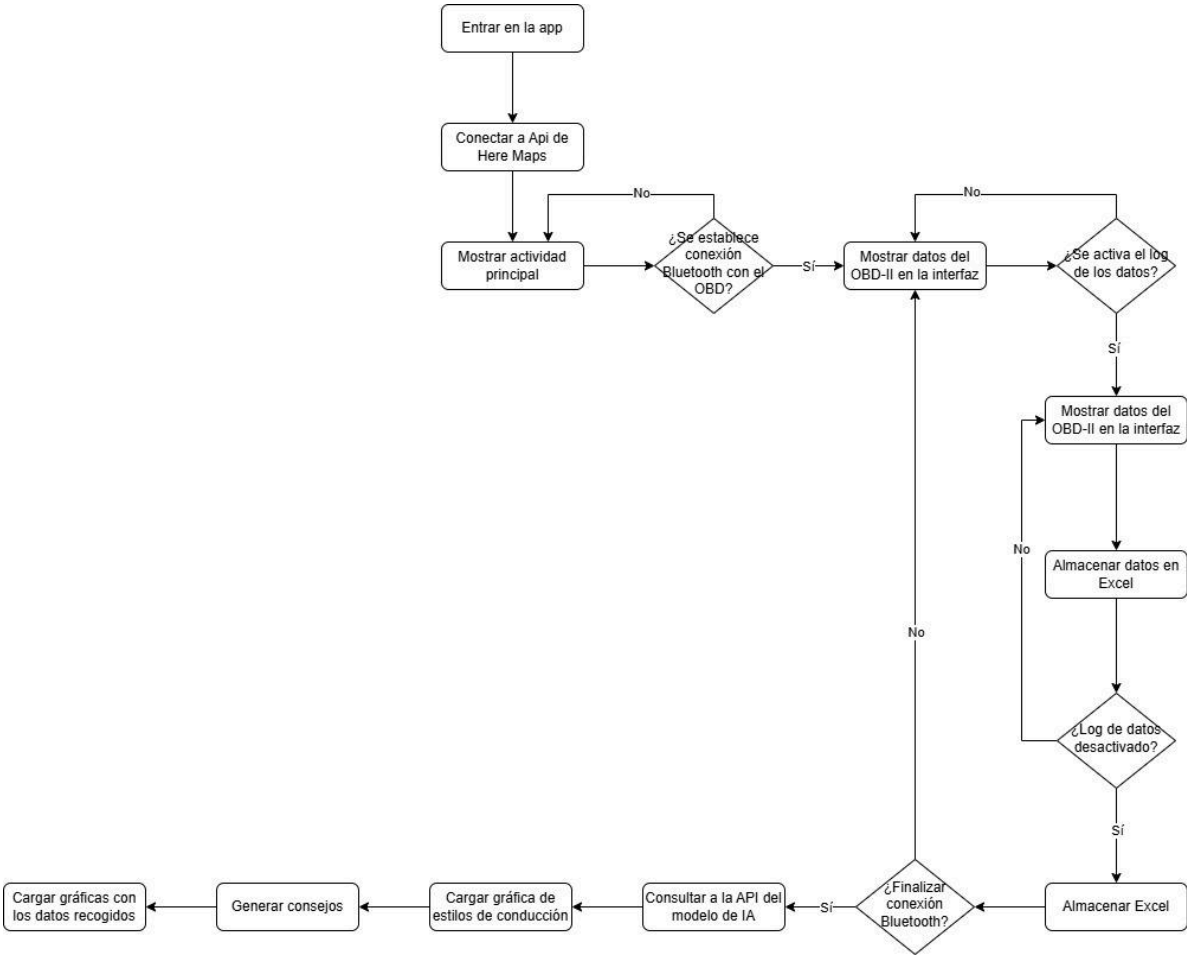


Figura 10. Diagrama de flujo del sistema desarrollado

En el siguiente diagrama se muestra la secuencia de interacción entre los diferentes componentes:

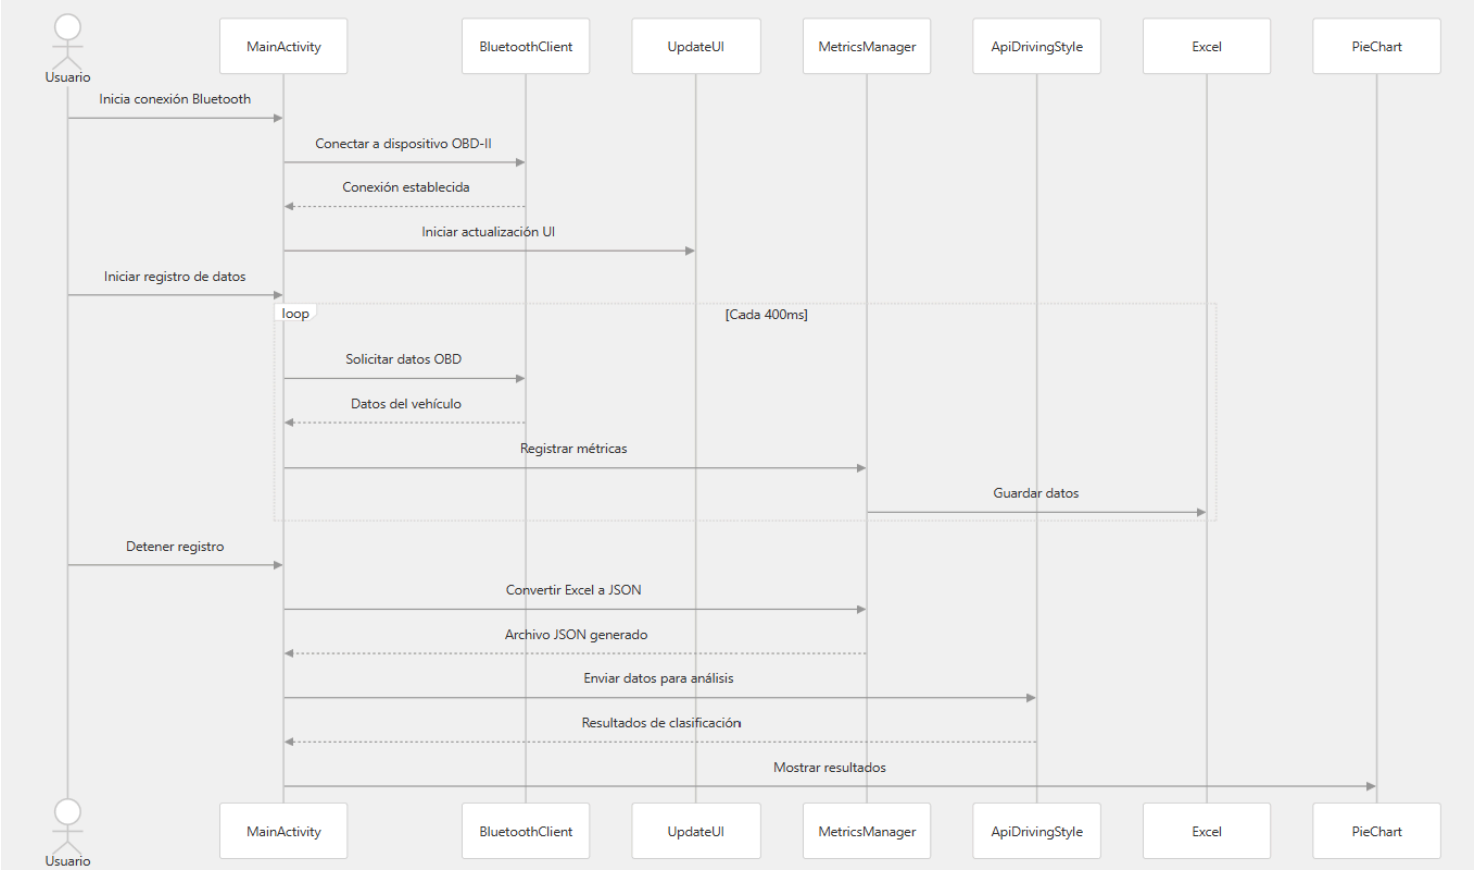


Figura 11. Diagrama de secuencia del sistema desarrollado

## 3.4. Diseño detallado

### 3.4.1. Recolección de datos

La recolección de datos en tiempo real se realiza mediante:

- Dispositivo OBD-II: conexión bluetooth a través de la API kotlin-obd-api, donde se extraen los siguientes datos:

Parámetro	Formato	Unidades	Nombre en análisis
Revoluciones por minuto	Entero	rpm	RPM
Velocidad del vehículo	Entero	km/h	Speed
Carga del motor	Porcentaje (0-100%)	%	Engine Load
Posición del acelerador	Porcentaje (0-100%)	%	Throttle Position
Ajuste corto de combustible	Porcentaje (-100-100%)	%	Fuel Trim

- Sensores del dispositivo móvil: se obtienen datos del acelerómetro y giroscopio.
- Contador de toques: se captura el número de veces que se toca la pantalla del móvil mientras se usa la aplicación.

### 3.4.2. Transformación y envío de datos

Una vez que los datos son recolectados, se siguen los siguientes pasos:

1. Almacenamiento en Excel: inicialmente, los datos se almacenan en un archivo Excel en el dispositivo móvil para permitir su revisión local y la organización de los registros.
2. Transformación a JSON: el archivo Excel se transforma a formato JSON para que sea compatible con Azure AI. La transformación a JSON asegura que los datos estén en un formato adecuado para su procesamiento en la nube, facilitando su análisis mediante los algoritmos de Machine Learning en Azure.

```

{
  "Input_data": {
    "columns": [
      "Touch Count",
      "RPM",
      "Fuel Trim",
      "Speed",
      "Throttle Position",
      "Engine Load",
      "Max Speed",
      "Gear",
      "Speed Diference",
      "Gyro X",
      "Gyro Y",
      "Gyro Z",
      "Accel X",
      "Accel Y",
      "Accel Z"
    ],
    "index": [
      1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12
    ],
    "data": [
      [
        "0", "1810", "2.0", "17", "24", "20", "30", "1", "0.210672", "0.399582", "-0.165773", "-5.011767", "7.23111", "5.182256",
        "-30"
      ]
    ]
  }
}

```

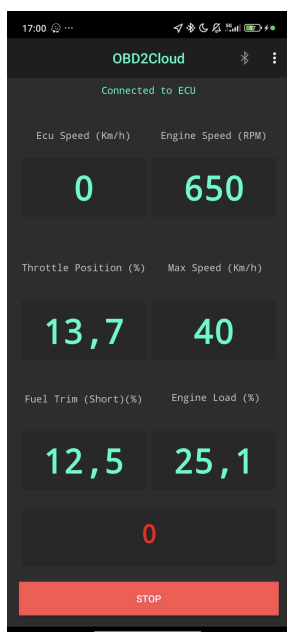
Figura 12. Estructura del archivo JSON que se envía a la nube para realizar la consulta sobre el estilo de conducción

- Envío a Azure: los datos convertidos a JSON se envían a Azure AI para su procesamiento y análisis, donde se clasificarán según el estilo de conducción del usuario.

### 3.4.3. Visualización de resultados y recomendaciones

Los resultados de clasificación del estilo de conducción se muestran en una interfaz gráfica que incluye:


- Datos en tiempo real: la aplicación muestra información actualizada sobre los parámetros del vehículo, como revoluciones por minuto, velocidad, posición del acelerador o carga del motor, entre otros.



- Gráfico circular de estilos de conducción: en este se puede observar el porcentaje de tiempo que el conductor ha pasado en cada estilo de conducción (normal, tranquilo, agresivo). Esto proporciona una visualización clara del comportamiento del conductor a lo largo del trayecto.

- Recomendaciones: debajo del gráfico de estilos de conducción, la aplicación presenta recomendaciones para mejorar el estilo de conducción. Estas recomendaciones se generan a partir de los datos recogidos durante la conducción, como las revoluciones por minuto (RPM), velocidad media, posición del acelerador (Throttle), carga del motor, y el Fuel Trim (ajuste de combustible). Se ofrecen de manera específica para cada conductor en función de su estilo predominante.

Figura 13. Datos en tiempo real mostrados por la aplicación



Las recomendaciones incluyen las siguientes sugerencias:

1. Aceleración más suave: Si se detecta una posición del acelerador elevada o un fuel trim (ajuste de combustible) alto, se sugiere al conductor mantener una aceleración más progresiva para mejorar la eficiencia del combustible.

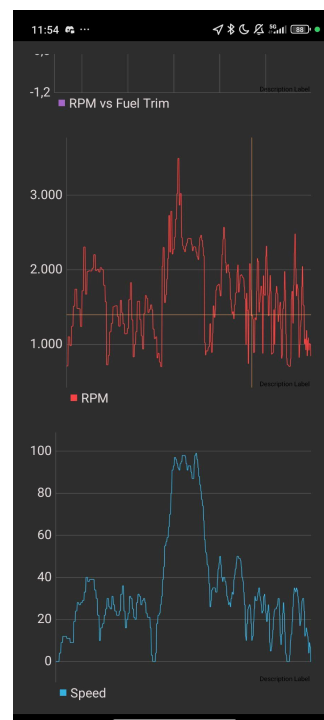
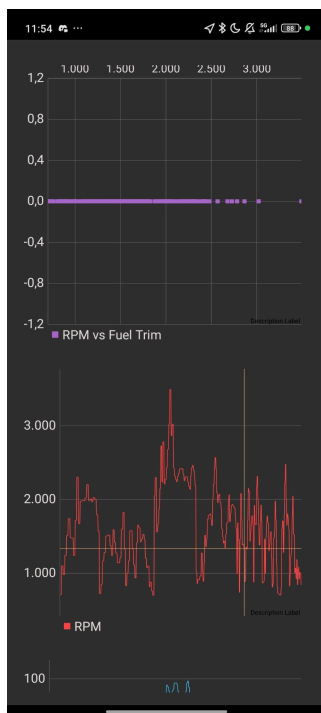
2. Evitar frenadas y aceleraciones bruscas: En estilos agresivos, se sugiere al conductor conducir de forma más relajada para reducir el consumo y el desgaste del motor.

3. Reducción de velocidad: Si la velocidad media supera ciertos valores (por ejemplo, 100 km/h), se recomienda disminuirla para mejorar la seguridad.

Figura 14. Recomendaciones mostradas por la aplicación

4. Mantenimiento de RPM adecuadas: Cuando las revoluciones del motor son elevadas (por ejemplo, mayores a 3000 rpm en conducción agresiva), se aconseja reducirlas para evitar un consumo excesivo y cuidar la vida útil del motor.

5. Mejorar la eficiencia de combustible: En casos donde el fuel trim (ajuste de combustible) es alto, se ofrecen consejos para optimizar la mezcla de aire-combustible conduciendo de manera más equilibrada.
- Gráficas de las métricas: la aplicación muestra representaciones visuales de las métricas clave: RPM vs Fuel Trim (Ajuste de combustible), RPM y Speed. Estas gráficas ayudan a comprender mejor cómo los diferentes parámetros afectan el estilo de conducción.



Figuras 15 y 16. Gráficas de las métricas recogidas durante la conducción.

### 3.5. Almacenamiento y Análisis de datos

- Almacenamiento local: los datos recopilados inicialmente se almacenan en formato Excel en el dispositivo móvil, lo que permite analizarlos fuera de la aplicación antes de enviarlos a la nube.
- Análisis de los Datos: una vez enviados a Azure AI, los datos son procesados mediante técnicas de Machine Learning, utilizando un modelo basado en LightGBM (Light Gradient Boosting Machine). Antes de entrenar el modelo, se aplica un proceso

de normalización de los datos mediante la técnica MaxAbsScaler, que escala los datos numéricos al rango [-1, 1] sin modificar ni perder información relativa.

### Características del modelo:

-Tipo de modelo: LightGBM

-Preprocesamiento: MaxAbsScaler (normalización de características numéricas)

-Entradas del modelo: RPM, Fuel Trim, Speed, Throttle Position, Engine Load, Max Speed, Gear, Speed Difference, Gyro X, Gyro Y, Gyro Z, Accel X, Accel Y, Accel Z.

-Salida: Predicción del estilo de conducción (tranquilo, normal, agresivo).

-Ventajas del modelo: LightGBM es eficiente y preciso para tareas de clasificación multiclase, especialmente con datasets estructurados. Es adecuado para dispositivos con recursos limitados o procesamiento en la nube.

Este modelo ha sido entrenado en Azure Machine Learning Studio con un conjunto de datos etiquetado previamente, clasificando patrones de conducción en función de métricas recogidas en tiempo real por la aplicación.

- Vista Gráfica: la aplicación proporciona una vista gráfica de los resultados procesados, con gráficos de las métricas y recomendaciones personalizadas. Esto permite al usuario entender su comportamiento de conducción y mejorar su eficiencia y seguridad al volante.



Figura 17. Matriz de confusión del modelo LightGBM entrenado en Azure ML.

## 3.6. Clasificación del estilo de conducción

El sistema desarrollado implementa dos modelos de clasificación en la nube de Azure AI para procesar los datos recopilados en formato JSON y categorizar el estilo de conducción del usuario en tres niveles: normal, tranquilo y agresivo.

Para la clasificación, se han probado dos enfoques diferentes:

- Modelo completo: utiliza todas las variables disponibles en los datos recolectados del OBD-II y los sensores móviles.
- Modelo refinado: emplea un subconjunto de variables seleccionadas en base a su correlación y relevancia en la clasificación, con el objetivo de optimizar la precisión y reducir la complejidad computacional.

### 3.6.1. Modelo completo: Parámetros utilizados

Este modelo emplea todas las variables recogidas para la clasificación del estilo de conducción:

- Número de toques de la pantalla: Indica la interacción del conductor con la aplicación, lo que puede correlacionarse con distracción.
- Revoluciones por minuto (RPM): Determina cómo se está utilizando el motor. RPM muy altas o bajas pueden indicar conducción agresiva o ineficiente.
- Ajuste corto de combustible (%): Refleja el ajuste de la centralita para el combustible inyectado a corto plazo, lo que puede estar relacionado con la eficiencia del consumo.
- Velocidad (Km/h): La velocidad real del vehículo, un factor clave para determinar la conducción agresiva.
- Posición del acelerador (%): Indica la cantidad de presión sobre el acelerador. Valores altos pueden sugerir aceleraciones bruscas.
- Carga del motor (%): Representa la cantidad de esfuerzo que está haciendo el motor, lo cual puede estar vinculado a una conducción más agresiva.
- Velocidad máxima permitida (Km/h): Límite de velocidad de la vía, proporcionado por OpenStreetMap. Permite evaluar si el conductor respeta las normas de tránsito.
- Número de marcha: Ayuda a identificar si el vehículo está en una marcha adecuada para su velocidad actual.
- Valores del giroscopio (X, Y, Z): Detecta inclinaciones y movimientos bruscos, como volantazos.
- Valores del acelerómetro (X, Y, Z): Permite identificar frenadas bruscas y aceleraciones rápidas, así como volantazos, indicadores de conducción agresiva.
- Diferencia de velocidad respecto a la velocidad máxima permitida (Speed Difference)

### 3.6.2. Modelo refinado: Parámetros utilizados

El modelo refinado selecciona únicamente las variables con mayor correlación con el estilo de conducción, eliminando aquellas que aportaban menor relevancia. Las variables elegidas fueron:

- Revoluciones por minuto (RPM)
- Posición del acelerador (%) (Throttle Position)
- Carga del motor (%) (Engine Load)
- Aceleración en el eje X (AccelX, ayuda a detectar volantazos)
- Diferencia de velocidad respecto a la velocidad máxima permitida (Speed Difference)

Con el objetivo de simplificar el modelo y mantener una alta capacidad de discriminación entre los diferentes estilos de conducción, se realizó una selección de variables basadas en análisis estadísticos robustos. Para ello se siguieron los siguientes pasos:

#### 1. Comparación entre estilos sin separar por conductor:

Se aplicó un análisis ANOVA para evaluar si existían diferencias significativas en las variables en función del estilo de conducción (tranquilo, normal y agresivo). Tras un primer análisis, resultó que algunas variables tenían igualdad de varianzas y otras no. Para las que no tenían igualdad de varianzas se hizo el test de Welch.

A continuación se muestran las tablas con los resultados del análisis ANOVA y el test de Welch.

## ANOVA

		Suma de cuadrados	gl	Media cuadrática	F	Sig.
SpeedExcess	Inter-grupos	5950,089	2	2975,044	15,969	,000
	Intra-grupos	906753,664	4867	186,306		
	Total	912703,753	4869			
Gear	Inter-grupos	949,663	2	474,831	197,207	,000
	Intra-grupos	11718,657	4867	2,408		
	Total	12668,320	4869			
RPM	Inter-grupos	435475862	2	217737931	577,365	,000
	Intra-grupos	1835461649	4867	377123,824		
	Total	2270937511	4869			
Fuel Trim	Inter-grupos	334,333	2	167,166	12,946	,000
	Intra-grupos	62845,781	4867	12,913		
	Total	63180,114	4869			
Speed	Inter-grupos	6427,700	2	3213,850	5,644	,004
	Intra-grupos	2771361,724	4867	569,419		
	Total	2777789,424	4869			
Throttle Position	Inter-grupos	1879,745	2	939,872	54,089	,000
	Intra-grupos	84571,630	4867	17,377		
	Total	86451,375	4869			
Engine Load	Inter-grupos	6920,174	2	3460,087	14,707	,000
	Intra-grupos	1145076,776	4867	235,274		
	Total	1151996,950	4869			
Accel X	Inter-grupos	4,614	2	2,307	21,093	,000
	Intra-grupos	532,341	4867	,109		
	Total	536,956	4869			

Figura 18. Resultados ANOVA

		Estadístico <sup>a</sup>	gl1	gl2	Sig.
SpeedExcess	Welch	14,272	2	3141,909	,000
Gear	Welch	199,535	2	3240,014	,000
RPM	Welch	558,297	2	2891,844	,000
Fuel Trim	Welch	13,304	2	3217,042	,000
Speed	Welch	5,984	2	3146,032	,003
Throttle Position	Welch	67,564	2	2871,268	,000
Engine Load	Welch	14,178	2	3217,921	,000
Accel X	Welch	21,459	2	3217,020	,000

a. Distribuidos en F asintóticamente.

Figura 19. Resultados del test de Welch

Entre los dos test, todas las variables tienen diferencias muy significativas ( $p < 0.01$ ) excepto la variable speed, que aún así es significativa ( $p < 0.05$ ).

## 2. Pruebas post-hoc:

Se realizó la prueba de Games-Howell para identificar entre qué estilos de conducción se producían diferencias significativas. Los resultados evidenciaron que la mayoría de las variables permitían distinguir de forma clara entre los tres estilos, lo que refuerza su capacidad discriminativa.

### Comparaciones múltiples

Games-Howell

Variable dependiente	(I) Estilo conduccion	(J) Estilo conduccion	Diferencia de medias (I-J)	Error típico	Sig.
SpeedExcess	0	1	,443	,454	,592
		2	-2,142*	,474	,000
	1	0	-,443	,454	,592
		2	-2,585*	,521	,000
	2	0	2,142*	,474	,000
		1	2,585*	,521	,000
Gear	0	1	,563*	,055	,000
		2	1,089*	,054	,000
	1	0	-,563*	,055	,000
		2	,526*	,053	,000
	2	0	-1,089*	,054	,000
		1	-,526*	,053	,000
RPM	0	1	-323,897*	15,888	,000
		2	-737,976*	24,245	,000
	1	0	323,897*	15,888	,000
		2	-414,079*	25,772	,000
	2	0	737,976*	24,245	,000
		1	414,079*	25,772	,000
Fuel Trim	0	1	,204	,129	,254
		2	-,437*	,117	,001
	1	0	-,204	,129	,254
		2	-,640*	,131	,000
	2	0	,437*	,117	,001
		1	,640*	,131	,000
Speed	0	1	-1,744	,782	,066
		2	-2,790*	,846	,003
	1	0	1,744	,782	,066
		2	-1,046	,907	,481
	2	0	2,790*	,846	,003
		1	1,046	,907	,481
Throttle Position	0	1	-,9003*	,1316	,000
		2	-1,5179*	,1421	,000
	1	0	,9003*	,1316	,000
		2	-,6176*	,1709	,001
	2	0	1,5179*	,1421	,000
		1	,6176*	,1709	,001
Engine Load	0	1	-2,0679*	,5299	,000
		2	,7678	,5338	,321
	1	0	2,0679*	,5299	,000
		2	2,8356*	,5541	,000
	2	0	-,7678	,5338	,321
		1	-2,8356*	,5541	,000
Accel X	0	1	,027573327*	,011386348	,041
		2	,075466659*	,011575231	,000
	1	0	-,027573327*	,011386348	,041
		2	,047893332*	,011935481	,000
	2	0	-,075466659*	,011575231	,000
		1	-,047893332*	,011935481	,000

Figura 20. Resultados Games-Howell

En la tabla anterior, los estilos de conducción se corresponden de la siguiente manera:

0 → Tranquilo

1 → Normal

2 → Agresivo

Las variables que no presentaron diferencias significativas en todos los estilos de conducción fueron:

-SpeedExcess: entre los estilos 0-1

-Fuel Trim: entre los estilos 0-1

-Speed: entre los estilos 0-1 y 1-2

-Engine Load: entre los estilos 0-2

### **3. Selección de variables:**

A partir de los resultados anteriores, se seleccionaron aquellas variables con mayor capacidad para diferenciar estilos de conducción. Las variables finalmente elegidas fueron:

- RPM (Revoluciones por minuto)
- Throttle Position (Posición del acelerador)
- Engine Load (Carga del motor)
- Accel X (Aceleración del eje X )
- SpeedExcess (Diferencia de velocidad del vehículo y la velocidad máxima permitida)
- Gear (Número de marcha)

Estas seis variables fueron utilizadas en el modelo refinado por su relevancia estadística y su capacidad para capturar patrones clave del comportamiento al volante.

### **4. Análisis de conglomerados:**

Con las variables seleccionadas, se realizaron agrupamientos de estilos de conducción utilizando técnicas de clustering. Se compararon agrupaciones de 3 y 4 grupos.

A pesar de que el conglomerado de 3 grupos podría parecer el más adecuado, ya que coincide con el número de clases objetivo del modelo (conducción tranquila, normal y agresiva), se optó por un modelo de 4 grupos.

Esta decisión se basó en que el modelo de 4 grupos permitía aislar un subconjunto de datos correspondiente a situaciones de baja actividad, como paradas en semáforos o señales de stop, circulación en punto muerto o retenciones en atascos.

**Centros de los conglomerados finales**

	Conglomerado			
	1	2	3	4
Throttle Position	19,3	17,0	23,7	15,0
RPM	2273	1592	3248	943
Gear	3	3	3	2
Accel X	-,023305	-,045408	-,102040	-,059032
SpeedExcess	1	-5	5	-17
Engine Load	38,4	32,2	42,8	28,0

**Número de casos en cada conglomerado**

Conglomerado	1	973,000
	2	1692,000
	3	291,000
	4	1914,000
Válidos		4870,000
Perdidos		,000

Figura 21. Resultados conglomerados

Este grupo ayudaba a separar esas situaciones mencionadas anteriormente del resto de estilos de conducción, lo que en teoría mejoraría la calidad del entrenamiento y posterior clasificación del modelo de Machine Learning.

Finalmente, se decidió eliminar del modelo refinado el número de marcha, ya que se llegó a la conclusión de que no sería determinante a la hora de clasificar el estilo de conducción.

## Resultado de la Clasificación

El modelo clasifica el estilo de conducción en tres categorías:

- Normal: Conducción eficiente y dentro de los parámetros estándar de velocidad y comportamiento.

- Tranquilo: Conducción relajada, con aceleraciones suaves y respetando los límites de velocidad.
- Agresivo: Conducción caracterizada por aceleraciones rápidas, frenadas bruscas y velocidad excesiva.

# Capítulo 4

## Resultados obtenidos

### 4.1. Pruebas realizadas

#### 4.1.1. Pruebas de conectividad Bluetooth

Para comprobar la capacidad de la aplicación de conectarse a diferentes dispositivos OBD-II, se realizaron pruebas en diferentes vehículos y condiciones:

- Vehículos utilizados: se han utilizado tres modelos diferentes con una diferencia considerable entre sus años de fabricación:
  - Honda Accord (año de fabricación: 2003)
  - Fiat Stilo (año de fabricación: 2008)
  - Jaguar XF (año de fabricación: 2017)
- Condiciones: se intentó conectar al dispositivo OBD-II mediante bluetooth realizando conducciones en ciudad, carretera y en reposo.
- Parámetros evaluados: se evaluó el tiempo promedio de conexión y éxito de conexión en el primer intento.

#### 4.1.2. Pruebas de extracción de datos

Se compararon los datos obtenidos desde el dispositivo OBD-II con los valores mostrados en el tablero del vehículo:

- Parámetros evaluados: revoluciones por minuto, velocidad, posición del acelerador y marcha actual.
- Metodología: se registraron datos simultáneamente durante un mismo trayecto de aproximadamente 10 minutos que mezclaba diferentes situaciones: ciudad, carretera, incorporaciones a autopista y situaciones con tráfico denso. Se realizaron 6 registros con 2 conductores diferentes.



- Velocidad máxima permitida
- Marcha
- Giroscopio en ejes X, Y, Z
- Acelerómetro en ejes X, Y, Z

#### 4.1.4. Pruebas de integración con sensores móviles

Se evaluó la capacidad de los sensores del móvil para detectar eventos significativos:

- Eventos detectados: frenadas bruscas, giros repentinos y aceleraciones rápidas.
- Métrica: precisión en la detección comparada con observaciones manuales




Figura 23. Gráfico de líneas y barras del acelerómetro en los ejes X y Z para detección de acelerones, frenadas y giros.

En este gráfico de líneas y barras podemos ver representado en azul el valor del acelerómetro en el eje X (lo que sirve para detectar aceleraciones si el valor es positivo y frenadas si es negativo), y el valor del acelerómetro en el eje Z (lo que sirve para detectar giros hacia la izquierda si el valor es negativo y hacia la derecha si el valor es positivo).

### **4.1.5. Pruebas de interfaz gráfica y facilidad de uso**

Se probó la claridad y usabilidad de la interfaz gráfica:

- Componentes evaluados: visualización de datos en tiempo real, navegación por la aplicación, comprensión de las recomendaciones y facilidad de uso.
- Método: Retroalimentación de usuarios mediante encuestas.

## **4.2. Resultados obtenidos**

### **4.2.1. Conectividad Bluetooth**

- Éxito de conexión: la aplicación logró conectarse al dispositivo OBD-II en el 90% de los intentos.
- Tiempo promedio de conexión: 4-5 segundos.

### **4.2.2. Datos del OBD-II**

Los datos medibles de forma objetiva mediante el cuadro del coche, como las revoluciones por minuto o la velocidad, coinciden a la perfección con los valores indicados en el cuadro de instrumentos del vehículo. Sin embargo, valores como la posición del acelerador o la carga del motor, aunque también relevantes, no pueden ser comprobados directamente con los indicadores del vehículo, ya que no existen medidores dedicados para estos parámetros en los cuadros de instrumentos estándar. Sin embargo, los valores obtenidos tienen sentido dentro del contexto del comportamiento del vehículo, por lo que deberían ser correctos.

En conclusión, los datos extraídos son lo suficientemente precisos para el análisis del estilo de conducción.

### **4.2.3. Clasificación de Estilos de Conducción**

- La aplicación, a partir de los datos recogidos, determinará el porcentaje de tiempo que se ha hecho un estilo de conducción de entre los 3 posibles (tranquilo, normal, agresivo), dando consejos para mejorar el estilo de conducción si fuese posible. Se mostrará en la aplicación de la siguiente forma:




Figura 24. Porcentaje de estilos de conducción detectados por la aplicación.

Para la clasificación del estilo de conducción, se han evaluado dos modelos distintos:

- Modelo completo: utiliza todas las variables disponibles y ha demostrado una alta precisión en pruebas reales (98,94%).
- Modelo refinado: emplea solo un subconjunto de variables seleccionadas por su relevancia en la clasificación. Aunque teóricamente mejora las métricas en validación, su desempeño en condiciones reales es notablemente inferior (42,91%).

A continuación se muestra una tabla comparativa con las métricas de validación de ambos modelos:

<b>Métrica</b>	<b>Modelo refinado</b>	<b>Modelo completo</b>
<b>Precisión</b>	0.99899	0.91437
<b>Macro de AUC</b>	1.0000	0.98467
<b>Micro de AUC</b>	1.0000	0.98477
<b>Valor ponderado de AUC</b>	1.0000	0.98466
<b>Macro de puntuación de precisión media</b>	0.99999	0.97260
<b>Micro de puntuación de precisión media</b>	1.0000	0.97266
<b>Valor ponderado de puntuación de precisión media</b>	1.0000	0.97268
<b>Precisión equilibrada</b>	0.99752	0.91448
<b>Macro de puntuación de F1</b>	0.99783	0.91415
<b>Micro de puntuación de F1</b>	0.99899	0.91437
<b>Valor ponderado de puntuación de F1</b>	0.99898	0.91429
<b>Pérdida de registro</b>	0.0073895	0.24964
<b>Correlación de Matthews</b>	0.99819	0.87156
<b>Coincidencia de macro normalizada</b>	0.99627	0.87172
<b>Macro de puntuación de precisión</b>	0.99817	0.91431
<b>Micro de puntuación de precisión</b>	0.99899	0.91437
<b>Valor ponderado de puntuación de precisión</b>	0.99899	0.91469
<b>Coincidencia de macro de puntuación</b>	0.99752	0.91448
<b>Coincidencia de micro de puntuación</b>	0.99899	0.91437
<b>Coincidencia de valor ponderado de puntuación</b>	0.99899	0.91437
<b>Precisión ponderada</b>	0.99959	0.91427

Como se observa en la tabla, el modelo refinado presenta métricas excepcionales en validación, pero su desempeño en pruebas reales es significativamente menor.

A continuación se muestra una tabla comparativa de los resultados obtenidos a partir de un conjunto de datos para cada persona y estilo de conducción:

### MODELO REFINADO

Conductor 1

Estilo de conducción	Registros a clasificar	Clasificaciones correctas	Porcentaje de acierto
Tranquilo	884	862	97,511%
Normal	924	176	19,068%
Agresivo	763	206	26,998%

Porcentaje de acierto medio con conductor 1: 47,86%

Conductor 2

Estilo de conducción	Registros a clasificar	Clasificaciones correctas	Porcentaje de acierto
Tranquilo	823	729	88,578%
Normal	739	132	17,861%
Agresivo	738	55	7,452%

Porcentaje de acierto medio con conductor 2: 37,96%

**Porcentaje de acierto medio de modelo refinado: 42,91%**

## MODELO COMPLETO

Conductor 1

Estilo de conducción	Registros a clasificar	Clasificaciones correctas	Porcentaje de acierto
Tranquilo	884	877	99,208%
Normal	924	912	98,701%
Agresivo	763	756	99,082%

Porcentaje de acierto medio con conductor 1: 98,99%

Conductor 2

Estilo de conducción	Registros a clasificar	Clasificaciones correctas	Porcentaje de acierto
Tranquilo	824	818	99,271%
Normal	740	729	98,513%
Agresivo	739	731	99,082%

Porcentaje de acierto medio con conductor 2: 98,9%

**Porcentaje de acierto medio de modelo completo: 98,94%**

Los resultados muestran que el modelo refinado no logra identificar correctamente los estilos de conducción en la realidad, a pesar de sus métricas superiores en la fase de entrenamiento. Esto podría deberse a varios motivos, como por ejemplo un sobreajuste, es decir, el modelo refinado podría estar demasiado ajustado a los datos de entrenamiento, lo que impide su generalización a escenarios reales. Otro posible motivo podría ser que algunas de las variables eliminadas durante el proceso de refinamiento, contengan información relevante para la clasificación en condiciones reales. Estos aspectos pueden ser abordados en trabajos futuros, con el fin de mejorar la capacidad de generalización del modelo y su aplicabilidad en contextos reales.

#### 4.2.4. Detección de Eventos con Sensores

- Precisión:
  - Frenadas bruscas: 90%
  - Giros repentinos: 85%
  - Aceleraciones: 90%

En la parte inferior se adjuntan gráficos de dispersión que permiten visualizar la relación entre la velocidad del vehículo y dos variables clave relacionadas con el estilo de conducción. En el primer gráfico, se representa en el eje X la velocidad y en el eje Y los valores del eje X del acelerómetro (AccelX), que reflejan giros repentinos. La nube de puntos junto con la línea de tendencia permite observar si existe una correlación entre la velocidad y la frecuencia o intensidad de los giros. En el segundo gráfico, se muestra también la velocidad en el eje X, y en el eje Y los valores del eje Z del giroscopio (GyroZ), que se asocian a aceleraciones y frenadas bruscas. La dispersión de los puntos y su tendencia permiten analizar si los comportamientos agresivos de aceleración o frenado tienden a darse a determinadas velocidades. Estas visualizaciones ayudan a identificar patrones que pueden relacionarse con diferentes estilos de conducción.




Figura 25. Relación entre la velocidad del vehículo y los valores del acelerómetro en el eje X (AccelX) para el análisis de giros bruscos





Figura 26. Relación entre la velocidad del vehículo y los valores del giroscopio en el eje Z (GyroZ) para el análisis de aceleraciones y frenadas bruscas.

#### 4.2.5. Interfaz gráfica y facilidad de uso

A continuación se muestran los resultados de la encuesta realizada por un total de 9 personas. Las encuestas fueron respondidas por usuarios con edades comprendidas entre los 23 y 54 años, todos con carnet de conducir. Se les proporcionó una breve explicación sobre el funcionamiento de la aplicación desarrollada y se les pidió que la utilizaran durante el mismo trayecto en coche. Durante la prueba, los participantes debían interactuar con la aplicación como lo harían en un uso normal, comprobando la conexión con el dispositivo OBD-II, la visualización de datos en tiempo real y la respuesta general de la interfaz. Al finalizar la prueba, completaron un formulario con preguntas relacionadas con la usabilidad, utilidad, precisión y diseño de la aplicación.


### ¿Los datos mostrados en la aplicación son fáciles de entender?

9 respuestas




### ¿La presentación de los datos en tiempo real es clara y legible?

9 respuestas




### ¿Los gráficos o indicadores utilizados facilitan la interpretación de la información?

9 respuestas



### ¿La actualización en tiempo real de los datos es suficientemente rápida y precisa?


9 respuestas



En una escala del 1 al 5, ¿qué tan satisfecho/a estás con la visualización de los datos en tiempo real?


 Copiar gráfico

9 respuestas




¿Fue fácil encontrar las funciones que estabas buscando?

9 respuestas




## ¿La estructura de la aplicación es intuitiva?

9 respuestas



## ¿Cuánto tiempo tardaste en aprender a usar la aplicación de forma efectiva?


9 respuestas



En una escala del 1 (muy difícil) al 5 (muy fácil), ¿cómo calificarías la facilidad de navegación de la aplicación?


 Copiar gráfico

9 respuestas




¿Las recomendaciones presentadas por la aplicación son claras y fáciles de entender?

9 respuestas




¿Consideras que las recomendaciones son relevantes para el uso que le das a la aplicación?

9 respuestas



¿Cómo de confiable consideras que es la información proporcionada por la aplicación?

9 respuestas



## 4.3. Discusión de resultados

En este apartado se realiza un análisis e interpretación de los resultados obtenidos durante el desarrollo y pruebas del sistema, evaluando su consistencia frente a las expectativas iniciales y su relevancia en el contexto del proyecto.

Además, se presentan comparaciones con estudios previos y una reflexión sobre las limitaciones encontradas y las posibles mejoras futuras.

### 4.3.1. Interpretación de los resultados

1. Conectividad Bluetooth: la aplicación logró conectarse al dispositivo OBD-II en el 90% de los intentos, con un tiempo promedio de conexión de 4-5 segundos. Esto demuestra que el sistema desarrollado es eficiente y confiable en la mayoría de escenarios evaluados. Sin embargo, el 10% de fallos en la conexión sugiere que podría haber problemas en situaciones específicas, como interferencias en la señal bluetooth.
2. Extracción de datos del OBD-II: los datos obtenidos de parámetros como revoluciones por minuto y velocidad coinciden perfectamente con los valores del tablero del vehículo, validando su precisión. Otros parámetros como la posición del acelerador y la carga del motor, no pudieron ser verificados directamente debido a la ausencia de medidores dedicados o indicadores en los vehículos, pero los valores obtenidos fueron consistentes con el comportamiento observado del vehículo.
3. Clasificación del estilo de conducción: el modelo de Machine Learning implementado logró una precisión del 91,13% al clasificar los estilos de conducción en las categorías “normal”, “tranquilo” y “agresivo”. Este resultado es satisfactorio considerando la complejidad del problema y la diversidad de datos involucrados.
4. Detección de eventos con sensores del dispositivo móvil: la detección de frenadas bruscas y aceleraciones obtuvo un 90% de precisión, mientras que los giros repentinos fueron detectados con un 85% de precisión. Estos valores son adecuados para propósitos prácticos, pero podrían mejorarse para aplicaciones que requieran un análisis más crítico.
5. Usabilidad e interfaz gráfica: las encuestas realizadas mostraron una aceptación positiva por parte de los usuarios en términos de claridad y facilidad de uso. Esto respalda la efectividad del diseño de la interfaz para cumplir con los objetivos de accesibilidad y comprensión.

### **4.3.2. Evaluación frente a las expectativas**

Los resultados obtenidos superaron las expectativas en términos de precisión del modelo y la fiabilidad de la conexión bluetooth. Sin embargo, el sistema presenta un margen de mejora en la detección de eventos con sensores y en la verificación de ciertos datos, como la carga del motor, debido a limitaciones en la comparación con indicadores que puedan ser utilizados de referencia.

### **4.3.3. Comparaciones entre pruebas y datos**

1. Conectividad y clasificación: la alta tasa de éxito en la conexión bluetooth fue un factor clave para garantizar la consistencia en la recopilación de datos, lo que a su vez contribuyó a la precisión del modelo de clasificación.
2. Eventos detectados y datos del OBD-II: los datos obtenidos del acelerómetro y giroscopio complementaron eficazmente los datos del OBD-II, proporcionando una vista más completa del estilo de conducción. Sin embargo, los datos recogidos mediante el OBD-II demostraron ser más precisos y confiables.

### **4.3.4. Comparación con estudios previos**

En comparación con aplicaciones existentes, como Torque Pro y Dash, el sistema desarrollado destaca por su integración de datos de sensores móviles y su capacidad para generar recomendaciones personalizadas basadas en el estilo de conducción.

Además, el modelo matemático utilizado para calcular la marcha actual ofrece una funcionalidad adicional que no se encuentra en la mayoría de las soluciones comerciales.

### **4.3.5. Aspectos concluyentes**

Los resultados obtenidos son concluyentes para demostrar la viabilidad del sistema propuesto. La precisión alcanzada en la clasificación del estilo de conducción y en la detección de eventos es suficiente para aplicaciones prácticas, y la interfaz gráfica cumple con los requisitos de usabilidad.

### 4.3.6. Limitaciones identificadas

Durante el desarrollo y las pruebas del sistema, se identificaron varias limitaciones que podrían abordarse en futuras mejoras del proyecto para mejorar la funcionalidad y la precisión del sistema:

1. Datos no validados directamente:
  - Parámetros como la carga del motor o la posición del acelerador no pudieron ser validados directamente debido a la falta de medidores específicos de los vehículos utilizados.
  - Impacto: esto podría limitar la confianza en ciertos análisis basados en estos datos, especialmente si estos parámetros son críticos para el estilo de conducción.
2. Precisión en la detección de giros repentinos:
  - Aunque el sistema logró identificar frenadas bruscas y aceleraciones con una precisión del 90%, los giros repentinos tuvieron una precisión ligeramente inferior (85%).
  - Impacto: en aplicaciones más críticas, como sistemas avanzados de asistencia al conductor o similares, esta precisión podría no ser suficiente.
3. Dependencia de APIs externas:
  - El sistema depende de la disponibilidad de datos en tiempo real de APIs como Here Maps para evaluar límites de velocidad.
  - Impacto: en áreas sin cobertura o con datos incompletos, esta funcionalidad podría no ser suficiente.

### 4.3.7. Mejoras propuestas y su implementación

Para superar estas limitaciones, se proponen las siguientes mejoras:

1. Validación cruzada de datos:
  - Implementación: realizar pruebas adicionales con vehículos que dispongan de herramientas de diagnóstico avanzadas para validar parámetros como la carga del motor y la posición del acelerador.
  - Impacto esperado: aumentará la fiabilidad de los datos y la confianza en los análisis realizados, especialmente en entornos más técnicos.
2. Ampliación de los datos de entrenamiento:
  - Implementación: recopilar datos de una mayor variedad de vehículos, condiciones de conducción y estilos de manejo para mejorar la generalización del modelo.

- Impacto esperado: reducirá el sesgo en los análisis y permitirá que el sistema sea más robusto frente a diferentes tipos de usuarios y vehículos.
3. Reducción de dependencia en APIs externas:
- Implementación: Incorporar un sistema de detección límites de velocidad basado en datos offline, utilizando mapas descargados previamente en el dispositivo móvil.
  - Impacto esperado: garantizará la funcionalidad en áreas con poca conectividad o sin cobertura.

#### **4.3.8. Impacto del trabajo**

Este proyecto combina tecnología de telemetría, análisis de datos de conducción y aprendizaje automático, ofreciendo una solución que:

- Optimiza el consumo de combustible al identificar y recomendar mejoras en el estilo de conducción.
- Reduce el impacto ambiental, fomentando prácticas de conducción más eficientes.
- Promueve la accesibilidad al integrar hardware asequible (OBD-II) con dispositivos móviles y software avanzado.

En comparación con herramientas existentes, el sistema destaca por:

- Personalización: Generación de recomendaciones adaptadas al conductor.
- Funcionalidad ampliada: Uso combinado de datos de OBD-II, sensores móviles y APIs.
- Innovación técnica: Implementación de clasificación de estilos de conducción y detección de eventos en tiempo real.

El trabajo realizado posiciona este sistema como un paso relevante en el desarrollo de tecnologías inteligentes para la conducción, con aplicaciones prácticas en la industria automotriz y en soluciones de movilidad sostenible.

## Capítulo 5

# Impacto social y medioambiental

### 5.1. Impacto social positivo

1. Educación y concienciación de los conductores: el sistema ofrece una plataforma accesible para que los conductores comprendan cómo sus hábitos afectan al consumo de combustible y las emisiones. La inclusión de recomendaciones prácticas y personalizadas permite a los usuarios mejorar su estilo de conducción. Esto no solo reduce el impacto ambiental, sino que también fomenta una cultura de conducción responsable y sostenible. En un contexto donde la mayoría de los conductores desconocen la influencia de sus hábitos en el medio ambiente, esta herramienta actúa como un puente entre la tecnología y la educación ambiental.
2. Aumento de la seguridad vial: detectar patrones de conducción agresiva, como frenadas bruscas o aceleraciones innecesarias, permite identificar comportamientos que aumentan el riesgo de accidentes. Al proporcionar retroalimentación, el sistema ayuda a los conductores a tomar decisiones más seguras, reduciendo potencialmente la incidencia de accidentes de tráfico.
3. Impacto económico positivo: optimizar el consumo de combustible reduce los gastos de gasolina, especialmente en entornos urbanos o trayectos largos. Según estudios, una conducción eficiente puede ahorrar hasta un 30% en costos de combustible. Además, al minimizar el desgaste del motor y otros componentes mecánicos, también se reducen los costos asociados al mantenimiento del vehículo.
4. Accesibilidad y democratización de la tecnología: el uso de dispositivo móviles y OBD-II estándar permite que cualquier conductor, independientemente de su nivel técnico, pueda beneficiarse del sistema. Esto contrasta con herramientas profesionales que requieren equipos especializados o conocimientos avanzados. Al centrarse en una interfaz gráfica sencilla y accesible, el sistema elimina barreras técnicas y facilita su adopción masiva.
5. Contribución a políticas públicas: este sistema podría ser un aliado estratégico para políticas de movilidad sostenible. Por ejemplo, los datos generados podrían servir como herramienta para estudios sobre tráfico urbano, consumo energético y emisiones en tiempo real, apoyando decisiones en el diseño de políticas de transporte y regulación ambiental.

## 5.2. Impacto medioambiental positivo

1. Reducción de emisiones de gases de efecto invernadero: según la Agencia Internacional de Energías (IEA), el transporte representa el 24% de las emisiones globales de CO<sub>2</sub> relacionadas con la energía. Al mejorar el estilo de conducción, el sistema ayuda a reducir emisiones innecesarias, lo que contribuye directamente a los objetivos globales de mitigación del cambio climático.
2. Optimización del consumo de recursos energéticos: la conducción eficiente no solo reduce las emisiones de CO<sub>2</sub>, sino que también optimiza el uso de combustible fósil. Esto es especialmente relevante en regiones donde los vehículos de combustión interna siguen siendo predominantes. La reducción de aceleraciones bruscas, marchas inadecuadas y frenadas constantes genera una mejora significativa en la eficiencia energética.
3. Mejora de la calidad del aire urbano: las ciudades enfrentan graves problemas de contaminación del aire debido a emisiones vehiculares. Este sistema podría contribuir a mitigar estos problemas, reduciendo la cantidad de partículas y gases tóxicos que afectan la salud pública.
4. Apoyo a la economía circular [\[11\]](#) y a la transición energética: aunque los vehículos eléctricos están ganando terreno, su adopción global todavía enfrenta desafíos relacionados con la infraestructura y la generación de energía limpia. Este sistema actúa como una solución intermedia, optimizando los recursos disponibles y reduciendo el impacto ambiental mientras se avanza hacia alternativas más sostenibles.

## 5.3. Impacto potencial negativo

1. Limitaciones tecnológicas y limitaciones de compatibilidad: la eficacia del sistema depende de la precisión de los dispositivos OBD-II y los sensores móviles. Esto puede excluir a conductores con vehículos antiguos o dispositivos no compatibles, limitando su alcance.
2. Huella ambiental de la infraestructura tecnológica: si bien el sistema promueve la sostenibilidad, su implementación conlleva impactos ambientales asociados al desarrollo y mantenimiento de la infraestructura tecnológica. La fabricación de dispositivos móviles y el uso de servidores en la nube para el procesamiento de datos generan emisiones indirectas de CO<sub>2</sub> que deben ser consideradas.

3. Gestión y seguridad de datos: aunque el sistema enfatiza la privacidad, la recopilación y almacenamiento de datos sensibles sobre conducción plantea desafíos relacionados con la ciberseguridad y la ética en el manejo de la información.
4. Impacto ambiental de la producción tecnológica: los dispositivos OBD-II y los smartphones implican procesos de extracción materias primas y fabricación que pueden tener un impacto significativo en el medio ambiente. Si el sistema no se implementa con estrategias claras para minimizar estos efectos, los beneficios podrían verse parcialmente reducidos.

## **5.4. Reflexión final**

El sistema desarrollado tiene un impacto transformador en la forma en que los conductores interactúan con la tecnología para mejorar su estilo de conducción. Su integración de herramientas como el OBD-II, sensores móviles y Machine Learning lo posiciona como una solución innovadora para enfrentar problemas de sostenibilidad, eficiencia energética y seguridad vial.

A pesar de los desafíos asociados a su implementación, los beneficios superan ampliamente a las limitaciones, especialmente cuando se considera su potencial para contribuir a la reducción de emisiones de gases contaminantes y mejorar la calidad de vida urbana. Este proyecto no solo es una muestra del poder de la tecnología para resolver problemas complejos, sino también un llamado a seguir explorando soluciones que equilibren innovación con sostenibilidad.

## **5.5. Datos objetivos**

- Ahorros potenciales: un estilo de conducción eficiente puede reducir el consumo de combustible hasta un 30%.
- Emisiones de CO<sub>2</sub>: el transporte representa el 24% de las emisiones globales relacionadas con la energía.
- Impacto urbano: las emisiones de vehículos son responsables de gran parte de los problemas de calidad del aire en ciudades densamente pobladas.

## **5.6. Impacto práctico y aplicaciones potenciales**

### **5.6.1. Integración en el mercado**

El sistema desarrollado tiene un alto potencial para ser adaptado como una solución comercial en el sector de la movilidad y la tecnología, dirigido a diferentes consumidores:

1. Consumidores individuales:
  - Uso práctico: los conductores pueden utilizar la aplicación para mejorar su estilo de conducción, reducir costos de combustibles y minimizar su impacto ambiental.
  - Modelo de negocio: podría implementarse como una aplicación freemium, con funciones básicas gratuitas y características avanzadas (como análisis detallados e informes personalizados) disponibles mediante una suscripción mensual.
2. Empresas de gestión de flotas:
  - Uso práctico: la herramienta podría integrarse en sistemas de gestión de flotas para monitorizar el desempeño de conductores, reducir costos operativos y optimizar rutas.
  - Modelo de negocio: licencias corporativas o integración personalizada con sistemas existentes, ofreciendo análisis a gran escala.
3. Fabricantes de vehículos:
  - Uso práctico: los fabricantes podrían integrar la solución como parte de sus sistemas telemáticos estándar, mejorando la experiencia del usuario y destacando por su enfoque en sostenibilidad.
  - Modelo de negocio: alianzas estratégicas con marcas para incluir la tecnología como un valor añadido.

### **5.6.2. Aplicación en iniciativas educativas**

El sistema también puede ser un recurso valioso para promover la educación en conducción eficiente y sostenible:

1. Programa de formación para nuevos conductores:
  - Uso práctico: la aplicación podría ser utilizada en autoescuelas como herramienta complementaria para enseñar a los estudiantes a adoptar hábitos de conducción más seguros y responsables.

- Ventaja educativa: permite a los alumnos visualizar en tiempo real cómo sus acciones afectan al consumo de combustible y estilo de conducción, fomentando una comprensión práctica.
2. Campañas de concienciación:
    - Uso práctico: las instituciones educativas y organizaciones ambientales podrían utilizar las herramientas en talleres o eventos para educar a los ciudadanos sobre el impacto de sus hábitos de conducción en el medio ambiente.
    - Impacto: promueve un cambio cultural hacia la sostenibilidad y la reducción de emisiones.

### **5.6.3. Aplicación en políticas gubernamentales**

El sistema puede desempeñar un papel crucial en iniciativas públicas para promover la movilidad sostenible y la seguridad vial:

1. Incentivos para conductores responsables:
  - Uso práctico: los gobiernos podrían ofrecer incentivos, como descuentos en impuestos o seguros, a los conductores que demuestren hábitos de conducción eficiente registrados mediante la aplicación.
  - Impacto: estimula un cambio de comportamiento a gran escala hacia prácticas de conducción más responsables.
2. Estudios sobre tráfico y emisiones:
  - Uso práctico: los datos anónimos recopilados por la aplicación podrían ser utilizados por instituciones gubernamentales para analizar patrones de tráfico y diseñar políticas más efectivas para reducir emisiones.
  - Impacto: mejora la planificación urbana y el diseño de infraestructuras, promoviendo ciudades más limpias y sostenibles.
3. Programas de reducción de emisiones:
  - Uso práctico: integrar la aplicación en campañas de reducción de emisiones como parte de los compromisos internacionales para combatir el cambio climático.
  - Impacto: contribuye directamente a alcanzar metas como las establecidas en el Acuerdo de París.

#### **5.6.4. Impacto potencial en el futuro**

El sistema tiene el potencial de transformar la relación entre los usuarios y sus vehículos. Su flexibilidad y capacidad de adaptación lo convierten en una herramienta versátil, con aplicaciones en educación, industria y políticas públicas. Promueve un cambio cultural hacia la sostenibilidad, mejorando tanto la seguridad vial como el impacto ambiental de la movilidad en el futuro.

# Capítulo 6

## Planificación y presupuesto del proyecto

### 6.1. Introducción

Este capítulo detalla la planificación temporal y el presupuesto estimado para el desarrollo de la aplicación Android destinada a clasificar estilos de conducción mediante OBD-II, sensores móviles y machine learning. Incluye diagramas de Gantt, una descripción de las fases del proyecto, así como un desglose del costo asociado a cada fase.

### 6.2. Planificación temporal

#### 6.2.1. Fases del proyecto

El desarrollo del proyecto se ha dividido en las siguientes fases:

1. Investigación y análisis:
  - Exploración de tecnologías relevantes (OBD-II, APIs, Azure, sensores móviles).
  - Identificación de requisitos funcionales y no funcionales.
  - Duración: 3 semanas.
2. Diseño del sistema:
  - Creación de la arquitectura del sistema.
  - Elaboración de diagramas (flujos de datos, componentes, comunicación entre módulos).
  - Duración: 3 semanas.
3. Implementación del sistema:
  - Desarrollo de la aplicación móvil (Android/Kotlin).
  - Integración con dispositivos OBD-II y sensores móviles.
  - Desarrollo del modelo de machine learning en Azure AI.
  - Duración: 7 semanas

4. Experimentación y obtención de medidas:
  - Recogida de datos durante la conducción de los dos conductores
  - Duración: 1 día
5. Análisis de los datos obtenidos:
  - Comprobación de los datos recogidos
  - Limpieza de datos
  - Validación de los datos
  - Análisis de los datos
  - Duración: 1 semana
6. Pruebas y validación:
  - Pruebas unitarias, de integración y de usabilidad.
  - Validación de los resultados y ajustes necesarios.
  - Duración: 4 semanas.
7. Documentación y presentación:
  - Redacción de la memoria final.
  - Preparación de la presentación del proyecto.
  - Duración: 3 semanas.

## 6.2.2. Diagrama de Gantt

El siguiente diagrama de Gantt representa la distribución temporal de las fases y tareas del proyecto:

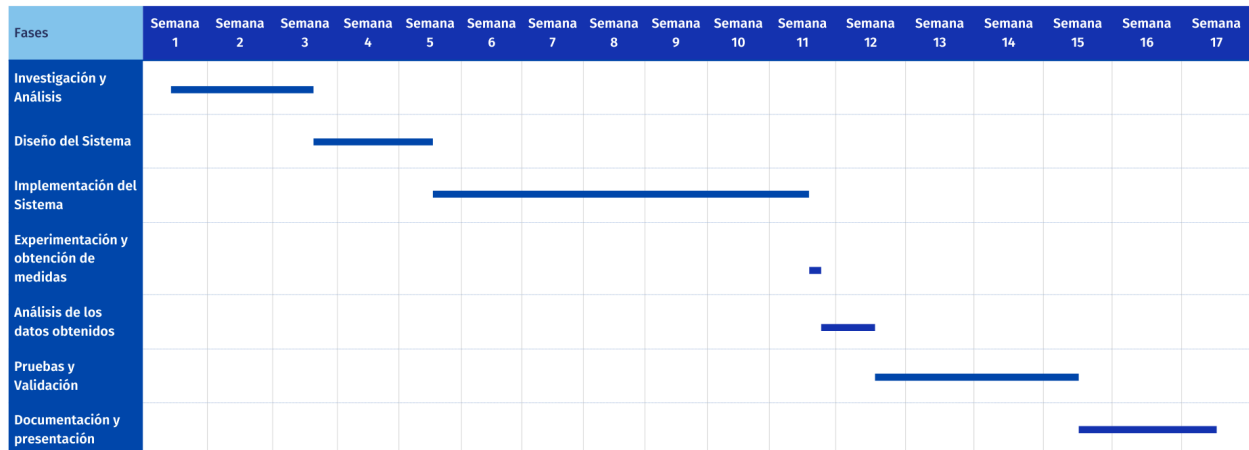


Figura 27. Diagrama de Gantt

## 6.3. Presupuesto estimado

### 6.3.1. Recursos humanos

Dado que el proyecto es individual, el cálculo de costos por tiempo de trabajo se basa en una estimación del tiempo dedicado y en una tarifa simbólica definida de la siguiente manera:

- Tarifa por hora (EUR): se ha fijado en 15,38 €/hora, tomando como referencia el salario medio bruto anual de un ingeniero recién graduado en España, estimado en 24.000 €/año, dividido por una jornada laboral estándar de 1.560 horas al año (40 horas/semana × 39 semanas efectivas).

<b>Actividad</b>	<b>Horas estimadas</b>	<b>Tarifa por hora (EUR)</b>	<b>Costo total (EUR)</b>
<b>Investigación y Análisis</b>	60	15'38€	922'80€
<b>Diseño del Sistema</b>	40	15'38€	615'20€
<b>Implementación del Sistema</b>	120	15'38€	1845'60€
<b>Pruebas y Validación</b>	40	15'38€	615'20€
<b>Documentación y Presentación</b>	30	15'38€	461'40€
<b>Total</b>			4460'20€

### 6.3.2. Recursos tecnológicos

<b>Recurso</b>	<b>Descripción</b>	<b>Costo (EUR)</b>
<b>Dispositivo OBD-II</b>	1 dispositivo	15€
<b>Suscripción Azure AI</b>	100€ de saldo gratuitos	0€
<b>Licencias de Software</b>	Herramientas de desarrollo y prueba	0€
<b>Total</b>		15€


Cabe destacar que, para el uso del sistema en entornos reales y a mayor escala, sería necesario contemplar el coste asociado a la suscripción del servicio en la nube (Azure AI), el cual no se ha incluido en la tabla anterior. Actualmente, el precio de los servicios de Azure Machine Learning varía según el tipo de instancia utilizada, el volumen de procesamiento y almacenamiento. Sin embargo, de forma aproximada, una suscripción para despliegues en producción con uso continuo, el coste puede ascender a 100–200 € mensuales o más, dependiendo del uso intensivo de recursos.

### 6.3.3. Resumen general del presupuesto

Categoría	Costo Total (EUR)
Recursos Humanos	4460'20€
Recursos Tecnológicos	15€
<b>Total General</b>	<b>4475'20€</b>

**Resumen de presupuestos**

- Recursos humanos
- Recursos Tecnológicos



## **6.4. Conclusión**

La planificación y el presupuesto presentados permiten abordar el proyecto de manera estructurada, eficiente y realista. Las fases y tiempos definidos garantizan un desarrollo organizado, mientras que la asignación de recursos humanos y tecnológicos maximiza la eficiencia y asegura la entrega de una solución de calidad con un presupuesto accesible.

# Capítulo 7

## Conclusiones y trabajos futuros

### 7.1. Logros alcanzados

Con este proyecto se ha logrado un sistema funcional, de bajo coste y poco intrusivo, capaz de monitorizar el comportamiento del conductor en tiempo real mediante la conexión a un dispositivo OBD-II y sensores del propio dispositivo móvil. La solución desarrollada permite recopilar, analizar y clasificar datos de conducción con una infraestructura tecnológica accesible, lo que la convierte en una herramienta viable para aplicaciones reales en seguridad vial, educación al conductor o investigación. Además, el sistema proporciona recomendaciones personalizadas para mejorar el estilo de conducción, fomentando una conducción más eficiente que permite reducir el consumo de combustible y las emisiones contaminantes.

El desarrollo de este proyecto ha permitido alcanzar una serie de logros y aprendizajes relevantes en el ámbito de la clasificación del estilo de conducción utilizando tecnologías como OBD-II, sensores móviles y Machine Learning. Entre las conclusiones principales destacan:

1. **Conexión Bluetooth confiable:** la aplicación desarrollada logra conectarse al dispositivo OBD-II en el 90% de los intentos, con un tiempo promedio de conexión de 4-5 segundos. Esto demuestra una solución eficiente para la recopilación de datos en tiempo real desde el vehículo.
2. **Precisión de los datos:** los datos obtenidos del OBD-II, como velocidad y revoluciones por minuto, mostraron alta consistencia al compararlos con los valores del tablero del vehículo. Esto confirma su validez para los análisis realizados.
3. **Comparación de Modelos de Clasificación:** se evaluaron dos modelos de Machine Learning:
  - **Modelo completo:** utiliza todas las variables disponibles y ha demostrado una precisión del 98% en pruebas reales.

- Modelo refinado: utiliza solo un subconjunto de variables, obteniendo una precisión del 99,89% en validación, pero solo un 42,9% en pruebas reales, lo que indica dificultades en la generalización.
4. Discrepancia entre métricas teóricas y rendimiento: aunque el modelo refinado mostró mejores métricas en validación, su desempeño en condiciones reales fue significativamente menor. Esto sugiere que algunas variables eliminadas eran clave para la clasificación, y que el modelo refinado podría estar sobre ajustado a los datos de entrenamiento.
  5. Detección de eventos con sensores: los sensores móviles permitieron identificar frenadas bruscas, aceleraciones y giros repentinos con una precisión aceptable (entre el 85% y el 90%), aportando una capa adicional de contexto al análisis.
  6. Interfaz gráfica intuitiva: los usuarios que evaluaron la aplicación destacaron la claridad y facilidad de uso en la interfaz, lo que refuerza el objetivo de hacer accesible la tecnología a conductores promedio.
  7. Impacto potencial positivo: este sistema tiene el potencial de fomentar una conducción más eficiente, contribuyendo a la reducción del consumo de combustible y las emisiones contaminantes, así como la mejora de la seguridad vial.

Sin embargo, se identificaron algunas limitaciones que deben ser consideradas:

- La detección de giros repentinos presenta menor precisión comparada con otros eventos.
- Algunos datos del OBD-II, como la carga del motor, no pudieron ser validados directamente debido a la falta de medidores en los vehículos utilizados.
- La dependencia de APIs externas para obtener datos como velocidad máxima de la vía puede limitar la funcionalidad en ciertas situaciones.

## 7.2. Valoración de las tecnologías utilizadas

1. Tecnología OBD-II: ha demostrado ser confiable y esencial para obtener datos precisos del vehículo, aunque requiere más personalización para diferentes modelos de automóviles.
2. Sensores móviles: proveen un complemento valioso al OBD-II, enriqueciendo los análisis con datos sobre maniobras del conductor.
3. Kotlin y Android: la elección de Kotlin como lenguaje y Android como plataforma permitió un desarrollo fluido y una interfaz moderna, adaptada a las necesidades de los usuarios.

4. Machine Learning y Azure: la implementación del modelo de clasificación en Azure fue eficiente, destacándose por su escalabilidad, potencia de cómputo y facilidad de despliegue. Sin embargo, el coste asociado al uso de servicios en la nube como Azure puede suponer un handicap importante para la explotación del sistema, especialmente por parte de usuarios particulares o proyectos con recursos limitados. Una posible solución a este inconveniente sería desplegar el modelo de IA en un servidor personal o dispositivo local, lo cual eliminaría costes recurrentes y permitiría un mayor control sobre la infraestructura.
5. APIs externas: aunque son útiles para obtener información contextual adicional, su dependencia puede representar un reto en entornos con conectividad limitada o poca cobertura. En las primeras fases del proyecto se utilizó OpenStreetMap para obtener la velocidad máxima permitida en las vías, pero se detectaron problemas de precisión y cobertura en algunos tramos urbanos y carreteras secundarias. Por esta razón, se optó por integrar la API de Here Maps, que ofrece una cobertura más completa, datos más actualizados y una mejor precisión en la información del límite de velocidad.

### **7.3. Trabajos futuros**

Este proyecto abre una serie de líneas de investigación y mejoras potenciales:

1. Ampliación de pruebas: realizar pruebas con una mayor variedad de vehículos y dispositivos OBD-II para validar la generalización del sistema.
2. Optimizar detección de eventos: mejorar los algoritmos para incrementar la precisión en la detección de giros repentinos y otros eventos.
3. Compatibilidad ampliada: extender la funcionalidad a vehículos eléctricos e híbridos, explorando métricas específicas para estos modelos..
4. Integración de más datos: explorar el uso de otros sensores y APIs, como información meteorológica o datos de tráfico en tiempo real.
5. Mayor personalización: incorporar ajustes que permitan adaptar las recomendaciones al perfil de conductor y las condiciones específicas de conducción.
6. Análisis avanzado: desarrollar modelos más sofisticados de machine learning que consideren factores adicionales, como el desgaste del vehículo y el impacto económico.
7. Automatización de recomendaciones: crear un sistema que no solo proporcione sugerencias, sino también herramientas para que el usuario pueda aplicar cambios automáticamente en sus hábitos de conducción.

8. Despliegue comercial: considerar la posibilidad de transformar la aplicación en un producto comercial, con mejoras en la interfaz, monetización y soporte a largo plazo.

En resumen, este trabajo establece una base sólida para el desarrollo de sistemas avanzados que promuevan la conducción eficiente y sostenible, ofreciendo un impacto positivo en la movilidad, el medio ambiente y la seguridad vial.

# Bibliografía

[1] International Energy Agency, “Transport Energy Efficiency,” [Online].

Available: <https://www.iea.org/reports/transport-energy-efficiency>.

[Accessed: 30-Apr-2025].

[2] Soziable.es, “Para lograr sistemas de transporte sostenibles es esencial reducir las emisiones,” [Online].

Available: <https://www.soziable.es/entrevistas/para-lograr-sistemas-de-transporte-sostenibles-es-esencial-reducir-las-emisiones-de>.

[Accessed: 30-Apr-2025].

[3] Geotab, “¿Qué es el OBD-II y cómo funciona?,” [Online].

Available: <https://www.geotab.com/es/blog/obd-ii/>.

[Accessed: 30-Apr-2025].

[4] Clipset, “Torque Pro: tu coche monitorizado desde Android,” [Online].

Available: <https://clipset.com/torque-pro-tu-coche-monitorizado-desde-android/>.

[Accessed: 30-Apr-2025].

[5] Microsoft, “Azure Machine Learning documentation,” [Online].

Available: <https://learn.microsoft.com/en-us/azure/machine-learning/>.

[Accessed: 30-Apr-2025].

[6] Scikit-learn, “Voting Classifier,” [Online].

Available: <https://scikit-learn.org/stable/modules/ensemble.html#voting-ensemble>.

[Accessed: 30-Apr-2025].

[7] Coches.com, “Qué es la normativa Euro 6e y qué implicaciones tiene,” [Online].

Available: <https://noticias coches.com/consejos/euro-6e/471643>.

[Accessed: 30-Apr-2025].

[8] Palmer Performance Engineering, “DashCommand – OBD-II App,” [Online].

Available:

<https://play.google.com/store/apps/details?id=com.palmerperformance.DashCommand>.

[Accessed: 30-Apr-2025].

[9] La Vanguardia / Andro4all, “Xiaomi Carrobot HUD: así es la pantalla para coches de Xiaomi,” [Online].

Available:

<https://www.lavanguardia.com/andro4all/android/xiaomi-carrobot-hud-pantalla-coche>.

[Accessed: 30-Apr-2025].

[10] Construible.es, “La recuperación económica aumenta un 10% las emisiones de CO<sub>2</sub> en España,” [Online].

Available:

<https://www.construible.es/2016/06/21/la-recuperacion-economica-aumenta-un-10-las-emisiones-co2-en-espana>.

[Accessed: 30-Apr-2025].

[11] Parlamento Europeo, “Economía circular: definición, importancia y beneficios,” [Online].

Available:

<https://www.europarl.europa.eu/topics/es/article/20151201STO05603/economia-circular-definicion-importancia-y-beneficios>.

[Accessed: 30-Apr-2025].

[12] Sostenibilidad.com, “Vehículos eléctricos sí, pero con energía renovable,” [Online]. Available: <https://www.sostenibilidad.com/energias-renovables/vehiculos-electricos/>.

[Accessed: 30-Apr-2025].

[13] Petropunto, “El impacto del estilo de conducción en el consumo de combustible,” [Online].

Available:

<https://petropunto.com/el-impacto-del-estilo-de-conduccion-en-el-consumo-de-combustible/>.

[Accessed: 30-Apr-2025].

[14] Geotab, “Ocho consejos de conducción ecológica para ahorrar combustible en tu flota,” [Online].

Available:

<https://www.geotab.com/es-latam/blog/ocho-consejos-conduccion-ecologica-ahorrar-combustible-flota/>.

[Accessed: 30-Apr-2025].

[15] Android Developers, “Kotlin y Android,” [Online].

Available: <https://developer.android.com/kotlin?hl=es-419>.

[Accessed: 30-Apr-2025].

[16] E. Vasconcelos, “kotlin-obd-api: A lightweight and developer-driven API to query and parse OBD commands,” GitHub, [Online].

Available: <https://github.com/eltonvs/kotlin-obd-api>.

[Accessed: 30-Apr-2025].

[17] HERE Technologies, “Finding speed limit of given waypoints using HERE Location Services,” [Online].

Available: <https://www.here.com/learn/blog/finding-speed-limit-hls>.

[Accessed: 30-Apr-2025].