



Facultad de Ciencias Económicas y Empresariales

# **Implementación de un sistema de alerta para la prevención de accidentes automovilísticos por medio de detección de cansancio en conductores**

Autor: 201808120

Director: José María Benito Peñalba

MADRID | 2022-2023



# Resumen

Este estudio se centra en el desarrollo de un sistema de detección de fatiga en conductores utilizando técnicas avanzadas de visión artificial y Deep Learning. El objetivo es contribuir a la seguridad vial al proporcionar una herramienta eficiente y precisa para detectar la somnolencia en tiempo real y alertar a los conductores antes de que ocurra un accidente. Para lograr esto, se ha diseñado un modelo de Deep Learning que clasifica los niveles de somnolencia en cuatro categorías. Para el entrenamiento y evaluación del modelo, se ha construido una base de datos propia, grabando a un conductor bajo distintos niveles de cansancio. Este enfoque garantiza la diversidad y calidad de las imágenes utilizadas, resultando en un modelo más robusto y confiable. El preprocesamiento de los datos ha sido una parte esencial del trabajo, incluyendo la extracción de imágenes de los vídeos, el ajuste de la iluminación, la extracción de características faciales, el muestreo de las imágenes, el recorte de la imagen para ajustarse a la cara detectada y la normalización. Estos pasos han sido fundamentales para mejorar la eficacia del modelo y su capacidad para detectar la fatiga con precisión. El modelo ha demostrado un rendimiento prometedor, con una exactitud del 91,22 %, aunque se han identificado áreas de mejora. Además, se han explorado distintos modelos de negocio para la comercialización de este sistema, incluyendo una aplicación móvil independiente, la integración directa con los vehículos y la colaboración con empresas aseguradoras. En resumen, este trabajo presenta un sistema innovador de detección de fatiga, demostrando su potencial para mejorar la seguridad vial y prevenir accidentes relacionados con la fatiga del conductor.

# Abstract

This study focuses on the development of a driver drowsiness detection system using advanced computer vision and Deep Learning techniques. The objective is to contribute to road safety by providing an efficient and accurate tool to detect drowsiness in real time and alert drivers before an accident occurs. To achieve this, a Deep Learning model has been designed that classifies drowsiness levels into four categories. For training and evaluation of the model, a proprietary database has been built by recording a driver under different levels of tiredness. This approach ensures the diversity and quality of the images used, resulting in a more robust and reliable model. Data preprocessing has been an essential part of the work, including extracting images from the videos, adjusting the illumination, extracting facial features, sampling the images, cropping the image to fit the detected face, and normalization. These steps have been instrumental in improving the efficiency of the model and its ability to accurately detect fatigue. The model has shown promising performance, with an accuracy of 91.22 %, although areas for improvement have been identified. In addition, different business models for the commercialization of this system have been explored, including a standalone mobile application, direct integration with vehicles, and collaboration with insurance companies. In summary, this work presents an innovative fatigue detection system, demonstrating its potential to improve road safety and prevent accidents related to driver fatigue.

# Agradecimientos

En primer lugar, quiero agradecer a mi familia por su constante apoyo, paciencia y motivación.

También quiero agradecer a mi director del trabajo, José María, por su guía experta, su dedicación y su invaluable orientación a lo largo de esta investigación.

Agradezco de corazón a mis amigos por su apoyo incondicional a lo largo de estos 5 años, siempre animándome a dar lo mejor de mí.

# Índice de la memoria

<b>1. Introducción</b>	<b>1</b>
1.1. Motivación . . . . .	1
1.2. Objetivos . . . . .	3
1.3. Metodología . . . . .	4
<b>2. Estado del Arte</b>	<b>6</b>
<b>3. Sistema Desarrollado para la Detección de Somnolencia</b>	<b>10</b>
3.1. Recopilación y exploración de los datos . . . . .	10
3.2. Preprocesado de datos . . . . .	14
3.3. Modelo de computer vision para la detección de somnolencia . . . . .	18
3.4. Sistema de alerta al conductor . . . . .	24
<b>4. Análisis de Resultados</b>	<b>26</b>
<b>5. Modelo de Negocio: Estrategias de Comercialización para el Sistema de Detección de Cansancio</b>	<b>32</b>
5.1. Suscripción a aplicación móvil . . . . .	33
5.2. Software integrado en el vehículo . . . . .	34
5.3. Colaboración con compañías aseguradoras . . . . .	36
5.4. Conclusiones del capítulo . . . . .	37
<b>6. Conclusiones y Trabajos Futuros</b>	<b>39</b>
<b>Apéndices</b>	<b>42</b>
<b>A. Repositorio de Código</b>	<b>42</b>
A.1. Introducción al repositorio . . . . .	42
A.2. Estructura del repositorio . . . . .	42
<b>Bibliografía</b>	<b>45</b>

# Índice de figuras

1.1. Distribución de factores concurrentes en los siniestros viales y siniestros mortales ocurridos en vías interurbanas. Año 2021. (Cataluña y País Vasco excluidos) . . . . .	2
3.1. Diagrama del desarrollo del proyecto . . . . .	11
3.2. Puntos de referencia del rostro de Mediapipe . . . . .	12
3.3. Ejemplo de conductor con la detección de puntos de referencia faciales utilizando Mediapipe . . . . .	13
3.4. Ejemplo de conductor con la detección de puntos de referencia faciales utilizando Dlib . . . . .	14
3.5. Esquema de los pasos del preprocesado de datos para la detección de somnolencia . . . . .	15
3.6. Comparación entre una imagen sin transformación y una con transformación	16
3.7. Fórmula del Eye Aspect Ratio (EAR) . . . . .	16
3.8. Convolución de una imagen . . . . .	19
3.9. Esquema del modelo para la detección de somnolencia . . . . .	20
3.10. Arquitectura del modelo VGG16 . . . . .	23
3.11. Aprendizaje del modelo: evolución de la pérdida y el accuracy . . . . .	23
4.1. Métricas de clasificación . . . . .	28
4.2. Matriz de confusión . . . . .	29
4.3. Curvas ROC . . . . .	30

# Índice de tablas

3.1. Equivalencia entre el KSS y las clases del proyecto . . . . .	11
3.2. Promedio de características según la clase de somnolencia . . . . .	17

# Acrónimos

<i>DL</i>	Deep Learning
<i>CNN</i>	Convolutional Neural Networks (Redes Neuronales Convolucionales)
<i>DGT</i>	Dirección General de Tráfico
<i>DDD</i>	Driver Drowsiness Detection (Detección de Cansancio en Conductores)
<i>EAR</i>	Eye Aspect Ratio (Relación de Aspecto del Ojo)
<i>MAR</i>	Mouth Aspect Ratio (Relación de Aspecto de la Boca)
<i>KSS</i>	Karolinska Sleepiness Scale
<i>FPS</i>	Fotogramas Por Segundo
<i>AUC</i>	Area Under the Curve (Área Debajo de la Curva)



# Capítulo 1

## Introducción

Este proyecto se enfoca en el diseño de un sistema innovador que detecte la somnolencia en los conductores con el objetivo de reducir los accidentes automovilísticos. Para lograrlo, se emplearán técnicas de Deep Learning (DL), específicamente redes neuronales convolucionales (CNN), para desarrollar un modelo de visión artificial (Computer Vision) capaz de identificar el nivel de cansancio de un conductor a partir de imágenes.

Esta solución se presenta como una valiosa herramienta para diversas empresas, así como una tecnología de gran interés para los ciudadanos y la sociedad en general, ya que contribuye a incrementar la seguridad vial. El cansancio es uno de los factores más relevantes entre las causas de accidentes, por lo tanto, es de vital importancia profundizar en este campo de investigación para prevenir estos sucesos y promover la seguridad en las carreteras.

A lo largo de este trabajo, se evaluarán diversos métodos para la detección del cansancio, identificando los retos existentes, y se realizará una exploración de posibles modelos de negocio. Como resultado final, se espera obtener un sistema funcional y confiable que sea capaz de detectar diferentes niveles de cansancio en los conductores. Además, se analizarán múltiples estrategias de comercialización para esta herramienta, siempre con un enfoque en mejorar la seguridad vial y proporcionar un sistema que aporte valor a la sociedad y reduzca los accidentes.

### 1.1. Motivación

La somnolencia al volante es un problema grave de seguridad vial que causa numerosos accidentes de tráfico al año en todo el mundo. Según la Dirección General de Tráfico (DGT)

de España, entre el 20 % y el 30 % de los accidentes de tráfico están relacionados con la somnolencia del conductor, incluso cuando ésta no es la causa principal (DGT, 2022b). Es decir, que con la implementación del sistema de detección de somnolencia desarrollado se podrían evitar entorno a 5000 accidentes viales al año en España. Además, en 2021 la somnolencia fue directamente responsable del 9% de los accidentes mortales en España (Ver Figura 1.1), lo que la convierte en la cuarta mayor causa de accidentes mortales (DGT, 2022a). La detección temprana de la fatiga del conductor es fundamental para prevenir accidentes de tráfico, por lo que es importante el desarrollo de sistemas de detección de fatiga en tiempo real. En este sentido, la visión artificial se presenta como una herramienta clave para el desarrollo de dichos sistemas.

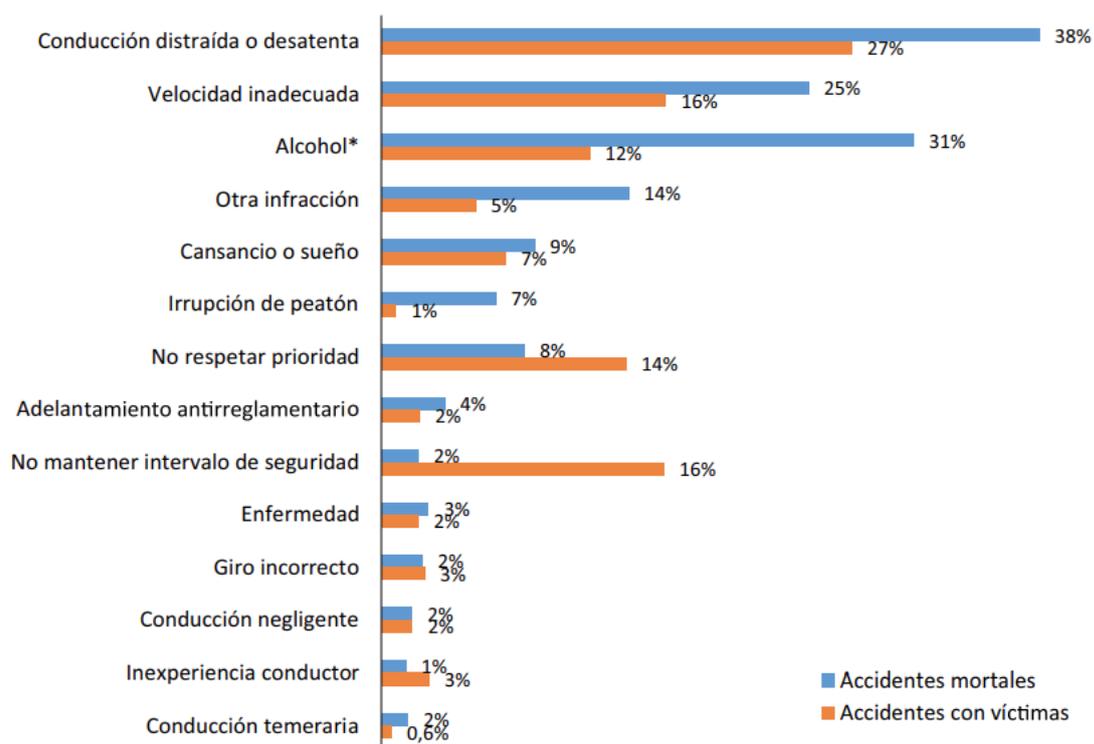


Figura 1.1: Distribución de factores concurrentes en los siniestros viales y siniestros mortales ocurridos en vías interurbanas. Año 2021. (Cataluña y País Vasco excluidos)

Fuente de Datos: (DGT, 2022a)

La visión artificial (computer vision) es un campo de la inteligencia artificial que se centra en el procesamiento de imágenes y vídeos para extraer información útil y tomar decisiones. En el desarrollo de sistemas de detección de fatiga, la visión artificial se presenta como una tecnología valiosa ya que permite analizar patrones visuales para detectar signos faciales de cansancio del conductor.

En la actualidad, la seguridad en el ámbito automovilístico es una prioridad para muchos países, y en este sentido tanto la Unión Europea como Estados Unidos están estableciendo nuevas regulaciones que obligarán a los vehículos a incorporar sistemas de detección y alerta

de cansancio. En la Unión Europea, se aprobó una ley en 2019 que establece que a partir de julio de 2022, todos los vehículos que aún no hayan sido aprobados para la venta en la Unión Europea deben tener instalados sistemas de detección de fatiga. Además, se ha dado un plazo hasta julio de 2024 para que los fabricantes garanticen que los vehículos que ya han sido aprobados para la venta pero aún no se han registrado, también estén equipados con estos sistemas (EU, 2021). Esta nueva regulación refleja la creciente conciencia sobre el impacto significativo que la somnolencia tiene en la conducción, así como la importancia de desarrollar sistemas de detección de fatiga que sean confiables y operen en tiempo real para minimizar los accidentes relacionados con la fatiga del conductor en las carreteras.

Es de vital importancia que los sistemas de detección de somnolencia en conductores sean altamente confiables y actúen en tiempo real para alertar al conductor antes de que ocurra algún accidente debido al cansancio. En este proyecto, se abordará este desafío mediante el uso de técnicas de visión artificial, específicamente utilizando datos de imágenes del conductor en distintos niveles de cansancio. La elección de utilizar la visión artificial como solución se justifica por sus fortalezas y el potencial que ofrece en este contexto. En el siguiente capítulo, se llevará a cabo un análisis exhaustivo de las distintas tecnologías implantadas a día de hoy y las múltiples ramas de investigación existentes, con el objetivo de respaldar la elección de la visión artificial y resaltar las ventajas que proporciona en la detección de somnolencia en conductores.

En resumen, la motivación de este trabajo se basa en la necesidad de abordar un problema grave de seguridad vial como es la somnolencia de los conductores, y la relevancia de desarrollar herramientas que permitan prevenir los accidentes de tráfico relacionados con este problema de manera automática. Mediante el uso de tecnologías de visión artificial, se pretende desarrollar un sistema capaz de detectar signos de fatiga en tiempo real, lo que contribuirá a reducir la tasa de accidentes de tráfico relacionados con la somnolencia.

## 1.2. Objetivos

El objetivo principal de este proyecto consiste en desarrollar un sistema de detección de fatiga en conductores con el fin de mejorar la seguridad vial y prevenir accidentes de tráfico relacionados con la somnolencia. Para ello, se analizarán imágenes en tiempo real mediante un modelo de visión artificial diseñado específicamente para detectar signos de cansancio. Para alcanzar este objetivo, se detallan los siguientes objetivos específicos:

- **Diseño de modelo de detección de fatiga:** Diseñar y desarrollar un modelo de visión artificial capaz de detectar señales de fatiga en conductores a partir del análisis de

imágenes de vídeo capturadas por una cámara situada en el vehículo.

- **Evaluación de los modelos diseñados:** Evaluar la efectividad de los modelos desarrollados en la detección de fatiga.
- **Exploración del modelo de negocio:** Investigar y analizar las posibilidades de implementar el sistema de detección de fatiga en el mercado actual, identificando posibles modelos de negocio y estrategias de comercialización.

Con este enfoque, se espera proporcionar una solución que contribuya a reducir los riesgos asociados al cansancio al volante y promueva una conducción más segura.

### 1.3. Metodología

Para el desarrollo de este proyecto, se ha seguido la siguiente metodología. En primer lugar, se contextualiza la importancia de la detección de la somnolencia en la conducción a través de una revisión de la literatura existente sobre el tema. Se han examinado las investigaciones previas relacionadas con el uso de cámaras para detectar la somnolencia en conductores y se ha realizado un análisis de los modelos de aprendizaje automático más utilizados para procesar y clasificar imágenes.

A continuación, se procedió a la recopilación de datos para la creación de una base de datos propia de imágenes de conductores con distintos niveles de cansancio. Esto se llevó a cabo mediante la grabación de vídeos mientras se conduce en diferentes momentos del día, y se etiquetaron las imágenes según el nivel de somnolencia. Una vez obtenida la base de datos, se procedió al procesamiento de las imágenes para facilitar la extracción de características. A continuación, se entrenaron diferentes modelos de aprendizaje automático utilizando los conjuntos de datos y se evaluaron mediante la medición de su precisión en la detección de la somnolencia en nuevas imágenes. Por último, se ha desarrollado un modelo de negocio para el sistema de detección de somnolencia. Se han analizado las diferentes oportunidades de mercado y se propone una estrategia de comercialización para el sistema desarrollado.

En resumen, la metodología propuesta consta de cuatro etapas: revisión de la literatura, recopilación de datos, entrenamiento de modelos de aprendizaje automático y desarrollo de un modelo de negocio.

En la implementación de este proyecto, existen varios retos a considerar. Uno de ellos es la calidad y cantidad de los datos necesarios para entrenar los modelos de aprendizaje automático. Es importante contar con una base de datos lo suficientemente grande y representativa

de conductores con distintos niveles de somnolencia, y que los datos estén etiquetados de manera precisa. Otro reto es la variabilidad en las condiciones de conducción, ya que la detección de la somnolencia puede verse afectada por factores como la iluminación, el tipo de carretera o el clima. Además, es necesario encontrar indicadores tempranos de somnolencia en los conductores, lo que podría requerir el uso de sensores adicionales como en los sistemas biológicos, que son capaces de prever la fatiga, y por lo tanto un sistema híbrido podría ser más robusto. Por último, para que el sistema de detección de somnolencia sea efectivo, es necesario evaluar su integración con el software y hardware existentes en los vehículos.

A pesar de estos retos, la idea de un sistema de detección de somnolencia en conductores es una solución necesaria y demandada por el mercado, ya que los accidentes de tráfico relacionados con la fatiga y la somnolencia son una problemática importante que puede prevenirse con la implementación de este tipo de sistemas. La dedicación a esta iniciativa es un esfuerzo que se justifica plenamente.

# Capítulo 2

## Estado del Arte

En este capítulo, se llevará a cabo una revisión de la literatura sobre las tecnologías existentes en el ámbito de los sistemas de detección de cansancio en conductores (Driver Drowsiness Detection, DDD). La importancia de abordar esta problemática para prevenir accidentes ha llevado a explorar diversos métodos para detectar la somnolencia y alertar al conductor antes de que ocurra un incidente. En sus inicios, los sistemas de detección de cansancio en conductores eran muy básicos y se centraban principalmente en variables simples de conducción, como la detección de desviaciones del vehículo fuera del carril. Sin embargo, con el aumento del poder computacional y el acceso al Deep Learning, los métodos han evolucionado para diseñar modelos más robustos, capaces de generalizar y lograr una detección confiable de la somnolencia del conductor en tiempo real. No obstante, estos nuevos métodos también presentan desventajas y limitaciones, y plantean preocupaciones en términos de privacidad y confidencialidad de los datos. A continuación, se destacan los avances tecnológicos más relevantes en este campo para justificar los métodos utilizados en este proyecto y resaltar su valor.

Volvo fue el primer fabricante en lanzar al mercado un sistema de detección de somnolencia en el año 2007 (Volvo Car Corporation, 2007). Su solución fue desarrollar dos herramientas para alertar a conductores cansados o distraídos. La primera fue el Control de Alerta de Conductor (Driver Alert Control, DAC), un sistema innovador que registraba el progreso del automóvil en la carretera y alertaba a los conductores que estaban perdiendo la concentración. Se activaba a velocidades superiores a 60 km/h, utilizando una cámara, sensores y una unidad de control para monitorear la distancia entre el vehículo y las marcas de la carretera. Si se detectaba un alto riesgo de perder el control del vehículo, se emitía una señal de audio y aparecía un mensaje en la pantalla del automóvil con un símbolo de taza de café, indicando al conductor que tomara un descanso. La segunda herramienta desarrollada

fue la Alerta de Salida de Carril (Lane Departure Warning, LDW). Este sistema era relativamente simple y se basaba en medir si el vehículo se salía del carril, produciendo una alerta sonora si detectaba un comportamiento no intencional. Aunque la combinación de estas dos herramientas representó un avance innovador para la seguridad vial, se veían afectadas por condiciones climáticas adversas y la visibilidad de las marcas de la carretera. Desde entonces, los avances tecnológicos han permitido el desarrollo de sistemas más sofisticados y precisos para la detección de la fatiga y la somnolencia del conductor en la carretera.

El trabajo de Albadawi, Takruri, y Awad (2022) hace una revisión de los últimos avances en los sistemas de detección de somnolencia del conductor, con el objetivo de identificar los métodos y tecnologías más efectivos para prevenir accidentes. Hay cuatro categorías principales de sistemas de detección de fatiga: basados en imágenes, en el vehículo, biológicos e híbridos.

Los basados en imágenes utilizan cámaras para medir el comportamiento del conductor según sus expresiones faciales o movimientos de cabeza. Existen numerosos estudios que abordan el problema de detección de fatiga utilizando este método. Cada uno se enfoca en diferentes medidas visuales del conductor, algunos se centran en el movimiento de los ojos, la apertura de la boca o la posición de la cabeza para detectar señales de somnolencia. Estos sistemas muestran resultados muy prometedores con una alta precisión sin ser demasiado invasivos, ya que solo requieren la instalación de una cámara en el vehículo. Sin embargo, presentan la desventaja de que, al depender de la expresión facial, su rendimiento se ve afectado por obstáculos como el uso de gafas de sol o la baja iluminación.

Por otro lado, los sistemas basados en el vehículo consisten en sensores incorporados en el vehículo que son capaces de detectar fatiga si los patrones de conducción difieren de los patrones típicos de ese conductor. La medida más común utilizada en estos sistemas es el ángulo de giro del volante (Steering Wheel Angle, SWA) que se obtiene a través de sensores conectados al volante. Estos sensores registran los movimientos del volante y permiten identificar cambios en la forma en que se está conduciendo el vehículo. Además, otra característica utilizada en estos sistemas es la salida de carril que detectan si el vehículo se está desviando de manera involuntaria del carril en el que se encuentra. Estos sistemas basados en el vehículo ofrecen una forma adicional de detectar la fatiga del conductor al analizar directamente los patrones de conducción. No obstante, se suelen utilizar en combinación con otras técnicas ya que resulta complicado encontrar indicadores específicos en los patrones de conducción que sean altamente confiables para determinar de manera precisa el estado de somnolencia del conductor, a diferencia de los sistemas basados en imágenes que capturan señales más directas (Pratama, Ardiyanto, y Adji, 2017).

Los sistemas biológicos monitorizan principalmente las señales del cerebro a través de

diferentes sensores capaces de medir estas variables fisiológicas, siendo el electroencefalograma (EEG) el más comúnmente utilizado. Estos sistemas tienen la ventaja de detectar la somnolencia con mayor antelación, lo que permite tomar medidas preventivas antes de que aparezcan signos físicos evidentes de somnolencia. Sin embargo, su aplicación puede ser más complicada y costosa debido a la necesidad de sensores y dispositivos adicionales, así como a la configuración que el conductor debe realizar. Además, la monitorización de señales de actividad cerebral puede considerarse invasiva. El uso de relojes inteligentes facilita la implementación de estos sistemas, pero todavía existen desafíos en términos de aceptación y comodidad por parte de los conductores.

En los últimos años, se están explorando nuevas opciones para detectar la somnolencia de manera sencilla mediante sistemas biológicos. Se ha diseñado un volante inteligente (Babusiak, Hajducik, Medvecky, Lukac, y Klarak, 2021) capaz de medir variables biológicas, como el nivel de oxígeno en sangre o la actividad eléctrica del corazón, a través del tacto de la mano al agarrarlo. Además, también registra los movimientos del volante para evaluar el comportamiento del conductor, por lo que se combina con un sistema basado en el vehículo. Estos datos pueden ser utilizados para detectar signos de fatiga o somnolencia y tomar medidas preventivas para garantizar la seguridad en la conducción. No obstante, es importante mencionar que estos avances aún están en proceso de investigación y desarrollo.

En cuanto a los modelos híbridos, son aquellos que combinan al menos dos de las técnicas mencionadas anteriormente, con el objetivo de obtener un modelo más robusto y fiable para la detección de fatiga. Estos sistemas aprovechan las fortalezas de cada enfoque, lo que los convierte en una opción ideal para abordar los desafíos de la detección de fatiga en los conductores. Al combinar diferentes modalidades de detección, como el análisis de patrones de conducción, el monitoreo de señales fisiológicas y el procesamiento de imágenes, los modelos híbridos pueden capturar una variedad más amplia de indicadores de fatiga. Sin embargo, su implementación requiere un mayor poder computacional y capacidad de procesamiento, lo que puede aumentar los requisitos técnicos y los costos asociados.

A medida que se exploran y desarrollan diferentes enfoques de detección de fatiga, es fundamental tener en cuenta la seguridad y privacidad de los datos, especialmente cuando se utilizan imágenes de los conductores. En este sentido, se han realizado estudios que se centran en desarrollar métodos y protocolos que garanticen la protección de la información personal. El estudio de Zhang, Saito, Yang, y Wu (2022) propone un protocolo de preservación de la privacidad para la detección de somnolencia en conductores utilizando técnicas de criptografía para proteger los datos personales mientras se mejora la precisión del sistema al re-entrenar los modelos con datos nuevos. Estos esfuerzos reflejan la importancia de abordar la seguridad y privacidad de los datos en la implementación de sistemas de detección de

somnolencia, considerando las regulaciones existentes en cuanto a la protección de datos.

Tras el análisis exhaustivo de la literatura, se ha llegado a la conclusión de que los sistemas basados en imágenes parecen ser los más prometedores en la detección de fatiga. Estos sistemas destacan por ser menos invasivos en comparación con los enfoques biológicos, al mismo tiempo que superan en precisión a los sistemas basados en el vehículo. Además, son más económicos al solo necesitar instalar una cámara. Gracias a su capacidad para lograr altos niveles de precisión y su capacidad para funcionar sin requerir configuraciones especiales por parte del conductor, los sistemas basados en imágenes son altamente accesibles y de fácil implementación en la práctica. En este trabajo, se pretende seguir el enfoque de detección basado en imágenes, extrayendo diversas métricas relevantes, como el EAR (Eye Aspect Ratio) y el MAR (Mouth Aspect Ratio), entre otras. Además, se plantea no solo abordar el aspecto técnico, sino también explorar posibles modelos de negocio en este campo de estudio. Este trabajo se propone como una contribución adicional al conocimiento existente, mediante experimentos y análisis que ayuden a avanzar en la detección de fatiga en conductores y a brindar nuevas perspectivas tanto técnicas como comerciales.

## Capítulo 3

# Sistema Desarrollado para la Detección de Somnolencia

A lo largo de este capítulo, se presenta en detalle el sistema para la detección de somnolencia desarrollado en este trabajo. La Figura 3.1 ilustra el esquema del proceso seguido. En primer lugar, se recopilaron datos mediante la grabación de una persona conduciendo en diferentes niveles de cansancio. Posteriormente, se llevó a cabo el preprocesamiento de los vídeos para extraer tres conjuntos de datos procesados: entrenamiento, validación y prueba. Estos conjuntos consisten en imágenes y características extraídas. Una vez que los datos fueron procesados, se procedió al diseño de varios modelos de detección de cansancio, los cuales fueron evaluados utilizando los datos de validación y ajustados para obtener un modelo óptimo. Finalmente, se evaluó el modelo utilizando los datos de prueba y se realizó un análisis exhaustivo de los resultados. Las secciones siguientes abordarán en detalle cada uno de estos pasos, mientras que en el próximo capítulo se realizará una evaluación del rendimiento y la capacidad del sistema para detectar distintos niveles de somnolencia a partir de las imágenes de un conductor.

### 3.1. Recopilación y exploración de los datos

En el desarrollo de este proyecto, se optó por crear una base de datos propia mediante la grabación de un conductor en diferentes niveles de cansancio. Con el objetivo de cumplir con las regulaciones de la Unión Europea, las cuales establecen la necesidad de utilizar la Escala de Somnolencia Karolinska (Karolinska Sleepiness Scale, KSS) o un método equivalente (InterRegs, 2021), se implementó un sistema de clasificación que se asemeja a los niveles del

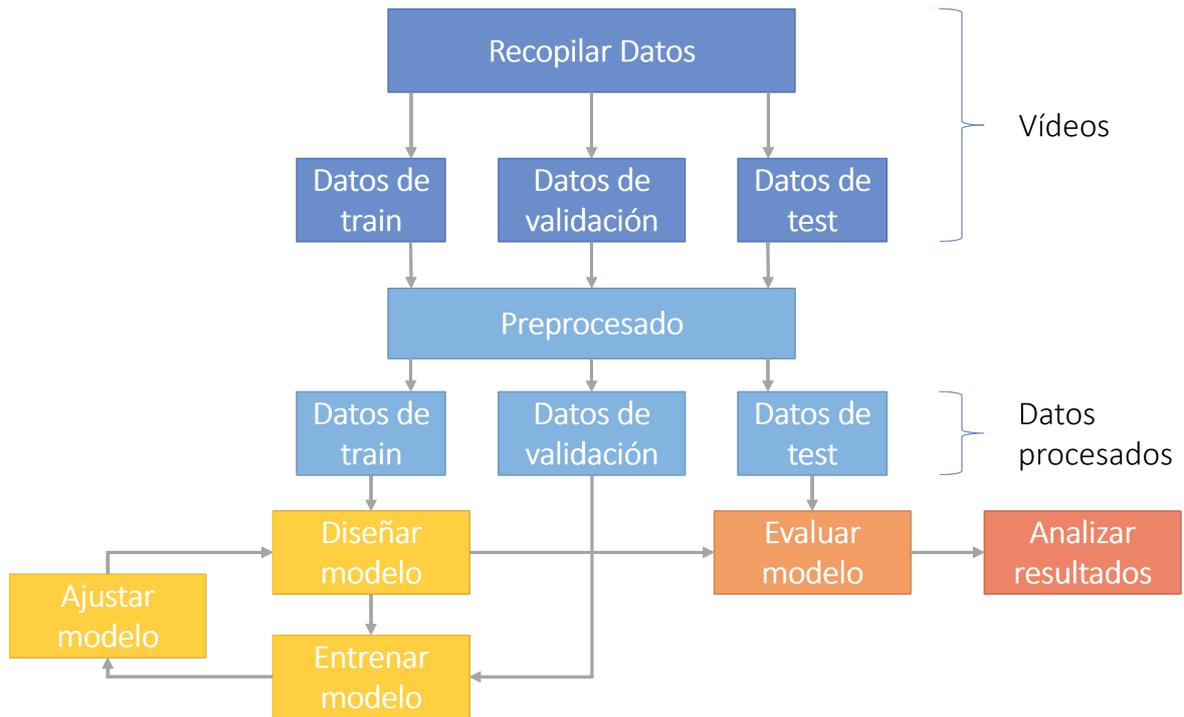


Figura 3.1: Diagrama del desarrollo del proyecto

KSS. Los niveles de cansancio utilizados en este proyecto son: alerta, ligeramente somnoliento, moderadamente somnoliento y muy somnoliento. Para proporcionar una correspondencia entre los niveles del KSS y las clases utilizadas en este proyecto, se presenta en la Tabla 3.1 una comparativa de los nueve niveles del KSS y sus respectivas clases.

KSS		Clase
1	Extremadamente alerta	Alerta
2	Muy alerta	
3	Alerta	
4	Bastante alerta	Ligeramente cansado
5	Ni alerta ni somnoliento	
6	Algunos signos de somnolencia	Moderadamente cansado
7	Somnoliento, sin esfuerzo por mantenerse despierto	
8	Somnoliento, con algo de esfuerzo por mantenerse despierto	
9	Muy somnoliento, gran esfuerzo por mantenerse despierto, luchando contra el sueño	Muy cansado

Tabla 3.1: Equivalencia entre el KSS y las clases del proyecto

Fuente de Datos: (Moessinger, Stürmer, y Mühlensiep, 2021)

Por lo tanto, se cuenta con una colección de varios vídeos del conductor correspondientes a cada una de las clases. Estos vídeos se capturaron en diversas condiciones para simular situaciones de la vida real, como momentos de baja iluminación o el uso de gafas por parte del conductor, lo cual puede dificultar la visibilidad de su rostro. De esta manera, se busca desarrollar un modelo más robusto capaz de detectar la somnolencia en diferentes entornos. En la siguiente sección, se detallará el proceso de preprocesado aplicado a los datos. Esto incluye ajustes de iluminación para garantizar que las imágenes sean adecuadas para la detección de cansancio, incluso en situaciones de conducción nocturna. Además, se explicará cómo se extrajeron ciertas características faciales para utilizarlas como datos de entrada en el modelo. Estas características adicionales ayudan a identificar señales de cansancio. Para llevar a cabo esta tarea, se empleó una biblioteca de Python llamada Mediapipe, que ofrece funciones específicas para la detección facial.

Mediapipe es una biblioteca de código abierto desarrollada por Google que proporciona una variedad de herramientas para el procesamiento de imágenes, incluyendo la detección facial. La detección facial en Mediapipe utiliza modelos preentrenados para detectar y localizar características faciales clave. Utiliza 468 puntos de referencia del rostro que permiten obtener información detallada sobre la expresión facial, lo cual resulta útil en la detección de somnolencia. En la Figura 3.2 se puede observar la malla que utiliza la librería para detectar la cara con los puntos de referencia.

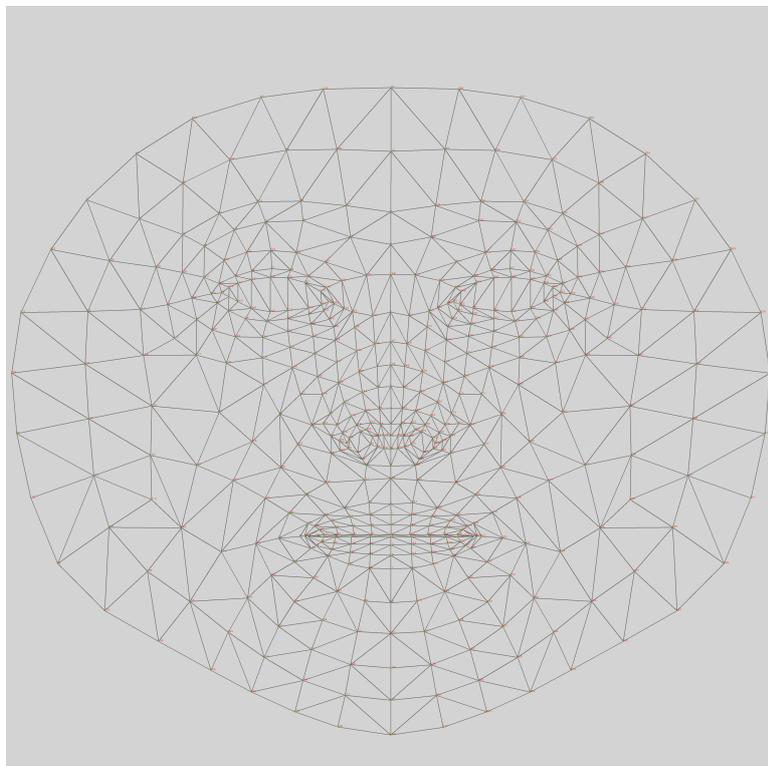


Figura 3.2: Puntos de referencia del rostro de Mediapipe

Al utilizar Mediapipe en este proyecto, se ha podido aprovechar su capacidad para detectar características faciales relevantes en los vídeos grabados del conductor. Esto ha permitido extraer información adicional sobre los movimientos y cambios en el rostro que pueden indicar signos de somnolencia. La Figura 3.3 muestra un ejemplo de una imagen del conductor con la detección facial aplicada, donde se puede apreciar la detección precisa de las características faciales, como el contorno de los ojos y de la boca entre otros. Esto demuestra la efectividad de Mediapipe en la detección de rasgos faciales relevantes para el análisis de la somnolencia y se presenta como una herramienta útil en el desarrollo de modelos de visión artificial para la detección de fatiga.

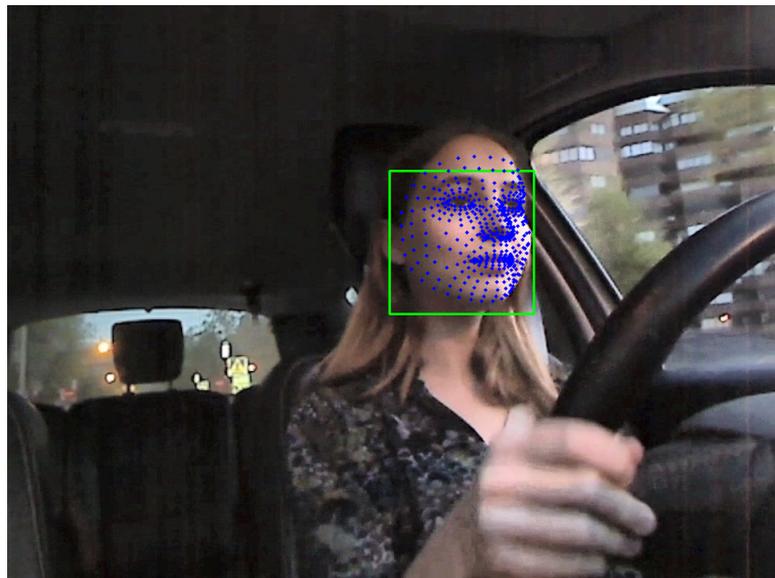


Figura 3.3: Ejemplo de conductor con la detección de puntos de referencia faciales utilizando Mediapipe

En el contexto de este proyecto, se ha optado por utilizar Mediapipe en lugar de otras librerías populares como Dlib debido a las siguientes consideraciones. Aunque Dlib también es ampliamente utilizada en aplicaciones de detección facial, tiene menos puntos de referencia disponibles en comparación con Mediapipe (Ver Figura 3.4), lo que podría limitar su capacidad para capturar detalles sutiles en la cara. Además, durante la exploración de los datos, se observó que Dlib tiende a ser menos precisa cuando la persona no está mirando directamente hacia la cámara. Es decir, si el conductor gira ligeramente la cabeza, Dlib tiene dificultades para detectar y seguir con precisión los puntos de referencia faciales. En contraste, Mediapipe ha demostrado ser más robusta en tales situaciones, manteniendo un buen funcionamiento incluso cuando hay variaciones en la orientación de la cabeza del conductor. Esto es crucial para lograr un sistema de detección confiable en condiciones del mundo real, donde es común que el conductor tenga movimientos naturales y no siempre esté mirando directamente a la cámara.

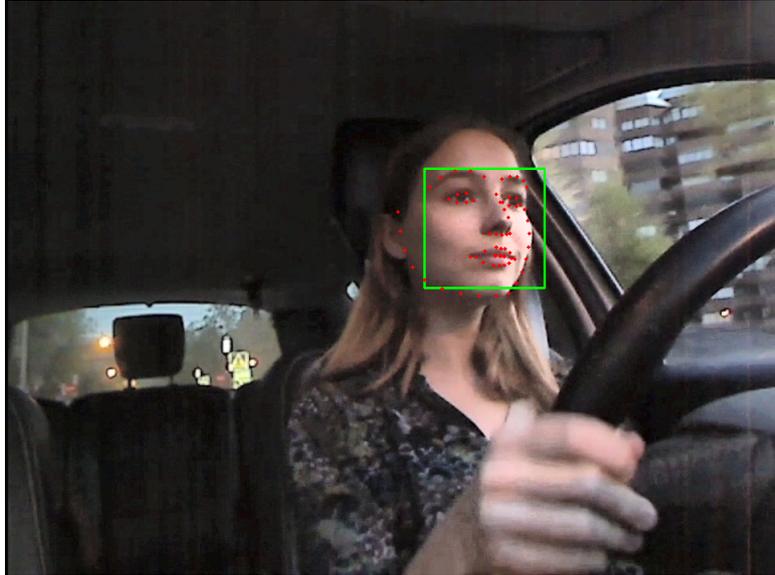


Figura 3.4: Ejemplo de conductor con la detección de puntos de referencia faciales utilizando Dlib

En el siguiente capítulo, se detallará de manera exhaustiva la metodología utilizada para el preprocesado de los datos, incluyendo el ajuste de iluminación y la extracción de características faciales con Mediapipe. Estos pasos son fundamentales para preparar los datos y proporcionar información valiosa al modelo de detección de somnolencia.

## 3.2. Preprocesado de datos

En este capítulo, se presenta el preprocesado de datos llevado a cabo en este proyecto para la detección de somnolencia en conductores. La Figura 3.5 muestra las etapas clave del proceso de preparación de los datos para su uso en el entrenamiento y evaluación de los modelos diseñados. Las distintas etapas incluyen la extracción de imágenes de los vídeos, el ajuste de la iluminación, la extracción de características faciales, el muestreo de las imágenes, el recorte de la imagen para ajustarse a la cara detectada y la normalización. Cada fase desempeña un papel crucial en la creación de un conjunto de datos para el desarrollo de un modelo de detección de somnolencia preciso y robusto. A continuación, se explicarán en detalle las diferentes fases del preprocesado.

Antes de comenzar con el proceso de preprocesado de los datos, es importante destacar que se ha realizado una cuidadosa división de los vídeos en conjuntos de entrenamiento, validación y prueba. Esta división se llevó a cabo de manera manual en lugar de una separación aleatoria de todas las imágenes. Esta decisión se tomó para evitar la inclusión de imágenes

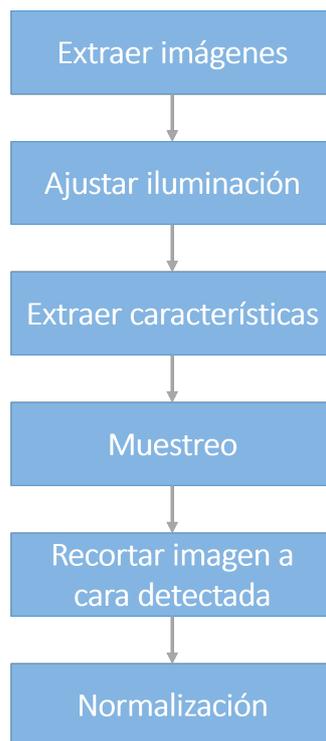


Figura 3.5: Esquema de los pasos del preprocesado de datos para la detección de somnolencia

muy similares pertenecientes al mismo vídeo en conjuntos diferentes, lo cual podría introducir un sesgo no deseado al filtrar información de entrenamiento a prueba. Así, se garantiza una separación adecuada de los datos y se promueve una evaluación justa y fiable del modelo de detección de somnolencia.

En primer lugar, se procesaron los vídeos grabados para extraer todas las imágenes del conductor. Además, se registró el número de fotogramas por segundo (FPS), un dato relevante para la extracción posterior de características faciales. Como se ha explicado anteriormente, los vídeos fueron grabados bajo diferentes condiciones lumínicas. Para abordar esto, se diseñó una función de transformación de las imágenes para ajustar su iluminación. Se empleó una técnica llamada Ecuación de Histograma Adaptativa de Contraste Limitado (CLAHE). Esta técnica permite mejorar el contraste de la imagen al normalizar las intensidades de los píxeles en regiones locales de la imagen. Al aplicar esta mejora, se logra una mayor visibilidad de los detalles tanto en áreas brillantes como en áreas oscuras de la imagen. En la Figura 3.6 se puede observar la diferencia entre la imagen original y la imagen con la transformación para ajustar la iluminación. Esta transformación es especialmente útil para asegurar que el modelo de detección de somnolencia sea capaz de funcionar de manera efectiva en diversas condiciones lumínicas, incluso en situaciones de conducción nocturna.

En el siguiente paso, se empleó la librería Mediapipe para detectar los rasgos faciales en las imágenes transformadas, con el propósito de extraer diversas características. Específica-



(a) Imagen sin transformación

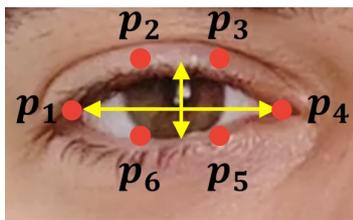


(b) Imagen con transformación

Figura 3.6: Comparación entre una imagen sin transformación y una con transformación

mente, se calcularon para cada imagen el EAR (Eye Aspect Ratio) y MAR (Mouth Aspect Ratio) para evaluar la apertura del ojo y de la boca, respectivamente, así como la duración y la frecuencia de los parpadeos. A continuación, se detallará el proceso utilizado para calcular cada una de estas características.

La primera característica extraída fue el EAR, métrica que evalúa la apertura de los ojos a partir de la relación entre las distancias de los puntos clave del ojo. La Figura 3.7 muestra el cálculo del EAR. Un valor menor de EAR indica una menor apertura de los ojos, mientras que un valor mayor indica una mayor apertura. Esta medida permite detectar cambios en la apertura del ojo, como parpadeos, por lo que es especialmente útil para la detección de somnolencia. Para determinar si ocurre un parpadeo, se establece un umbral y se considera que el ojo se cierra si el EAR cae por debajo de dicho umbral. De esta manera, se pueden extraer características adicionales como la duración y la frecuencia de parpadeo.



$$\text{EYE\_ASPECT\_RATIO} = \frac{\|p_2 - p_6\| + \|p_3 - p_5\|}{2 \cdot \|p_1 - p_4\|} \quad (3.1)$$

Fuente de Datos: (Datahacker.rs, 2020)

Figura 3.7: Fórmula del Eye Aspect Ratio (EAR)

A partir del EAR, se ha determinado si ocurre un parpadeo en cada imagen. Mediante el análisis de fotogramas consecutivos, se utilizó una ventana deslizante (sliding window) para recorrer los vídeos y extraer la duración de los parpadeos. Esta medida se obtuvo considerando parpadeos consecutivos dentro de ventanas de 10 segundos. Para este cálculo, se tuvo en cuenta el valor de FPS, que indica el tiempo transcurrido entre cada imagen. De manera

similar, se pudo obtener la frecuencia de parpadeo analizando la cantidad de parpadeos en un intervalo de tiempo determinado.

Finalmente, se calcula el MAR de manera similar al EAR utilizando los puntos de referencia de la boca proporcionados por Mediapipe. Esta métrica permite analizar la apertura de la boca, por lo que se espera que a medida que aumente el cansancio, haya un mayor MAR debido a un número más elevado de bostezos. El MAR proporciona información adicional sobre el estado de somnolencia y complementa la evaluación basada en el análisis de los ojos.

La Tabla 3.2 muestra el promedio de diversas características extraídas de los datos de entrenamiento, clasificadas según la clase de somnolencia. Se observa que a medida que aumenta el nivel de cansancio, tanto el EAR derecho como el EAR izquierdo disminuyen gradualmente, lo que indica una menor apertura de los ojos. Además, se observa un aumento en la duración y frecuencia de parpadeo a medida que el nivel de cansancio aumenta. Esto sugiere una mayor fatiga ocular y una mayor necesidad de parpadear para mantener la atención. Por último, el MAR muestra un incremento progresivo a medida que el cansancio se intensifica, lo cual indica una mayor apertura de la boca, posiblemente debido a un mayor número de bostezos. Estas relaciones entre las características y los niveles de cansancio son consistentes con los patrones esperados, proporcionando una base sólida para el desarrollo y entrenamiento de modelos de detección y clasificación de somnolencia.

<b>Clase</b>	<b>EAR derecho</b>	<b>EAR izquierdo</b>	<b>Duración parpadeo</b>	<b>Frecuencia parpadeo</b>	<b>MAR</b>
alerta	0.485	0.517	0.065	12.408	0.129
ligeramente cansado	0.478	0.517	0.088	30.048	0.147
moderadamente cansado	0.473	0.507	0.165	47.997	0.166
muy cansado	0.461	0.506	0.116	55.493	0.163

Tabla 3.2: Promedio de características según la clase de somnolencia

Una vez extraídas las características mencionadas, se avanzó al siguiente paso del preprocesado de los datos. En esta etapa, se procedió a tomar una muestra aleatoria de cada conjunto de datos, garantizando una distribución equilibrada de las clases de cansancio. Además, se realizó la partición de los datos de manera que quedara una distribución del 70 % para el conjunto de entrenamiento, un 15 % para el conjunto de validación y otro 15 % para el conjunto de prueba.

Después de esta etapa, se procedió a recorrer las imágenes de la muestra seleccionada. Durante este proceso, se utilizó Mediapipe para la identificación de la cara y así poder recortar cada imagen con un margen alrededor de la región facial. Esta estrategia permitió reducir el

tamaño de las imágenes y, a su vez, disminuir los costes de procesamiento. Finalmente, se realizó la normalización de las características extraídas, así como de las imágenes recortadas. Esta normalización asegura que todas las variables estén en un rango comparable, lo cual facilita el entrenamiento de los modelos de detección de somnolencia.

En lugar de almacenar todas las imágenes preprocesadas en una estructura de datos específica de programación, se utilizó el generador de imágenes (ImageGenerator) proporcionado por Keras, librería de Python que se utiliza para construir modelos de Deep Learning. Este generador permite cargar y preprocesar las imágenes dinámicamente durante el entrenamiento del modelo. Esta estrategia resulta más eficiente en términos de uso de memoria, ya que solo se cargan las imágenes necesarias para cada paso de entrenamiento, en lugar de cargar todo el conjunto de datos de una vez. Además del generador de imágenes, se creó un generador personalizado que se encargó de proporcionar tanto las imágenes preprocesadas como las características (EAR, MAR, etc.) necesarias para el entrenamiento. Esto permitió una integración fluida de las dos fuentes de información en el modelo durante el proceso de entrenamiento.

En resumen, en esta sección se ha llevado a cabo una explicación exhaustiva del preprocesado de datos para la detección de somnolencia en conductores. Se han seguido diversas etapas, incluyendo la extracción de imágenes de los vídeos, el ajuste de la iluminación y la detección de características faciales. Con los datos procesados, la siguiente sección se enfocará en el diseño detallado del modelo para la detección de somnolencia en conductores.

### **3.3. Modelo de computer vision para la detección de somnolencia**

En este proyecto, se ha desarrollado un modelo de visión artificial para la detección de distintos niveles de somnolencia en conductores utilizando técnicas de Deep Learning. El objetivo principal es identificar si un conductor se encuentra en un estado de somnolencia a partir de las imágenes capturadas, lo que puede ser crucial para prevenir accidentes de tráfico relacionados con la fatiga. El uso de Deep Learning en este contexto ofrece la ventaja de ser capaz de aprender automáticamente características relevantes de los datos, lo que las hace especialmente adecuadas para analizar imágenes complejas. Para abordar este problema, se ha empleado una red neuronal convolucional (CNN), una arquitectura especialmente diseñada para el procesamiento de imágenes.

La capa convolucional es la parte central de una CNN y se compone de filtros o kernels

que se desplazan por la imagen de entrada para extraer características locales, como se muestra en la Figura 3.8. Cada filtro calcula el producto escalar entre los valores del filtro y la ventana de entrada correspondiente. Esto permite detectar características específicas, como bordes, texturas o formas, y su salida se utiliza para formar mapas de características. La idea detrás de las capas convolucionales es que las características locales aprendidas se combinen y se utilicen para construir representaciones más abstractas de la imagen. Las primeras capas convolucionales extraerán características más simples, pero a medida que los datos fluyen a través de la red, se van extrayendo características cada vez más complejas y significativas. Esta capacidad de las CNN para aprender automáticamente características y patrones relevantes en las imágenes las convierte en una elección ideal para el problema de detección de somnolencia en conductores, ya que pueden capturar tanto características sutiles como características más evidentes relacionadas con la somnolencia, como la apertura de los ojos, el parpadeo o la posición de la cabeza.

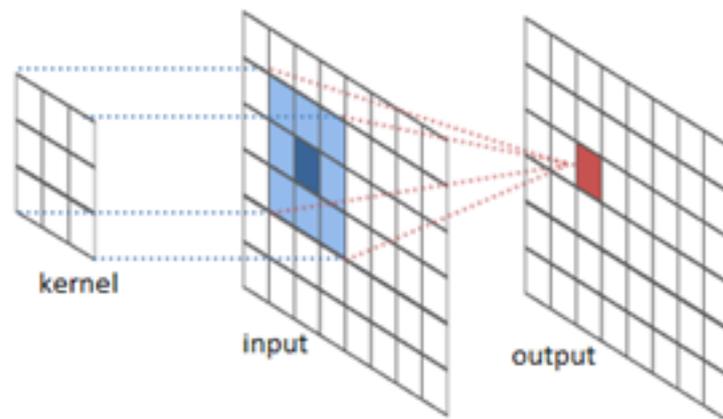


Figura 3.8: Convolución de una imagen  
Fuente de Datos: (Pokhrel, 2019)

En el desarrollo del modelo de detección de somnolencia, se ha diseñado una arquitectura personalizada que aprovecha las ventajas del Deep Learning para combinar información de imágenes capturadas del conductor y características numéricas relevantes, como el EAR o la duración de parpadeo. La Figura 3.9 ilustra en detalle la arquitectura final del modelo.

La arquitectura consta de dos ramas de entrada: una para procesar las imágenes y otra para procesar las características numéricas. En la rama de imágenes, se utilizan capas convolucionales para extraer características visuales de las imágenes, mientras que la rama de características numéricas utiliza capas totalmente conectadas para procesar la información numérica. Ambas ramas se combinan al final, lo que permite al modelo capturar relaciones complejas entre las imágenes y las características numéricas, mejorando su capacidad para detectar distintos niveles de somnolencia.

Para obtener la mejor arquitectura, se han realizado diversos experimentos ajustando pa-

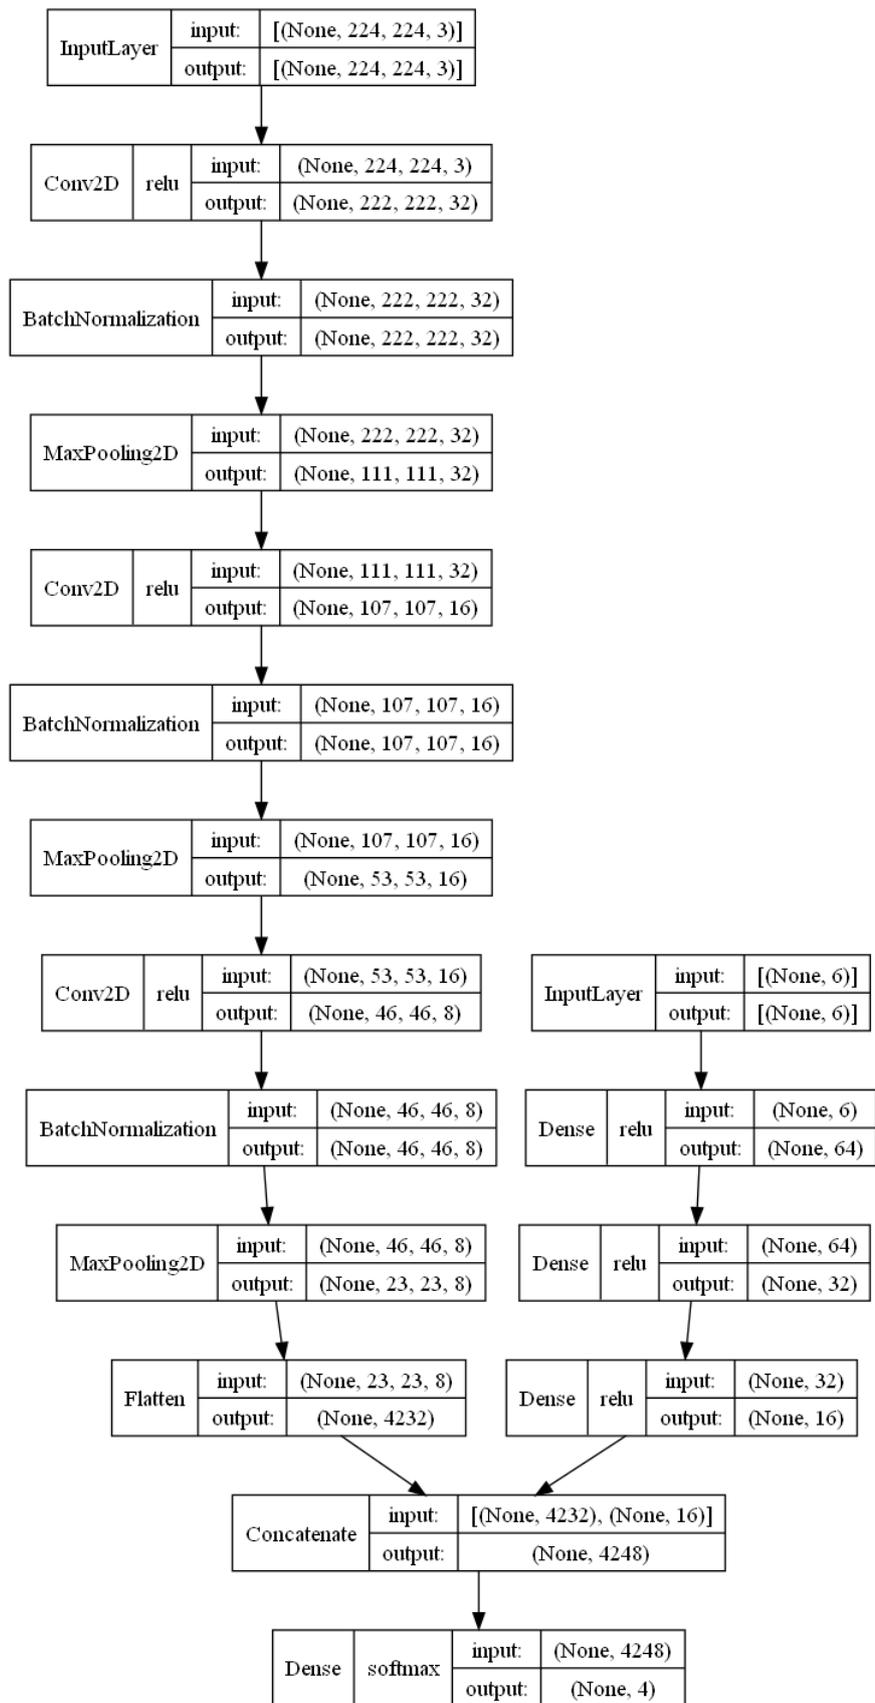


Figura 3.9: Esquema del modelo para la detección de somnolencia

rámetros clave, como el número de filtros y el tamaño de kernel de las capas convolucionales. La estrategia utilizada se basó en aumentar gradualmente la complejidad del modelo y evaluar su rendimiento con el conjunto de validación. A medida que se probaron diferentes configuraciones, se observó que agregar más capas convolucionales y más capas completamente conectadas permitió al modelo aprender características más sofisticadas y mejorar su capacidad de detección y clasificación de niveles de somnolencia. Sin embargo, se tuvo en cuenta que este aumento en la complejidad del modelo también conllevaba un mayor tiempo de entrenamiento y requisitos computacionales. Por lo tanto, se buscó encontrar un equilibrio adecuado entre la complejidad y el rendimiento del modelo.

En una CNN, el número de filtros y el tamaño del kernel son dos aspectos clave que influyen en la capacidad de la red para capturar características relevantes. En este trabajo se decidió seguir una estrategia de disminuir el número de filtros y aumentar el tamaño del kernel a medida que se avanza en la red. En las capas iniciales, los filtros capturan características de bajo nivel, como bordes y texturas simples. A medida que se avanza en la red, las capas convolucionales tienden a aprender características más complejas y abstractas. Al reducir el número de filtros, se busca comprimir la información de las capas anteriores para permitir a las siguientes capas capturar características más relevantes. Por otro lado, el aumento gradual del tamaño del kernel ha demostrado un mejor rendimiento. Esto se debe a que aumentar el tamaño permite a la red capturar características más grandes y globales de la imagen. Esta estrategia ha ayudado a la red a enfocarse en características más significativas y relevantes para el problema de detección de somnolencia, mejorando así su capacidad de clasificación y generalización.

Además de las capas convolucionales, se incorporaron capas de MaxPooling y Batch Normalization en la arquitectura del modelo de detección de somnolencia. Las capas de MaxPooling se utilizan para reducir la dimensionalidad de las características extraídas y extraer las características más importantes. Estas capas permiten capturar información relevante al seleccionar los valores máximos en una región determinada, lo que ayuda a reducir el riesgo de sobreajuste y a mejorar la eficiencia computacional del modelo. Por otro lado, las capas de Batch Normalization normalizan la salida de las capas anteriores, lo que acelera el proceso de entrenamiento y mejora la estabilidad del modelo. Añadir estas capas a la red demostró un mayor rendimiento al evaluarlo con los datos de validación ya que permiten una mejor extracción de características relevantes y ayudan a optimizar el proceso de entrenamiento.

Una estrategia importante que se ha aplicado es la disminución del factor de aprendizaje, también llamado learning rate, a medida que el modelo aprende. El factor de aprendizaje es un parámetro que determina la magnitud de los ajustes realizados en los pesos de la red durante el proceso de entrenamiento. Inicialmente, se estableció un factor de aprendizaje alto ya que

ayuda a explorar rápidamente el espacio de soluciones y a realizar ajustes significativos en los pesos. Sin embargo, a medida que se avanza en el proceso de entrenamiento, es importante disminuir gradualmente el factor de aprendizaje. Esto se debe a que, a medida que el modelo se acerca a una solución óptima, los ajustes necesarios en los pesos deben ser más pequeños y precisos. Si se mantiene un factor de aprendizaje alto, podría resultar en oscilaciones o pasos excesivos en la optimización, lo que puede afectar negativamente el rendimiento del modelo. La estrategia se basa en la siguiente ecuación:

$$\text{learning rate} = \text{learning rate inicial} \times \text{factor de disminución}^{\text{época}/\text{épocas de disminución}} \quad (3.2)$$

Al utilizar esta ecuación, el learning rate disminuye a medida que se incrementan las épocas de entrenamiento, lo que permite una adaptación más precisa del modelo. La elección adecuada de los valores para learning rate inicial, factor de disminución y épocas de disminución requirió ajuste y experimentación.

Además de la arquitectura personalizada, también se exploró la posibilidad de utilizar transfer learning con una red preentrenada, específicamente VGG16. El transfer learning es una estrategia en la cual se aprovecha el conocimiento y los pesos aprendidos por una red neuronal entrenada en un conjunto de datos masivo para inicializar la red y acelerar el proceso de aprendizaje en un nuevo conjunto de datos más específico, en este caso, la detección de somnolencia en conductores. VGG16 es una red neuronal convolucional conocida que ha demostrado un buen rendimiento en diversos problemas de computer vision. Está compuesta por 16 capas convolucionales y completamente conectadas como se puede observar en la Figura 3.10.

No obstante, durante los experimentos realizados, se observó que el uso de VGG16 no proporcionaba mejoras significativas en el rendimiento del modelo de detección de somnolencia. Además, el entrenamiento de VGG16 requería mucho tiempo debido a su alta complejidad. Debido a estas razones, el trabajo se enfocó en el desarrollo de una arquitectura personalizada que se ajustara de manera más precisa a los datos específicos de la detección de somnolencia en conductores.

Después de realizar múltiples pruebas y ajustes, finalmente se obtiene el modelo final de detección de somnolencia. Este modelo cuenta con 4 neuronas en la capa de salida, representando la distribución de probabilidad de pertenecer a cada estado de somnolencia. Durante el proceso de entrenamiento, se ha evaluado regularmente el rendimiento del modelo utilizando los datos de validación. Esta práctica permite controlar el sobreajuste y garantizar que el modelo tenga una buena capacidad de generalización.

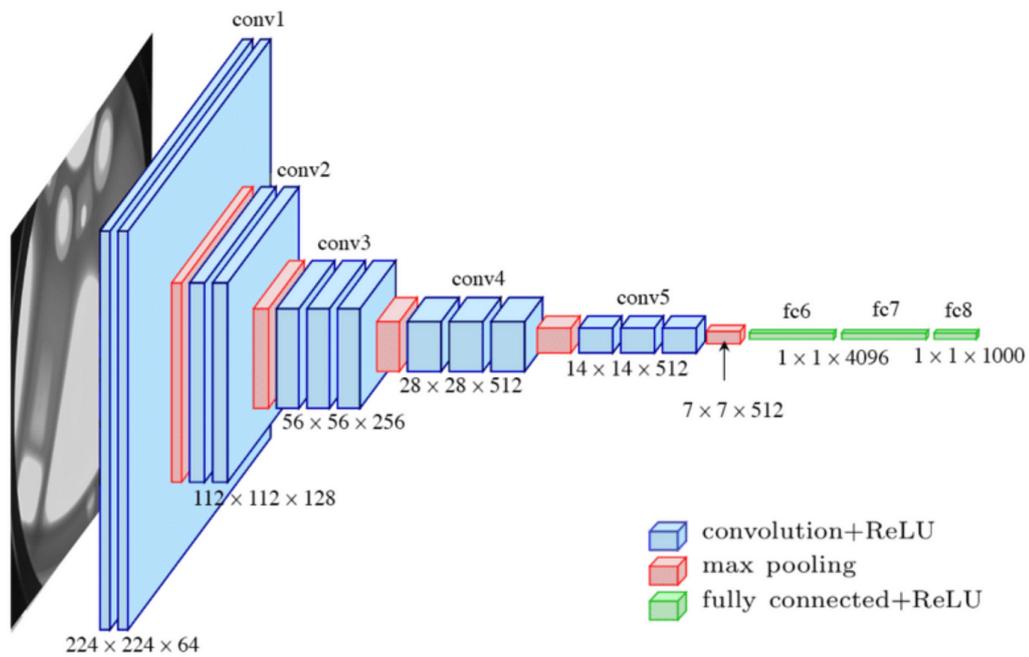


Figura 3.10: Arquitectura del modelo VGG16  
Fuente de Datos: (Le, 2021)

En la Figura 3.11 se muestra la evolución del accuracy y la pérdida durante el entrenamiento. Se puede observar que el accuracy aumenta progresivamente con cada epoch, mientras que la pérdida disminuye. Esto indica que el modelo está aprendiendo y mejorando su capacidad de clasificación a medida que avanza el entrenamiento. Es importante destacar que el accuracy alcanza el 100% en los datos de entrenamiento, lo cual es un indicador positivo ya que aprende a clasificar las imágenes vistas a la perfección. Sin embargo, en los datos de validación, el accuracy se mantiene alrededor del 90%, lo cual es esperado ya que son datos no vistos por el modelo, pero sigue siendo un resultados prometedor.

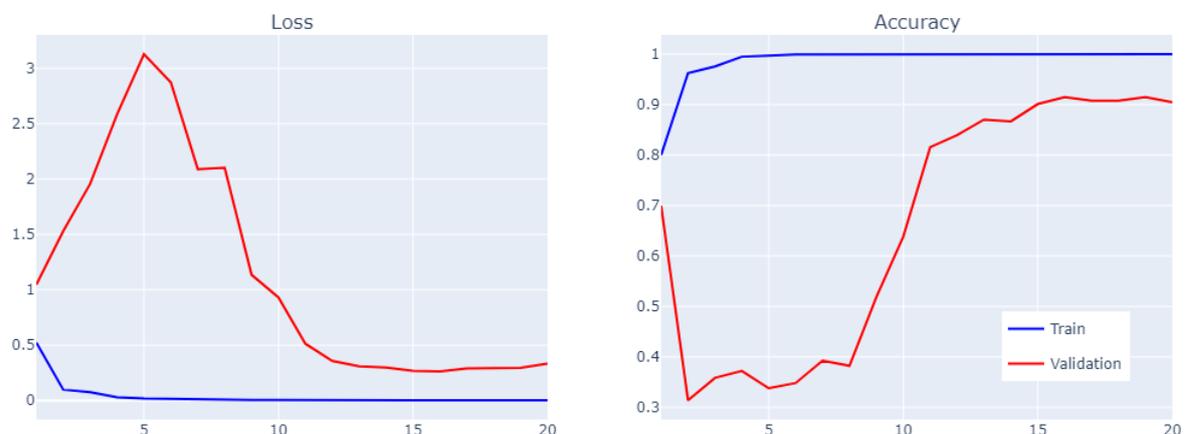


Figura 3.11: Aprendizaje del modelo: evolución de la pérdida y el accuracy

En el próximo capítulo, se realizará un análisis más detallado de los resultados y se evaluará el rendimiento del modelo utilizando datos de prueba. En general, se puede afirmar que el modelo muestra buenos resultados hasta el momento, lo cual es alentador y brinda confianza en su capacidad para detectar niveles de somnolencia en conductores.

### **3.4. Sistema de alerta al conductor**

En esta sección, se plantea la implementación teórica del funcionamiento práctico del sistema en situaciones reales. Si bien actualmente se cuenta con un modelo de clasificación que puede predecir el nivel de somnolencia en cada imagen capturada, resulta ineficiente y poco práctico hacer predicciones para cada fotograma individualmente, especialmente considerando que puede haber múltiples fotogramas por segundo. Además, existen situaciones en las que eventos como estornudos o movimientos bruscos pueden dar lugar a predicciones erróneas de alta somnolencia y no es deseable que esté saltando la alerta constantemente por errores como estos.

Por lo tanto, se propone un enfoque de procesamiento por lotes de 10 segundos. Esto implica tomar un conjunto de imágenes correspondientes a un intervalo de tiempo de 10 segundos (que serían aproximadamente 300 imágenes considerando una frecuencia de 30 FPS) y realizar una predicción en base a dicho lote. La decisión de utilizar un período de 10 segundos puede ajustarse según el caso de uso y el nivel de riesgo que la empresa esté dispuesta a asumir.

En función de las predicciones realizadas en el lote de 10 segundos, se establecerá un umbral para activar las alertas correspondientes. Por ejemplo, si más del 50 % de las imágenes son clasificadas como "muy cansado", se pueden activar medidas de alerta como hacer vibrar el volante o emitir una alarma audible. En caso de que la cantidad de imágenes clasificadas como "muy cansado" sea menor, pero aún así haya más del 50 % clasificadas como "moderadamente cansado", se podría optar por mostrar una notificación en la pantalla recomendando un descanso. Estos umbrales se adaptarían a través de múltiples pruebas y según el nivel de prudencia que se desee según el caso de uso. A modo de ejemplo, algunos vehículos, como los de la marca Volvo, utilizan una representación gráfica de una taza de café para indicar la necesidad de un descanso en caso de detectar cansancio en el conductor (Volvo Car Corporation, 2007).

Además, en la etapa de preprocesamiento de los datos se ha tenido en cuenta la adaptación al enfoque de procesamiento por lotes propuesto para reflejar la situación real planteada. Específicamente, al calcular métricas como la frecuencia y duración de parpadeos, se ha

considerado la división de los datos de prueba y validación en lotes de 10 segundos. De esta manera, al integrar el procesamiento por lotes en el preprocesamiento de los datos y considerar la duración de parpadeos en intervalos de 10 segundos, se logra una mayor coherencia y aplicabilidad en el análisis de los datos de prueba y validación, brindando una representación más precisa de la somnolencia del conductor en situaciones reales.

Es importante destacar que el umbral y el porcentaje de imágenes clasificadas para activar las alertas pueden ser definidos y ajustados según las necesidades y el riesgo asociado a cada caso de uso. En situaciones en las que los vehículos son utilizados para fines profesionales, como camiones, autobuses o taxis, donde los conductores pasan largas horas al volante, se podría considerar un umbral más alto. Por el contrario, en vehículos de uso privado, donde el riesgo puede ser menor, se puede optar por un umbral más bajo.

Este enfoque de procesamiento por lotes y la configuración de umbrales adaptativos permiten optimizar el funcionamiento del sistema de alerta al conductor, evitando falsas alarmas y minimizando los riesgos asociados a la somnolencia al volante. La implementación práctica de este sistema requeriría una integración adecuada con los dispositivos del vehículo y una estrategia de retroalimentación constante para mejorar su precisión y eficacia a lo largo del tiempo.

# Capítulo 4

## Análisis de Resultados

En este capítulo, se presenta un análisis exhaustivo de los resultados obtenidos por el modelo de detección de somnolencia diseñado. El sistema utiliza una red neuronal convolucional (CNN) que toma como entrada las imágenes del conductor, junto con una tabla de datos que contiene características adicionales como el EAR (Eye Aspect Ratio). El modelo proporciona una distribución de probabilidad para cuatro clases de somnolencia: alerta, ligeramente cansado, moderadamente cansado y muy cansado. En el capítulo anterior, se detalló el proceso de procesamiento de los datos y el diseño del modelo. En este capítulo, se analizarán y evaluarán en profundidad los resultados obtenidos. Se examinarán métricas clave como la precisión, el recall y el F1-score, y se presentará la matriz de confusión y las curvas ROC. El objetivo principal es evaluar el desempeño del modelo en la detección de diferentes niveles de somnolencia y proporcionar una visión clara de su eficacia y áreas de mejora potencial.

El análisis inicial revela un prometedor accuracy del 91.22% en los datos de prueba, lo cual indica un buen desempeño general del modelo en la clasificación de los niveles de somnolencia. Además, el tiempo de predicción es de aproximadamente 1,5 segundos para el conjunto de prueba que contiene casi 300 imágenes, lo que sería equivalente a 10 segundos de vídeo del conductor. Este tiempo es bastante rápido y respalda la viabilidad del sistema para su implementación en tiempo real, como se planteó en el capítulo anterior. No obstante, antes de llegar a conclusiones definitivas sobre el desempeño del modelo, es necesario realizar un análisis más profundo, considerando otras métricas como precisión, recall, F1-score, así como examinar la matriz de confusión para comprender mejor los aciertos y errores de clasificación y determinar las áreas en las que el modelo puede ser mejorado.

En el análisis de los resultados, se utilizaron tres métricas clave para evaluar el desempeño del modelo de clasificación en cada clase de somnolencia: precisión, recall y F1-score. La

precisión mide la proporción de ejemplos correctamente clasificados como positivos con respecto al total de ejemplos clasificados como positivos. Se calcula mediante la siguiente fórmula:

$$\text{Precisión} = \frac{\text{Verdaderos positivos}}{\text{Verdaderos positivos} + \text{Falsos positivos}} \quad (4.1)$$

El recall, también conocido como sensibilidad, es la proporción de instancias positivas correctamente identificadas respecto al total de instancias positivas. Su fórmula es:

$$\text{Recall} = \frac{\text{Verdaderos positivos}}{\text{Verdaderos positivos} + \text{Falsos negativos}} \quad (4.2)$$

Por último, el F1-score es una medida que combina la precisión y el recall en una sola métrica, proporcionando una medida ponderada del rendimiento del modelo. Se calcula mediante la fórmula:

$$\text{F1-score} = 2 \times \frac{\text{Precisión} \times \text{Recall}}{\text{Precisión} + \text{Recall}} \quad (4.3)$$

En principio, la métrica F1-score parece ser la más relevante ya que combina tanto la precisión como el recall en una sola medida. El F1-score proporciona una visión equilibrada del desempeño del modelo al considerar tanto los falsos positivos como los falsos negativos. Sin embargo, es importante mencionar que la relevancia de cada métrica puede variar dependiendo del caso de uso específico. En casos donde la seguridad y la minimización de los riesgos son fundamentales, como podría ser en una empresa de transporte de carga donde existe más riesgo, se le podría dar prioridad al recall sobre la precisión, específicamente el recall de las clases de niveles de somnolencia más altos. El recall es la métrica que indica la capacidad del modelo para detectar correctamente los casos positivos, es decir, que el conductor esté muy cansado. Al priorizar el recall, se minimizan los falsos negativos para que el modelo no deje pasar casos de alta somnolencia que podrían representar un mayor riesgo de accidentes. Esto podría significar tolerar un mayor número de falsos positivos (clasificar erróneamente casos de alerta o somnolencia no severa como niveles de cansancio más altos), pero se prefiere tomar precauciones adicionales y ser más prudente en la detección. En el siguiente análisis, se evaluarán las métricas de precisión, recall y F1-score en general, sin considerar un caso de uso específico, para obtener una evaluación completa del rendimiento del modelo.

En la Figura 4.1 se presenta una gráfica de barras que muestra las métricas de precisión, recall y F1-score para cada clase del sistema de detección de somnolencia. Esta gráfica proporciona una visualización clara y comparativa de las métricas para cada clase, lo que permite analizar el rendimiento del modelo de manera más intuitiva.

Al analizar los resultados, se observa que la clase 'alerta' obtuvo un rendimiento excelente

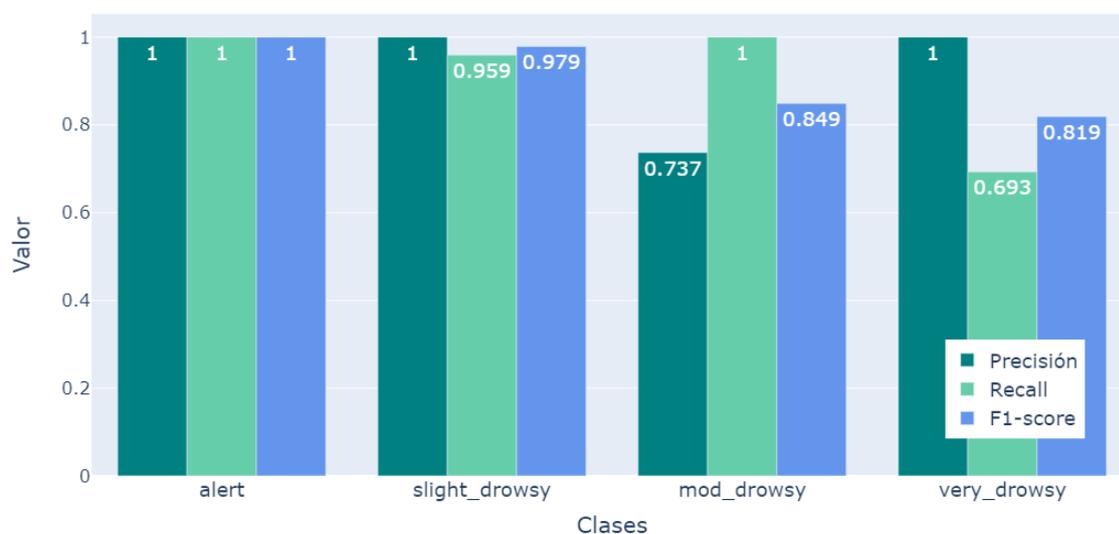


Figura 4.1: Métricas de clasificación

en todas las métricas evaluadas. La precisión, recall y F1-score para esta clase fueron del 100 %, lo que indica que el modelo clasificó correctamente todas las instancias de 'alerta'. Esto sugiere que el sistema es altamente confiable al detectar el estado de alerta del conductor.

En cuanto a la clase 'ligeramente cansado', se logró una alta precisión y recall, lo que indica una buena capacidad del modelo para detectar esta clase. El F1-score obtenido fue también alto, lo que demuestra un equilibrio entre precisión y recall. Estos resultados sugieren que el sistema puede identificar eficazmente los casos de cansancio leve.

En el caso de la clase 'moderadamente cansado', se observa una precisión inferior en comparación con las otras clases. Sin embargo, el recall fue perfecto, lo que indica que el modelo pudo detectar todas las instancias reales de esta clase. El F1-score obtenido refleja un equilibrio aceptable entre precisión y recall, aunque se recomienda mejorar la precisión para esta categoría en particular.

Por último, la clase 'muy cansado' mostró una alta precisión, pero el recall fue más bajo, lo que indica que el sistema no logró detectar todos los casos reales de mucho cansancio. Esto puede suponer un riesgo ya que el 30 % de los casos de somnolencia severa no se están clasificando correctamente. El F1-score obtenido refleja un buen equilibrio general entre precisión y recall, pero sugiere la necesidad de mejorar la capacidad de detección de casos de somnolencia muy severa.

En resumen, el sistema de detección de somnolencia muestra un rendimiento generalmente sólido en la clasificación de las diferentes clases. Sin embargo, se identificaron áreas de mejora en la precisión y el recall, especialmente en las clases 'moderadamente cansado' y

'muy cansado'. Estos resultados resaltan la importancia de continuar optimizando el modelo para mejorar su capacidad de detección en casos de somnolencia más pronunciada.

Al analizar la matriz de confusión (Figura 4.2), se observa que en general el modelo presenta un buen desempeño con una baja tasa de errores. La mayoría de las predicciones se alinean correctamente con las clases correspondientes, lo que indica una buena capacidad del modelo para distinguir entre los distintos niveles de somnolencia. Sin embargo, se observa un número significativo de confusiones en la clase 'muy cansado', donde 23 de las 75 instancias se clasifican erróneamente como 'moderadamente cansado'.

		Predicted Label			
		alert	slight_drowsy	mod_drowsy	very_drowsy
True Label	alert	75 (25.3%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
	slight_drowsy	0 (0.0%)	70 (23.6%)	3 (1.0%)	0 (0.0%)
	mod_drowsy	0 (0.0%)	0 (0.0%)	73 (24.7%)	0 (0.0%)
	very_drowsy	0 (0.0%)	0 (0.0%)	23 (7.8%)	52 (17.6%)

Figura 4.2: Matriz de confusión

Aunque esta confusión puede parecer preocupante a primera vista, es importante destacar que las clases 'muy cansado' y 'moderadamente cansado' son niveles de somnolencia adyacentes y, por lo tanto, es comprensible que exista cierta superposición y dificultad para distinguir entre ellas. Además, estos resultados también pueden estar influenciados por las características específicas de la base de datos utilizada en el entrenamiento del modelo.

Para abordar este problema, se plantea la necesidad de ampliar la base de datos utilizada en el entrenamiento del modelo. Al contar con una mayor diversidad de imágenes de conductores en diferentes niveles de somnolencia, el modelo puede aprender patrones más robustos y generalizables, lo que puede mejorar su capacidad para distinguir entre los niveles de cansancio de manera más precisa.

Además, es importante considerar el umbral de decisión para la activación de alarmas o advertencias al conductor. Si se establece un umbral más bajo, de manera que se active la alarma cuando se detecte un nivel moderado de cansancio, se podrían reducir los errores de clasificación. Esto implica que la alarma se activaría tanto para casos de 'moderadamente cansado' como para casos de 'muy cansado'. Bajo esta configuración, la tasa de falsos negati-

vos se reduciría y simplemente podría haber algunos falsos positivos en la clase 'ligeramente cansado' donde se puede observar en la matriz de confusión que 3 de las 73 instancias se han clasificado como 'moderadamente cansado'.

En resumen, aunque se observan algunos errores en la matriz de confusión, especialmente entre las clases 'muy cansado' y 'moderadamente cansado', el modelo presenta un buen rendimiento. Se pueden considerar diversas estrategias para mejorar el rendimiento del modelo. Ampliar la base de datos y ajustar el umbral de decisión pueden ser enfoques clave para lograr un modelo de detección de somnolencia más preciso y generalizable.

Continuando con el análisis de los resultados, en la Figura 4.3 se presentan las curvas ROC. La curva ROC es una representación gráfica que muestra la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos para diferentes umbrales de clasificación. El AUC (Area Under the Curve) es el área encerrada bajo la curva ROC y proporciona una medida numérica de la capacidad de discriminación del modelo. Un AUC cercano a 1.0 indica un alto rendimiento en la clasificación, mientras que un valor cercano a 0.5 sugiere una clasificación aleatoria. Al observar la curva ROC global, se puede apreciar una excelente capacidad de discriminación con un área bajo la curva (AUC) de 0.9883. Esto indica que el modelo tiene una alta probabilidad de clasificar correctamente las instancias tanto positivas como negativas en general.

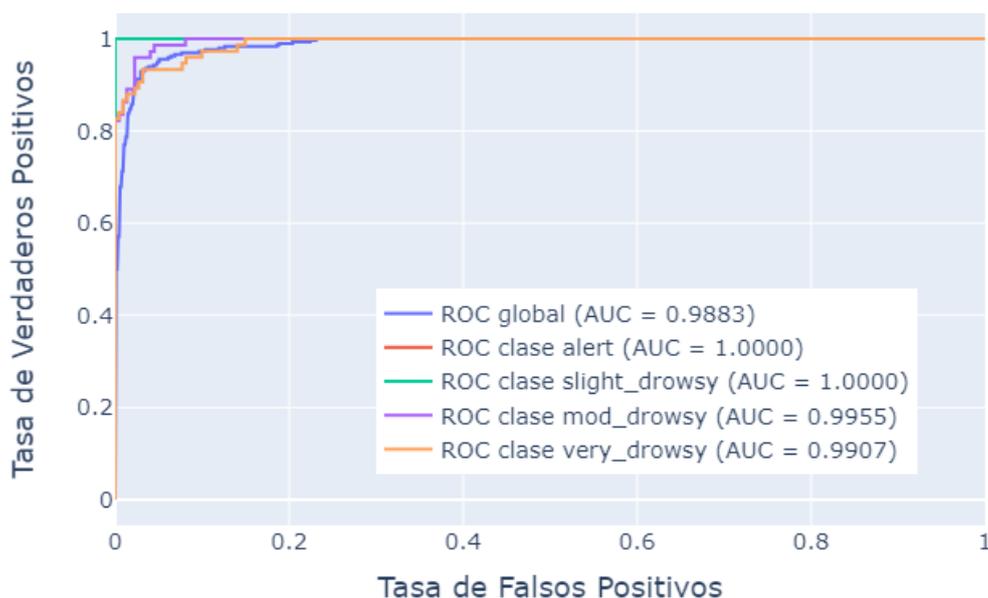


Figura 4.3: Curvas ROC

Al examinar las curvas ROC individuales para cada clase, se observa un rendimiento perfecto en las clases 'alerta' y 'ligeramente cansado', con AUC de 1.0 para ambas. Esto significa que el modelo es altamente preciso en la clasificación de estas clases y tiene una

alta capacidad para distinguirlas de otras clases de somnolencia. En la clase 'moderadamente cansado', la curva ROC muestra un AUC de 0.9955, y en la clase 'muy cansado', la curva ROC muestra un AUC de 0.9907. Aunque estos valores sean ligeramente menores en comparación con las otras clases, siguen siendo bastante altos, lo que sugiere un buen rendimiento en la detección de estos niveles de cansancio.

En conclusión, el análisis de resultados del modelo de detección de somnolencia ha revelado un desempeño sólido en general. El modelo ha demostrado una alta precisión en la clasificación de las clases 'alerta' y 'ligeramente cansado', lo cual es alentador para la detección temprana de la somnolencia en los conductores. Sin embargo, se han identificado áreas de mejora, especialmente en la clasificación de niveles de cansancio más altos como 'moderadamente cansado' y 'muy cansado'. La matriz de confusión ha mostrado una confusión notable entre estas clases, indicando la necesidad de una mayor diversidad en los datos de entrenamiento. Además, el análisis de las curvas ROC ha evidenciado un rendimiento sólido en la mayoría de las clases, pero se ha observado una ligera disminución en la capacidad de discriminación de la clase 'muy cansado'. Estos hallazgos destacan la importancia de ajustar y optimizar el modelo para mejorar su capacidad de detección en todos los niveles de somnolencia. En general, este análisis ha sentado las bases para futuras mejoras y refinamientos del sistema, con el objetivo de garantizar una detección precisa y confiable de la somnolencia en situaciones reales.

## Capítulo 5

# Modelo de Negocio: Estrategias de Comercialización para el Sistema de Detección de Cansancio

En este capítulo, se van a analizar las diversas estrategias comerciales potenciales para el sistema de detección de cansancio desarrollado. A través de tres modelos de negocio, se mostrará cómo una organización puede crear, entregar y capturar valor de manera efectiva y eficiente. Primero, se estudiará el modelo de una aplicación móvil basada en suscripción. Este modelo enviaría alertas de fatiga en tiempo real a los conductores, proporcionando una herramienta activa y directa para mejorar la seguridad en la carretera. En segundo lugar, se explorará la posibilidad de una solución integrada de software en los vehículos, lo cual no sólo añadiría un componente de seguridad, sino que también elevaría el valor y atractivo de los vehículos para los consumidores conscientes de la seguridad. Finalmente, se evaluará la oportunidad de establecer una colaboración con las compañías de seguros. Este modelo podría proporcionar un incentivo tangible a los conductores para adoptar una conducción segura, al mismo tiempo que permitiría a las aseguradoras optimizar sus modelos de riesgo y costes.

Para cada uno de estos modelos, se va a desarrollar un Business Model Canvas. Se trata de una herramienta de gestión estratégica que permite visualizar y descomponer cada modelo de negocio en sus componentes fundamentales. Este enfoque permitirá una comprensión más clara de cada modelo, facilitando una visión sólida de cómo cada uno puede funcionar en la práctica. A continuación, se presentan los tres posible modelos de negocio.

## 5.1. Suscripción a aplicación móvil

Esta idea de negocio consiste en la suscripción a la aplicación. Los usuarios pagarán una cuota mensual o anual para tener acceso a la aplicación y a las actualizaciones del sistema de alerta. Esto funcionará utilizando una aplicación que tendrá el sistema y recogerá los datos de una cámara que apunte al conductor para capturar su cara y detectar su nivel de cansancio. En caso de que supere un umbral preestablecido, se transmitirá una alerta al conductor que le indicará que no está en condiciones de conducir. Este umbral podría ser adaptable por el usuario dependiendo de su nivel de prudencia. Este sistema no sólo mejorará la seguridad al volante, sino que también proporcionará un valor añadido a los clientes. Con un modelo de ingresos basado en suscripciones, licencias premium, y venta de cámaras con marca propia, se espera generar ingresos sostenibles mientras se proporciona un servicio valioso para los clientes. Las secciones fundamentales del Business Model Canvas son las siguientes:

- **Segmentos de clientes:** El segmento de clientes objetivo son los conductores individuales y profesionales, incluyendo taxistas, camioneros, conductores de autobús, y repartidores en furgoneta, que desean mejorar la seguridad en la conducción y minimizar el riesgo al volante.
- **Propuesta de valor:** Se ofrece un acceso fácil y conveniente al sistema de alerta al conductor a través de una aplicación móvil. Es una solución fiable y económica para un usuario individual o conductores profesionales que quieran mejorar la seguridad en la conducción y minimizar el riesgo de quedarse dormido al volante. La cámara grabaría a la persona y si se detecta cansancio mostraría una alerta por pantalla o sonaría una alarma. Además, en caso de accidente, la aplicación geolocaliza y avisa a emergencias.
- **Canales de distribución:** Los canales de distribución incluyen las tiendas de aplicaciones móviles (App Store, Google Play), y campañas de marketing para generar conciencia sobre el riesgo al volante y para comercializar la aplicación a través de radio, TV, y redes sociales.
- **Relaciones con los clientes:** Se mantiene una relación estrecha con los clientes a través del soporte técnico de la aplicación, actualizaciones de software (como el re-entrenamiento del modelo), y retroalimentación del usuario.
- **Fuentes de ingresos:** El modelo de ingresos se basa en un modelo de suscripción mensual de bajo costo, ingresos por licencias premium (un pago por varios coches usando la misma licencia), y venta de cámaras bajo la propia marca que puedan ser conectadas al móvil y facilitar la grabación del conductor.

- **Actividades clave:** La actividad clave para este negocio es el desarrollo y mantenimiento de la aplicación móvil y de la inteligencia artificial. Además, con cierta frecuencia se llevará a cabo una actualización del modelo de detección de somnolencia para incorporar mejoras al adaptar y re-entrenar el modelo. Una actividad clave también es la adquisición de usuarios mediante campañas de marketing para comercializar la aplicación y concienciar del riesgo al volante. También, se encargará de la integración Bluetooth del móvil con la cámara diseñada.
- **Recursos clave:** Los recursos clave incluyen un equipo de desarrollo de software, data scientists y expertos en ciberseguridad para garantizar la privacidad de los datos de los usuarios. Otro recurso es la protección intelectual, es decir, marca, logo, algoritmo y modelo de utilidad. También se necesitarán servidores para el almacenamiento de datos, y conocimiento en seguridad vial.
- **Socios clave:** Los socios clave son los proveedores de servicios en la nube (para almacenar datos y procesar los modelos), las tiendas de aplicaciones móviles (App Store, Google Play), empresas de publicidad, y organismos oficiales como la Dirección General de Tráfico, la plataforma Ponle Freno, la Federación Nacional de Autoescuelas, y asociaciones de conductores profesionales como la Plataforma del Taxi de Madrid y asociaciones de transportistas.
- **Estructura de costes:** La estructura de costes se compone de los siguientes. En primer lugar, los costes asociados al inicio de la empresa como el registro de la marca. Además, se tendrían los costes del equipo de programación y los salarios del equipo técnico y de ventas. También se tendrán costes por la compra de cámaras para revender bajo la marca propia, el coste de las oficinas, y los costes de marketing y publicidad.

## 5.2. Software integrado en el vehículo

Este modelo de negocio se enfoca en la integración directa del sistema de alerta de cansancio en los vehículos. Este enfoque proporciona un valor agregado significativo para los fabricantes de vehículos y, en última instancia, para los conductores, al mejorar la seguridad y minimizar el riesgo de accidentes por fatiga al volante.

- **Segmentos de clientes:** El principal segmento de clientes son los fabricantes de vehículos, incluyendo diseñadores de coches, ingeniería de vehículos y el área de software de vehículos.

- **Propuesta de valor:** Se ofrece un sistema sencillo, fiable y económico que mejora la seguridad en la conducción y minimiza el riesgo de quedarse dormido al volante. Se incorporaría el sistema desarrollado en el software del vehículo, el cual deberá incorporar una cámara apuntando al conductor. Esta propuesta se presenta como una solución de edge computing, una tecnología que permite el procesamiento de datos cerca del lugar donde se generan, en el "borde" de la red, lo que permite un procesamiento de datos más rápido y eficiente, mejorando la detección en tiempo real y la respuesta a situaciones de fatiga del conductor. Además, se alinea con las nuevas regulaciones de la Unión Europea requiriendo a los fabricantes incorporar algún tipo de sistema de detección de cansancio por lo que es de gran valor para estas empresas.
- **Canales de distribución:** Los principales canales de distribución son la colaboración directa con fabricantes de automóviles, la presencia en ferias y eventos profesionales, y la publicación en revistas especializadas.
- **Relaciones con los clientes:** Se mantiene una relación estrecha con nuestros clientes a través de un Key Account Manager que está en contacto con el fabricante del vehículo. Además, se proporciona soporte técnico para fabricantes de vehículos y un equipo de asistencia técnica para asistir en la integración del sistema en el vehículo.
- **Fuentes de ingresos:** Las principales fuentes de ingresos con este modelo de negocio son los acuerdos comerciales con fabricantes de vehículos, las licencias de uso, un sistema de ingresos vía cuota por vehículo instalado, y los servicios de mantenimiento y actualización. Aunque el software esté incorporado en el vehículo, se requieren actualizaciones periódicas para mejorar su eficacia y precisión. Estas actualizaciones, que podrían incluir nuevos datos o modelos re-entrenados, se realizarían a través de una conexión 5G con los servidores para garantizar una baja latencia y una alta seguridad, dada la sensibilidad de los datos manejados.
- **Actividades clave:** Las actividades clave incluyen el desarrollo de soluciones para la integración, la adaptación a los sistemas existentes en los vehículos, la colaboración con fabricantes, y la actualización del algoritmo.
- **Recursos clave:** Los recursos clave incluyen la protección intelectual (marca, logo, algoritmo, modelo de utilidad), un equipo de desarrollo de software, data scientists y expertos en ciberseguridad para garantizar la privacidad de los datos de los usuarios. También se requerirá un equipo técnico especializado para interactuar en la industria del automóvil.
- **Socios clave:** Los socios clave son los fabricantes de automóviles, los proveedores de componentes electrónicos, las empresas de ingeniería, y los proveedores de servicios

en la nube para almacenar datos y procesar los modelos. Además, organizaciones como Sernauto y Faconauto, que representan a los proveedores de automoción y a los concesionarios de automóviles en España respectivamente, también serían socios esenciales debido a su influencia y conexiones en la industria automotriz.

- **Estructura de costes:** La estructura de costes incluye los costes asociados al inicio de la empresa como el registro de la marca, los costes del equipo de programación, los salarios del equipo técnico, los costes de las instalaciones de oficinas, los costes de desarrollo del sistema, y los costes de marketing y publicidad.

### 5.3. Colaboración con compañías aseguradoras

En este modelo de negocio, se busca colaborar con compañías aseguradoras para proporcionar un sistema que no solo mejore la seguridad de los conductores, sino que también reduzca los riesgos y costes para las aseguradoras. Los clientes de seguros de automóviles también se beneficiarían de descuentos y beneficios si utilizan este sistema.

- **Segmentos de clientes:** El principal segmento de clientes son las compañías de seguros y los clientes de seguros de automóviles que buscan reducir el coste de su póliza si sus hábitos de conducción son seguros.
- **Propuesta de valor:** Se ofrece un sistema sencillo y fiable para las aseguradoras que quieran diferenciarse y ofrecer un valor añadido a sus clientes basado en la seguridad en la conducción y minimizar el riesgo de quedarse dormido al volante, con un coste reducido. En caso de accidente, la aplicación geolocaliza y avisa a emergencias. Además, puede dar acceso a la aseguradora a datos sobre hábitos de conducción que permitan segmentar clientes y reducir costes de pólizas e indemnizaciones.
- **Canales de distribución:** Los principales canales de distribución son la colaboración directa con compañías de seguros, la presencia en ferias y eventos profesionales, y la publicación en revistas especializadas.
- **Relaciones con los clientes:** Se mantiene una relación estrecha con las compañías de seguros clientes a través de un Key Account Manager que está en contacto con la aseguradora. Además, se proporciona soporte técnico y asesoramiento a los técnicos de la aseguradora en la gestión de datos de hábitos de conducción.
- **Fuentes de ingresos:** Las principales fuentes de ingresos son los acuerdos comerciales con las compañías de seguros, las licencias de uso del sistema, tarifas por servicios

adicionales, y un sistema de ingresos vía cuota por póliza con este sistema incluido. Además, se ofrece un sistema de ingresos por actualización de licencia y versión cada año al renovar la póliza.

- **Actividades clave:** Las actividades clave incluyen la presentación del sistema a las aseguradoras, la adaptación a los requisitos y políticas de las compañías (manejo de datos sensibles, la forma en que se generan los informes de actividad del conductor, etc.), y la formación y capacitación de los empleados de las compañías aseguradoras en el uso y funcionamiento del sistema.
- **Recursos clave:** Los recursos clave incluyen la protección intelectual (marca, logo, algoritmo, modelo de utilidad), el equipo de desarrollo de software, data scientists y expertos en ciberseguridad, el sistema de Deep Learning para la detección de cansancio, y un equipo técnico muy especializado para gestionar los datos generados por la aplicación sobre hábitos de conducción de los clientes.
- **Socios clave:** Los socios clave son las compañías de seguros, y organizaciones como CESVIMAP y Centro Zaragoza. CESVIMAP (Centro de Experimentación y Seguridad Vial MAPFRE) y Centro Zaragoza son instituciones de investigación en seguridad vial y reparación de vehículos, respectivamente. Su experiencia y conocimiento en el campo, junto con sus fuertes relaciones con las compañías de seguros, los convierten en socios esenciales para el desarrollo, mejora y adopción de nuestro sistema de alerta al conductor. Su respaldo podría aumentar la credibilidad y la aceptación de nuestro sistema en el mercado.
- **Estructura de costes:** Al igual que en los modelos anteriores, la estructura de costes incluye los costes asociados al inicio de la empresa como el registro de la marca, los costes del equipo de programación, los salarios del equipo técnico, los costes de las instalaciones de oficinas, los costes de desarrollo del sistema, y los costes de marketing y publicidad.

## 5.4. Conclusiones del capítulo

A lo largo de este capítulo, se han explorado tres modelos de negocio viables para la comercialización del sistema de detección de cansancio. Cada uno de estos modelos presenta una estrategia única para crear, entregar y capturar valor, y todos ellos tienen el potencial de ser rentables y sostenibles a largo plazo.

El primer modelo, basado en una aplicación móvil por suscripción, ofrece una solución

directa y accesible para los conductores individuales y profesionales. Este modelo proporciona una herramienta activa para mejorar la seguridad en la carretera y minimizar el riesgo de accidentes por fatiga al volante. El segundo modelo, que implica la integración del sistema en el software de los vehículos, añade un componente de seguridad significativo y aumenta el valor y atractivo de los vehículos para los consumidores conscientes de la seguridad. El tercer modelo, que implica una colaboración con las compañías de seguros, ofrece una solución que beneficia tanto a las aseguradoras como a los conductores. Este modelo permite a las aseguradoras optimizar sus modelos de riesgo y costes, mientras que proporciona un incentivo tangible a los conductores para adoptar una conducción segura.

Es importante destacar que estos modelos no son mutuamente excluyentes. De hecho, podrían combinarse de varias maneras para maximizar el valor y la rentabilidad del sistema. Por ejemplo, la aplicación móvil podría ofrecerse en colaboración con las aseguradoras, proporcionando licencias a sus clientes como parte de sus pólizas de seguro. Del mismo modo, el sistema integrado en el vehículo podría ofrecerse en combinación con la aplicación móvil, y de esta manera poder alcanzar tanto a usuarios que tengan vehículos antiguos como a los que desean comprar un vehículo con sistemas innovadores incorporados como la detección de somnolencia.

En resumen, este capítulo ha demostrado que el sistema de detección de cansancio no sólo es valioso desde el punto de vista de la seguridad vial, sino que también ofrece oportunidades comerciales significativas. A través de una estrategia de comercialización bien pensada, este sistema tiene el potencial de mejorar la seguridad en la carretera, salvar vidas y generar ingresos sostenibles.

## Capítulo 6

# Conclusiones y Trabajos Futuros

Este trabajo ha planteado el desarrollo y evaluación de un sistema de detección de fatiga basado en técnicas de computer vision y Deep Learning. La motivación principal detrás de este proyecto fue contribuir a la mejora de la seguridad vial al proporcionar una herramienta eficiente y precisa para detectar la somnolencia en los conductores en tiempo real.

Una de las contribuciones significativas de este trabajo ha sido la construcción de una base de datos propia, que permitió entrenar y evaluar el modelo de detección de fatiga en condiciones más realistas y representativas de situaciones reales como puede ser la conducción nocturna. Este enfoque aseguró la diversidad y calidad de las imágenes utilizadas, lo que resultó en un modelo más robusto y confiable. Sin embargo, se propone ampliar la base de datos con conductores de distintos perfiles para mejorar la habilidad de generalizar del modelo.

El preprocesamiento de los datos desempeñó un papel fundamental en el éxito del sistema. Se implementaron técnicas específicas para manejar imágenes oscuras, lo que permitió que el modelo funcionara de manera efectiva en diferentes condiciones de iluminación. Además, se tuvo en cuenta la velocidad de procesamiento para garantizar que el sistema pudiera funcionar en tiempo real al recortar las imágenes a una dimensión menor incluyendo solo la cara, lo cual es esencial para su aplicación práctica en vehículos.

Se obtuvieron resultados prometedores con un accuracy del 91.22 % en los datos de prueba, mostrando una gran capacidad de detección y clasificación de los niveles de somnolencia. Además, el modelo de clasificación ha logrado una alta precisión y recall en las clases "alerta" y "ligeramente cansado". Sin embargo, se han identificado áreas de mejora en la clasificación de la clase "muy cansado", lo que indica la necesidad de ajustar los umbrales de clasificación y mejorar la capacidad de distinguir este nivel de somnolencia.

Es importante destacar que este trabajo no solo se ha centrado en el desarrollo del modelo de detección de fatiga, sino también en su aplicación práctica. Se ha propuesto un enfoque de procesamiento por lotes de 10 segundos para tomar decisiones basadas en un intervalo de tiempo más amplio, lo que mejora la eficiencia del sistema y reduce los falsos positivos causados por eventos breves o inesperados.

En términos de aplicación real, se han explorado diferentes enfoques de integración del sistema en el mercado. La opción de ofrecerlo como una aplicación móvil independiente brinda flexibilidad y accesibilidad, mientras que la integración directa con los vehículos implica la colaboración con fabricantes automotrices y la adaptación a los requisitos específicos de cada modelo de vehículo. Además, la colaboración con empresas aseguradoras podría incentivar el uso del sistema al ofrecer beneficios, como reducción de primas, a los clientes que lo utilicen.

En cuanto a los futuros pasos, hay varias direcciones prometedoras que podrían explorarse para mejorar y expandir el sistema de detección de fatiga. En primer lugar, es esencial abordar las preocupaciones sobre la privacidad y seguridad de los datos. Dado que el sistema utiliza imágenes de los conductores, se maneja información potencialmente sensible. Por lo tanto, es crucial investigar y aplicar métodos robustos para proteger la información y mantener la confidencialidad de los datos. Esto podría implicar el uso de técnicas de encriptación avanzadas, el desarrollo de políticas de uso y almacenamiento de datos claras y transparentes, y la implementación de medidas de seguridad física y digital para proteger los datos contra el acceso no autorizado.

En segundo lugar, se podría considerar la posibilidad de combinar las técnicas de visión artificial con modelos biológicos para mejorar la detección de la fatiga. Los modelos biológicos, que utilizan señales del conductor como los datos de un electroencefalograma, pueden proporcionar información valiosa incluso antes de que haya señales visuales evidentes de cansancio. Por ejemplo, se podría explorar la implementación de un sistema híbrido utilizando una tecnología similar al propuesto en el estudio ??, que ha desarrollado un volante inteligente capaz de capturar estas señales biológicas. Este enfoque podría mejorar la precisión y la anticipación de la detección de la fatiga, lo que a su vez podría mejorar la seguridad en la carretera.

Finalmente, el sistema de detección de fatiga podría integrarse con vehículos semi-autónomos o autónomos. En este escenario, si se detecta que el conductor está cansado, el sistema autónomo podría tomar el control del vehículo para prevenir posibles accidentes. Esta aplicación podría ser especialmente valiosa en el contexto de los avances actuales en la tecnología de vehículos autónomos, y podría representar una importante contribución a la seguridad y eficiencia de estos sistemas.

En resumen, este trabajo ha demostrado que el uso de técnicas de computer vision y Deep Learning, como las redes neuronales convolucionales (CNN), puede brindar soluciones efectivas para la detección de fatiga en conductores. El sistema desarrollado ha mostrado un rendimiento prometedor, pero también se han identificado áreas de mejora, como la precisión en la clasificación de diferentes niveles de somnolencia. Además, hay varias direcciones para futuros trabajos que podrían mejorar aún más su eficacia y aplicabilidad. Con ajustes adicionales, la consideración de aplicaciones prácticas y la continua investigación y desarrollo, el sistema tiene el potencial de ser una herramienta valiosa para mejorar la seguridad vial y prevenir accidentes relacionados con la fatiga del conductor.

# Apéndice A

## Repositorio de Código

### A.1. Introducción al repositorio

Se ha facilitado un repositorio en GitHub que contiene el código realizado en este trabajo en el siguiente enlace: [https://github.com/carlotala/TFG\\_BA\\_project\\_code](https://github.com/carlotala/TFG_BA_project_code).

El propósito del repositorio es proporcionar acceso al código fuente necesario para replicar y extender el trabajo realizado en la realización de este TFG. Además, facilita el acceso a los modelos entrenados para su uso en la detección de somnolencia en conductores.

### A.2. Estructura del repositorio

El repositorio incluye un archivo “README” que proporciona una explicación detallada sobre cada uno de los archivos que incluye, así como instrucciones paso a paso sobre cómo utilizarlos. A continuación, se hace una breve explicación de los principales archivos de código fuente que se encuentran en el repositorio:

- “data\_preprocess.ipynb”: Este archivo de notebook de Jupyter tiene la función de cargar y preprocesar los datos para su uso en los modelos de clasificación. Lee los datos del directorio ‘/data’ y almacena por un lado las imágenes procesadas en el directorio ‘/data/images/sample’ y por otro lado la tabla con las características extraídas en el directorio ‘data/features/processed’.
- “model\_workflow.ipynb”: En este notebook se implementa y entrena el modelo de

visión artificial para la clasificación de niveles de somnolencia, y se proporciona un análisis de los resultados.

Asimismo, se incluye un archivo “requirements.txt” que enumera todas las dependencias necesarias para ejecutar el proyecto. Es esencial asegurarse de tener estas dependencias instaladas en el entorno de desarrollo antes de ejecutar el código. También se proporciona una carpeta con el modelo entrenado disponible como fichero ‘.h5’.

Para utilizar este código, se recomienda clonar el repositorio en la máquina local y abrir los notebooks de Jupyter en un entorno Python con las bibliotecas requeridas instaladas. En cada archivo se encuentran las instrucciones para cargar los datos, entrenar los modelos y analizar los resultados.



# Referencias

- Albadawi, Y., Takruri, M., y Awad, M. (2022). A review of recent developments in driver drowsiness detection systems. *Sensors*, 22(5). Descargado de <https://www.mdpi.com/1424-8220/22/5/2069> doi: 10.3390/s22052069
- Babusiak, B., Hajducik, A., Medvecky, S., Lukac, M., y Klarak, J. (2021, Aug). Design of smart steering wheel for unobtrusive health and drowsiness monitoring. *Sensors*, 21(16), 5285. doi: 10.3390/s21165285
- Datahacker.rs. (2020, Jun). *011 How to detect eye blinking in videos using dlib and OpenCV in Python*. <https://datahacker.rs/011-how-to-detect-eye-blinking-in-videos-using-dlib-and-opencv-in-python/>.
- DGT. (2022a). Avance de las principales cifras de la siniestralidad vial españa 2021.
- DGT. (2022b, Nov). *Conducir con fatiga*. <https://www.dgt.es/muevete-con-seguridad/evita-conductas-de-riesgo/conducir-con-fatiga/#:~:text=La%20fatiga%20se%20relaciona%20con,aparici%C3%B3n%20o%20potenciar%20sus%20efectos>.
- EU. (2021). *Regulation of the european parliament and of the council on the general safety of motor vehicles, and repealing regulation (ec) no 661/2009 and directive 2007/46/ec*. [https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=PI\\_COM:Ares\(2021\)1075107&rid=11](https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=PI_COM:Ares(2021)1075107&rid=11).
- InterRegs. (2021, Sept). *InterRegs Spotlight: EU Regulation on Driver Drowsiness and Attention Warning Systems Published*. <https://www.interregs.com/articles/spotlight/eu-regulation-on-driver-drowsiness-and-attention-warning-systems-published-000233>.
- Le, K. (2021, Mar). *An overview of VGG16 and NiN models*. <https://medium.com/mlearning-ai/an-overview-of-vgg16-and-nin-models-96e4bf398484>.
- Moessinger, M., Stürmer, R., y Mühlensiep, M. (2021, 01). Auditive beta stimulation as a countermeasure against driver fatigue. *PLoS ONE*, 16. doi: 10.1371/journal.pone.0245251
- Pokhrel, S. (2019, Dec). Beginners Guide to Convolutional Neural Networks - Towards Data Science. *Towards Data Science*. <https://towardsdatascience.com/beginners-guide-to-understanding-convolutional-neural-networks>

-ae9ed58bb17d.

Pratama, B. G., Ardiyanto, I., y Adji, T. B. (2017). A review on driver drowsiness based on image, bio-signal, and driver behavior. *2017 3rd International Conference on Science and Technology - Computer (ICST)*, 70-75.

Volvo Car Corporation. (2007, Aug). *Volvo cars introduces new systems for alerting tired and distracted drivers*. <https://www.media.volvocars.com/us/en-us/media/pressreleases/12130>.

Zhang, L., Saito, H., Yang, L., y Wu, J. (2022). Privacy-preserving federated transfer learning for driver drowsiness detection. *IEEE Access*, 10, 80565-80574. doi: 10.1109/ACCESS.2022.3192454