



**Universidad
Europea**

UNIVERSIDAD EUROPEA DE MADRID

ESCUELA DE ARQUITECTURA, INGENIERÍA Y DISEÑO

GRADO EN INGENIERÍA MATEMÁTICA APLICADA AL ANÁLISIS DE

DATOS

PROYECTO FIN DE GRADO

**DETECCIÓN DE ACCIDENTES DE TRÁFICO EN
TIEMPO REAL MEDIANTE REDES NEURONALES
CONVOLUCIONALES**

PABLO NEIRA VOCES

Dirigido por

CARLOS RAMÍREZ LIZÁN

CURSO 2021-2022

Pablo Neira Voces

TÍTULO: DETECCIÓN DE ACCIDENTES DE TRÁFICO EN TIEMPO REAL MEDIANTE REDES NEURONALES CONVOLUCIONALES.

AUTOR: PABLO NEIRA VOCES.

TITULACIÓN: GRADO EN INGENIERÍA MATEMÁTICA APLICADA AL ANÁLISIS DE DATOS.

DIRECTOR/ES DEL PROYECTO: CARLOS RAMÍREZ LIZÁN.

FECHA: MAYO DE 2022.

RESUMEN

Los accidentes de tráfico suponen una de las principales causas de muerte a nivel mundial. Sobre esto, gobiernos estatales y autoridades sanitarias han reflexionado en múltiples ocasiones intentando prevenir esta problemática. No obstante, las mejoras son leves, si es que existen.

En este contexto, este proyecto pretende orientar el problema desde un enfoque revolucionario basado en disminuir los daños ocasionados por los accidentes de tráfico, ya que, se considera que la prevención de los mismos es una labor complicada. Además, los proyectos con este foco no están generando resultados. Por este motivo, se han empleado las tecnologías que ofrece la inteligencia artificial con el objetivo de lograr identificar de forma automática y en tiempo real los accidentes de tráfico. Para ello, se ha aplicado la detección de objetos, basada en el aprendizaje profundo para entrenar una red neuronal que lleve a cabo esta funcionalidad.

Todo esto pretende emplearse con el fin de reducir los tiempos de espera de atención sanitaria a las víctimas de accidentes de tráfico. De esta forma, con total seguridad se reducirá el impacto mortal de los mismos, considerando que la consecución de estos sucesos es inevitable.

Palabras clave: inteligencia artificial, detección de objetos en tiempo real, redes neuronales, accidente, demora en la atención sanitaria.

ABSTRACT

Traffic accidents are one of the leading causes of death worldwide. Governments and health authorities have thought about this on many occasions in an attempt to prevent this problem. However, improvements are slight, if they exist at all.

In this context, this project aims to address the problem from a revolutionary approach based on reducing the damage caused by traffic accidents, since the prevention of such accidents is considered to be a complicated task. Moreover, projects with this goal are not generating results. For this reason, the technologies offered by artificial intelligence have been used with the aim of automatically identifying traffic accidents in real time. Therefore, object detection based on deep learning has been applied to train a neural network to carry out this functionality.

All of this is intended to be used in order to reduce waiting times for health care for victims of traffic accidents. In this way, the deadly impact of these accidents will certainly be reduced, considering that the occurrence of these events is inevitable.

Keywords: artificial intelligence, real-time object detection, neural networks, accident, healthcare delay.

AGRADECIMIENTOS

En primer lugar, me gustaría agradecer a mi tutor Carlos por su apoyo constante y por permitirme aprender de su experiencia, ha sido un guía excelente y una parte fundamental de este estudio. Ha sabido interpretar perfectamente la idea que le transmití y eso ha propiciado que este proyecto se haya desarrollado con mucha ilusión, gracias.

También me gustaría agradecer a mis amigos y seres cercanos cuyo apoyo ha sido fundamental a lo largo de toda la carrera. En especial a mis padres y abuelos, gracias a ellos soy la persona que soy hoy.

Por último, agradecer a todos los profesores, compañeros y en general, a todas las personas que han formado parte de esta etapa de mi vida, gracias a todos.

Cita - frase célebre / Dedicatoria

“Las especies que sobreviven no son las más fuertes, ni las más rápidas, ni las más inteligentes; sino aquellas que se adaptan mejor al cambio.”

Charles Darwin

TABLA RESUMEN

	DATOS
Nombre y apellidos:	Pablo Neira Voces
Título del proyecto:	Detección de accidentes de trabajo mediante redes neuronales
Directores del proyecto:	Carlos Ramírez Lizán
El proyecto se ha realizado en colaboración de una empresa o a petición de una empresa:	NO
El proyecto ha implementado un producto: (esta entrada se puede marcar junto a la siguiente)	SÍ
El proyecto ha consistido en el desarrollo de una investigación o innovación: (esta entrada se puede marcar junto a la anterior)	NO
Objetivo general del proyecto:	Visualizar una imagen en tiempo real y ser capaz de identificar cuando ocurre un accidente

Índice

RESUMEN	3
ABSTRACT	4
TABLA RESUMEN	7
Capítulo 1. RESUMEN DEL PROYECTO	13
1.1 Contexto y justificación	13
1.2 Planteamiento del problema	13
1.3 Objetivos del proyecto	13
1.4 Resultados obtenidos	13
1.5 Estructura de la memoria	13
Capítulo 2. ANTECEDENTES / ESTADO DEL ARTE	15
2.1 Estado del arte	15
2.2 Contexto y justificación	28
2.3 Planteamiento del problema	30
Capítulo 3. OBJETIVOS	32
3.1 Objetivos generales	32
3.2 Objetivos específicos	32
3.3 Beneficios del proyecto	32
Capítulo 4. DESARROLLO DEL PROYECTO	34
4.1 Planificación del proyecto	34
4.2 Descripción de la solución, metodologías y herramientas empleadas	41
4.3 Recursos requeridos	55
4.4 Presupuesto	58
4.5 Viabilidad	58
4.6 Resultados del proyecto	59

Capítulo 5.	DISCUSIÓN	75
Capítulo 6.	CONCLUSIONES	76
6.1	Conclusiones del trabajo	76
6.2	Conclusiones personales	77
Capítulo 7.	FUTURAS LÍNEAS DE TRABAJO	78
Capítulo 8.	REFERENCIAS	79
Capítulo 9.	ANEXOS	83

Índice de Figuras

Figura 1. Tipos de aprendizaje automático.	16
Figura 2. Diferencia entre Inteligencia Artificial, Aprendizaje Automático y Deep Learning.	17
Figura 3. Explicación visual de la funcionalidad de la visión artificial.	18
Figura 4. Esquema de una neurona.	19
Figura 5. Tipos de función de activación	20
Figura 6. Visualización del proceso de convolución.	22
Figura 7. Submuestreo con Max-Pooling	23
Figura 8. Arquitectura de una red neuronal convolucional.	24
Figura 9. Desarrollo matemático de una neurona.	25
Figura 10. Proceso de una red neuronal.	26
Figura 11. Proceso de la detección de objetos	27
Figura 12. Fallecidos en el mundo por accidentes de tráfico.	28
Figura 13. Distribución por fases de las muertes en accidentes de tráfico.	29
Figura 14. Distribución de la variable “tipo_lesividad”.	44
Figura 15. Valores nulos por variable en el dataset de accidentes.	45
Figura 16. Valores nulos por variable en el dataset de activaciones	46
Figura 17. Resultado de la creación de la variable “fecha” en el dataset de activaciones.	47
Figura 18. Automatización de descarga de los vídeos.	48
Figura 19. Proceso de extracción de “frames”.	49
Figura 20. Ejemplo de “frame” extraído.	49
Figura 21. Interfaz gráfica de la herramienta “LabelIMG”.	50
Figura 22. Ejemplo de archivo de entrada a la red neuronal.	50
Figura 23. Arquitectura de una “SSD Mobile Net”.	52
Figura 24. Arquitectura de una “EfficientDet D7”.	53
Figura 25. Arquitectura de una “CenterNet”.	53
Figura 26. Ejemplo de resultado de la red neuronal.	54
Figura 27. Accidentes en función del estado meteorológico.	59
Figura 28. Accidentes en función de la hora y damnificado.	60
Figura 29. Activaciones de emergencias en función de la hora.	61
Figura 30. Accidentes en función de la hora y el sexo.	61

Figura 31. Accidentes en función de la hora y la atención sanitaria.	62
Figura 32. Accidentes según la edad.	63
Figura 33. Accidentes por vehículo y sexo.	63
Figura 34. Comportamiento de la demora para la atención sanitaria a las víctimas.	64
Figura 35. Accidentes por distritos de Madrid.	65
Figura 36. Activaciones de emergencia por distrito.	65
Figura 37. Calles con mayor número de accidentes.	66
Figura 38. Traslados en función del hospital.	67
Figura 39. Mapa de la accidentalidad de Madrid.	68
Figura 40. Cuadro de mandos de activaciones de emergencia.	69
Figura 41. Cuadro de mandos de accidentes en Madrid.	70
Figura 42. Evolución del “MAP”.	72
Figura 43. Evolución del “Recall”.	72
Figura 44. Evolución de la pérdida.	73
Figura 45. Resultados de la evaluación.	73

Índice de Tablas

Tabla 1. Planificación del proyecto.	34
Tabla 2. Diagrama de Gantt del proyecto.	38
Tabla 3. Variables del dataset de accidentes de tráfico de Madrid.	41
Tabla 4. Variables del dataset de activaciones de emergencia de Madrid.	43
Tabla 5. Variables descartadas en el dataset de accidentes de tráfico.	45
Tabla 6. “LabelMap” de la red neuronal.	51
Tabla 7. Presupuesto del proyecto.	58
Tabla 8. Resultados del modelo.	71

Capítulo 1. RESUMEN DEL PROYECTO

1.1 Contexto y justificación

La Dirección General de Tráfico cuenta con más de 300 cámaras distribuidas por la Comunidad de Madrid encargadas de monitorizar la vigilancia de las carreteras. El histórico de imágenes captadas por estas cámaras podría ser utilizado para el desarrollo de modelos de Inteligencia Artificial mediante los que automatizar procesos, por ejemplo la detección de accidentes.

1.2 Planteamiento del problema

La cuestión que se tratará en este proyecto y que se intentará solucionar será la demora en la atención a las víctimas de accidentes de tráfico mediante la construcción de una red neuronal para la detección automática de los mismos.

1.3 Objetivos del proyecto

El objetivo general es conseguir automatizar el proceso de la identificación de accidentes de tráfico. Más específicamente, se pretende disminuir el número de víctimas mortales provocadas por estos sucesos, reducir costes derivados del personal encargado del proceso actual y digitalizar el sector.

1.4 Resultados obtenidos

Se ha conseguido construir un sistema capaz de detectar automáticamente accidentes de tráfico en tiempo real. Este está basado en la detección de objetos a partir de redes neuronales convolucionales. En este aspecto, se han entrenado diferentes algoritmos y se han evaluado los resultados con el fin de seleccionar el modelo óptimo. Antes de ello, se ha podido desarrollar un análisis de la accidentalidad de Madrid, con el fin de encontrar las ubicaciones óptimas para la instalación del sistema.

1.5 Estructura de la memoria

La estructura de la memoria se compone de los siguientes apartados:

Capítulo 1. RESUMEN DEL PROYECTO. En este primer punto se aborda un resumen general del proyecto, así como el contexto y justificación, planteamiento del problema, objetivos y resultados.

Capítulo 2. ANTECEDENTES/ESTADO DEL ARTE. En este apartado se hablará del estado del arte, y se tratarán con más detalle el contexto y la justificación así como el planteamiento del problema.

Capítulo 3. OBJETIVOS. En esta sección se especificarán tanto los objetivos generales como los específicos, además de los beneficios del proyecto.

Capítulo 4. DESARROLLO DEL PROYECTO. Se hablará de la planificación del proyecto, la descripción de la solución, los recursos requeridos, el presupuesto y el análisis de viabilidad.

Capítulo 5. DISCUSIÓN. Se discutirán los resultados del proyecto y se tratarán las diversas limitaciones encontradas durante el desarrollo del mismo.

Capítulo 6. CONCLUSIONES. Se detallan las conclusiones obtenidas tanto del proyecto como a nivel personal.

Capítulo 7. FUTURAS LÍNEAS DE TRABAJO. Se presentan los pasos a seguir con este proyecto para la maximización de su rendimiento y la implementación de mejoras.

Capítulo 8. REFERENCIAS.

Capítulo 9. ANEXOS.

Capítulo 2. ANTECEDENTES / ESTADO DEL ARTE

2.1 Estado del arte

En este punto se explicarán conceptos necesarios para el entendimiento del proyecto, así como técnicas y tecnologías empleadas para el desarrollo del mismo.

2.1.1 Inteligencia Artificial

Definición

La inteligencia artificial es la rama de la ciencia que se encarga del estudio del aprendizaje automático en máquinas y, desde el punto de vista de la ingeniería, propone la creación de sistemas que posean un comportamiento inteligente. Dicho de otra manera, la IA pretende construir sistemas que presenten un comportamiento similar al que presenta un ser humano, es decir, que presenta racionalidad (sistemas que piensan y actúan racionalmente) y humanidad (sistemas que piensan y actúan como humanos). Otras facetas relacionadas con este tipo de comportamiento son el aprendizaje, la capacidad de adaptación a entornos cambiantes o la creatividad. [3]

Historia

La exploración inicial de la Inteligencia Artificial tuvo lugar en la década de 1950 y exploraba temas como la resolución de problemas. En la década de 1960 el Departamento de Defensa de los Estados Unidos mostró interés en este tipo de trabajo y comenzó a entrenar computadoras para que imitaran el razonamiento humano básico. Por ejemplo, la DARPA (“Defense Advanced Research Projects Agency”) realizó proyectos de planimetría de calles en la década de 1970 y en 2003 produjo asistentes virtuales inteligentes. Este trabajo inicial abrió el camino para la automatización y el razonamiento actual de las computadoras. [4]

Aprendizaje automático

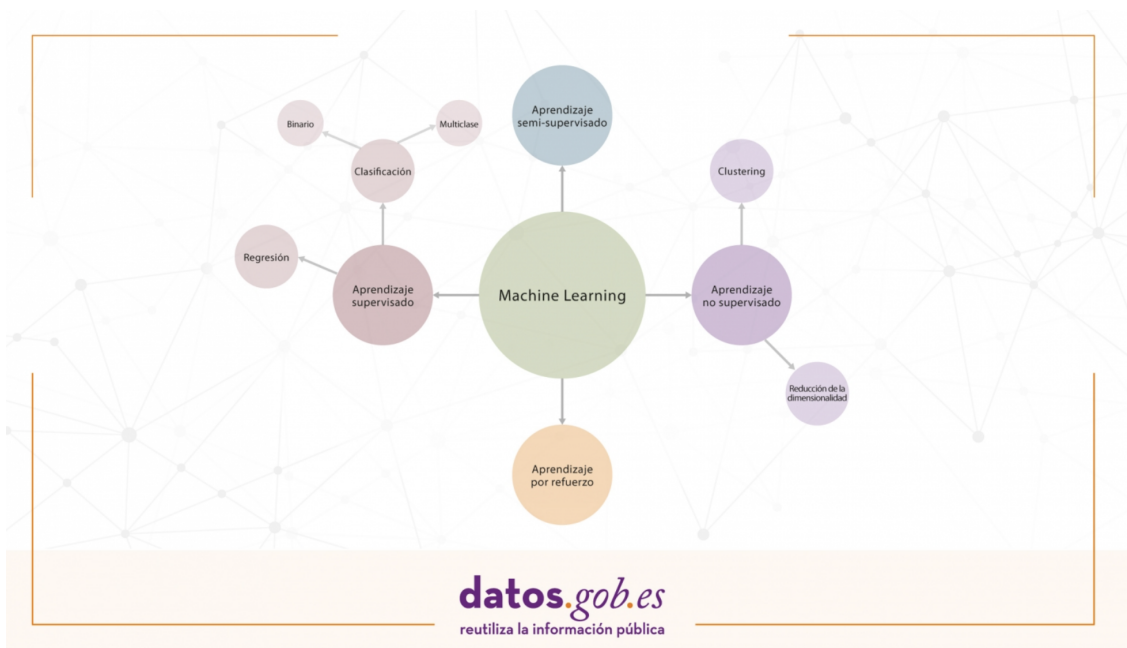
El aprendizaje automático es una rama de la IA que se basa en el uso de datos y algoritmos para simular la forma en la que aprenden los seres humanos, con una mejora gradual de su precisión. Este es un componente importante del creciente campo de la ciencia de datos y por tanto, de este proyecto. [5]

El modelo de la detección automática de accidentes será desarrollado a partir de un aprendizaje basado en la experiencia, por lo que se relaciona directamente con este concepto. UC Berkeley divide este proceso de aprendizaje de un algoritmo en tres partes: [5][6]

1. **Proceso de decisión.** Una serie de cálculos u otros pasos que a partir de los datos identifica qué patrón siguen los mismos.
2. **Función de error.** Evalúa la precisión que ha tenido el modelo comparándola con ejemplos conocidos, en caso de que existan.

3. **Proceso de optimización.** Un método a partir del cual el algoritmo examina el fallo para posteriormente actualizar la forma en que el proceso toma la decisión final, de modo que la próxima vez el error sea inferior.

Figura 1. Tipos de aprendizaje automático.



Fuente: datos.gob.es, (2020).

Existen distintos tipos de aprendizaje dependiendo de los datos disponibles y la tarea que se vaya a abordar: [5][7]

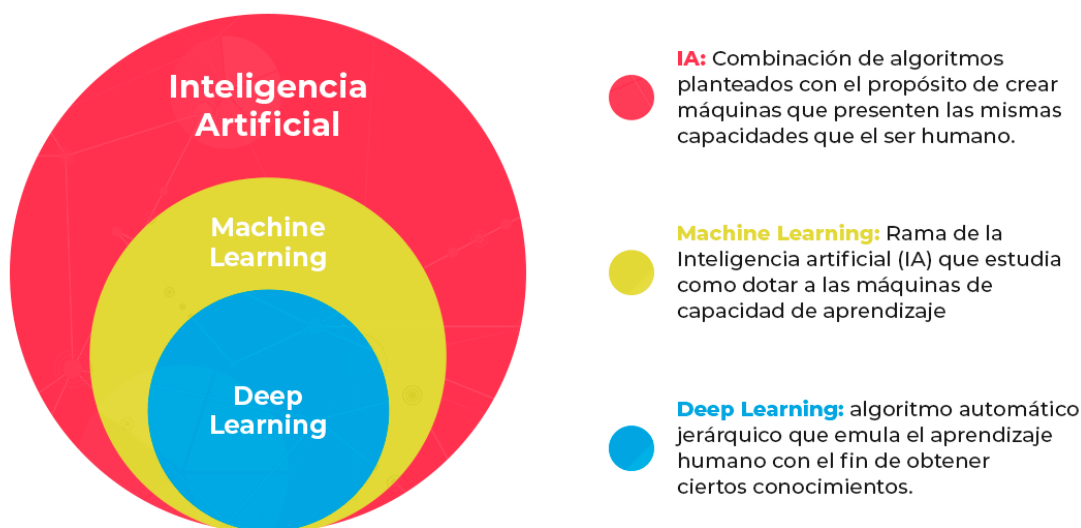
- **Aprendizaje supervisado.** Necesita conjuntos de datos etiquetados, es decir, se conoce el resultado correcto para cada dato de entrada. En función del tipo de etiqueta se puede aplicar en problemas de clasificación (la salida del modelo es una etiqueta discreta) o de regresión (el modelo produce como salida un valor real y continuo).
- **Aprendizaje no supervisado.** Este tipo trabaja con datos que no han sido etiquetados, es decir, no existe una etiqueta que predecir. Estos algoritmos se usan principalmente en tareas donde es necesario analizar los datos para extraer nuevo conocimiento o agrupar entidades por afinidad.
- **Aprendizaje semi-supervisado.** Ofrece un punto intermedio entre el aprendizaje supervisado y no supervisado. Durante el entrenamiento, utiliza un conjunto de datos etiquetados más pequeño para guiar la clasificación y la extracción de características de un conjunto de datos sin etiquetar de mayor tamaño.
- **Aprendizaje por refuerzo.** Es un método que se basa en recompensar los comportamientos deseados y penalizar los no deseados. Es un aprendizaje basado en la metodología prueba-error que fija objetivos a largo plazo para obtener una recompensa general máxima y así lograr una solución óptima.

Deep learning

El deep learning es un tipo de aprendizaje automático que entrena a una computadora para que realice tareas, imitando el comportamiento de los seres humanos basado en el procesamiento de datos a partir de redes neuronales artificiales, las cuales supondrán una parte fundamental de este proyecto.

Haciendo uso de muchas capas de procesamiento, el deep learning es capaz de reconocer patrones configurando parámetros básicos acerca de los datos. Así, la computadora entrena y aprende por cuenta propia, identificando estos patrones y obteniendo un mayor rendimiento. De esta manera se han podido desarrollar tareas como el reconocimiento de voz, procesamiento del lenguaje natural o como en el caso de este proyecto, detección de objetos en imágenes. [8]

Figura 2. Diferencia entre Inteligencia Artificial, Aprendizaje Automático y Deep Learning.



Fuente: Máster Data Science UCM, 2020.

Computer vision

El término computer vision es un subcampo del aprendizaje automático que se basa en enseñar a las computadoras a “ver” y entender el contenido de las imágenes digitales. Esta es una tarea complicada a nivel computacional. [9]

En general, la tecnología de visión artificial se desarrolla en tres etapas: [10]


- **Adquisición.** Las computadoras tienen un banco diario de más de 3 mil millones de fotos y videos que las personas tomamos con nuestros dispositivos electrónicos, así como las obtenidas de cámaras de vigilancia, procesos de control de calidad y satélites.
- **Procesamiento.** La tecnología del deep learning anteriormente explicada genera modelos analíticos con parámetros específicos para que las computadoras aprendan

datos, identifiquen patrones y, en consecuencia, tomen decisiones con una mínima intervención humana.

- **Explicación.** Según la información obtenida del procesamiento anterior, las computadoras pueden identificar y categorizar objetos que han visto antes e incluso interactuar de manera diferente con cada objeto.

La clave de este proceso es que las imágenes están digitalizadas, lo que significa que están formadas por píxeles, y la computadora asigna un número a cada píxel en función de la intensidad de color o escala de grises disponible. De esta forma, la imagen se convierte en un conjunto de números, a partir de los cuales se crean patrones de identificación. Por tanto, lo que para nosotros significa una afinidad visual para las entidades virtuales es una proximidad numérica. [10]

Figura 3. Explicación visual de la funcionalidad de la visión artificial.



Fuente: Energy, 2021.

Se puede ver de una forma muy nítida en la imagen como con una base en este campo se consigue que la máquina identifique objetos. De esta forma, se podrá aplicar este concepto para detectar accidentes de tráfico.

2.1.3 Redes neuronales

Este concepto supone una parte fundamental del proyecto por lo que se realizará una explicación detallada del mismo a continuación.

Definición

Las redes neuronales, también conocidas como redes neuronales artificiales (ANN) o redes neuronales simuladas (SNN), son un subcampo del aprendizaje automático y constituyen el núcleo de los algoritmos de deep learning. Su nombre y estructura se inspiran en el cerebro humano, al igual que este, está formado por conexiones de neuronas que trabajan

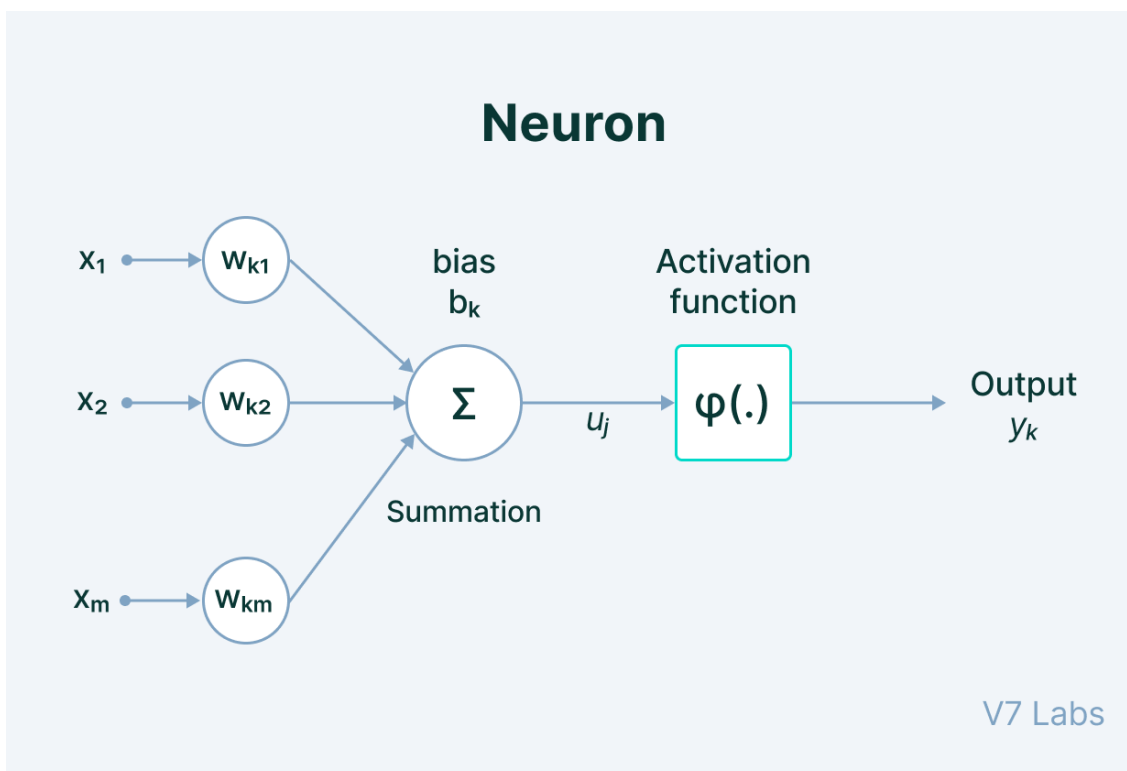
conjuntamente. Una red neuronal artificial está basada en un conjunto interconectado de neuronas artificiales. [11]

Se componen de capas: una capa de entrada, una o más capas ocultas y una capa de salida. Cada neurona, o nodo, se conecta a otro y tiene un peso y un umbral asociados. Se activa un nodo individual si su salida está por encima del valor umbral especificado, enviando datos a la siguiente capa de la red. [11]

Arquitectura

La arquitectura de la red neuronal está formada por unidades individuales llamadas neuronas que, como se ha mencionado, imitan el comportamiento biológico del cerebro. Estos son los distintos componentes de una neurona: [12][13]

Figura 4. Esquema de una neurona.



Fuente: V7labs.com, 2021.

- **Input.** Es el conjunto de características que se introducen en el modelo para el proceso de aprendizaje. Por ejemplo, la entrada en la detección automática de accidentes sería una matriz de valores de píxeles pertenecientes a una imagen.
- **Weight.** Su principal función es dar importancia a las características que más contribuyen al aprendizaje. Para ello, se introduce una multiplicación escalar entre el valor del input y la matriz de pesos.

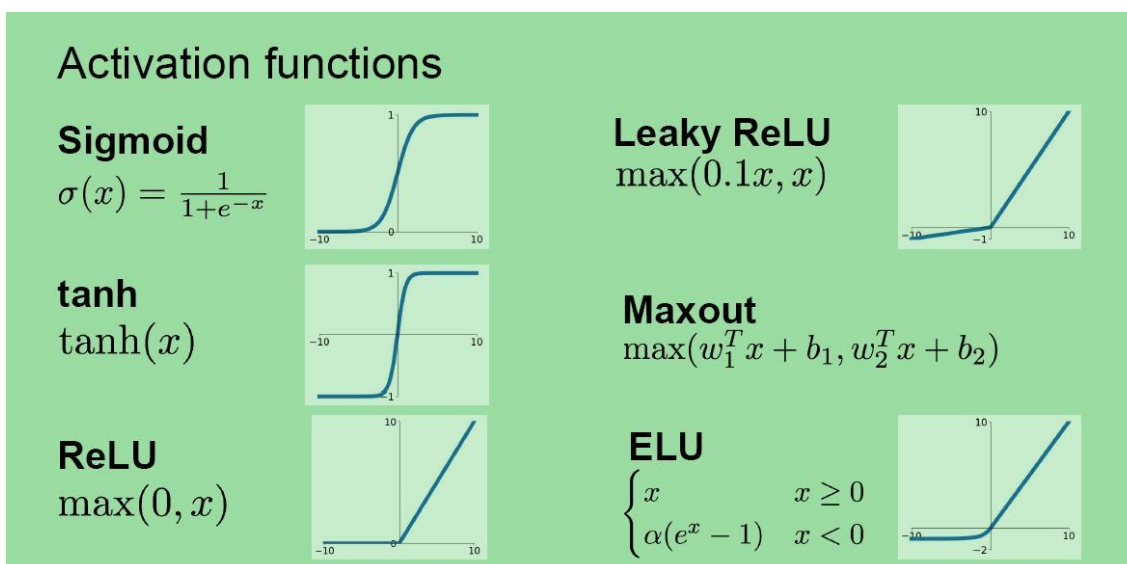
- **Función de activación.** Es una función que transmite la información resultante de la combinación lineal de los pesos y entradas, es decir, la forma de transmitir la información a través de las conexiones de salida.

Inicialmente se utilizaba una “Función de Escalón de Heaviside” con un valor de umbral de 0.5. Esta función producirá un valor real binario (0 o 1), dependiendo de la entrada. La salida de la función de activación es siempre la salida de la neurona y permite hacer una clasificación binaria simple de los valores de entrada. Existe una gran variedad, se detallan a continuación las más utilizadas: [14]

- **Sigmoide.** Genera como salida un número a una escala (0,1).
- **Tangente hiperbólica.** Genera como salida un número a una escala (-1,1).
- **Rectified Linear Unit (ReLU).** Transforma los valores introducidos anulando los negativos y manteniendo los positivos de la misma forma que entraron. Sólo se activa con valores positivos. Comúnmente utilizada en visión artificial.
- **Leaky ReLU.** Transforma los valores introducidos multiplicando los valores negativos por un coeficiente rectificativo y manteniendo los positivos de la misma forma que entraron.
- **Softmax.** Transforma las salidas en una representación de tipo probabilidad, en la que la suma de estas probabilidades tiene “1” como resultado.

En el caso de este proyecto se ha hecho uso de la función de activación ReLU.

Figura 5. Tipos de función de activación



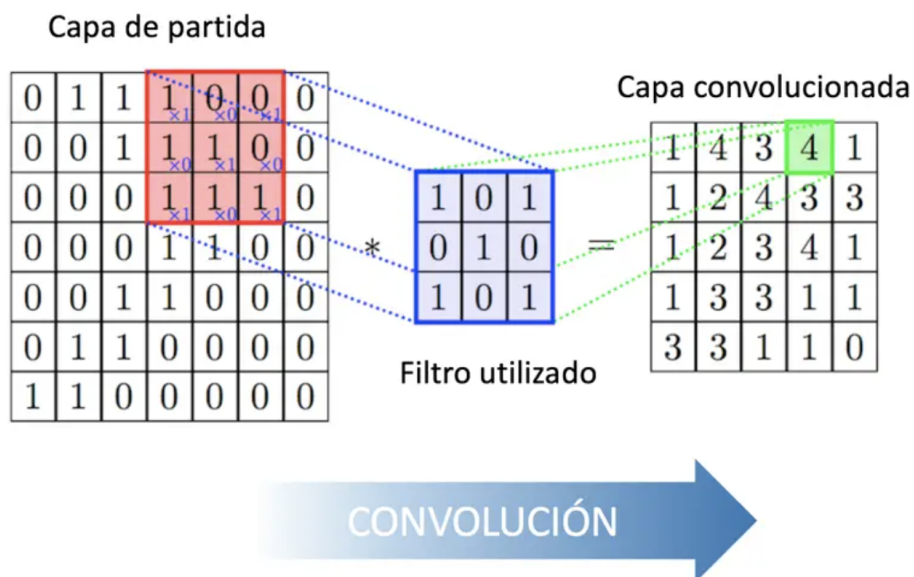
Fuente: Programmerclick.com, 2018.

Redes neuronales convolucionales

Existen diversos tipos de redes neuronales, sin embargo, las convolucionales pretenden simular el funcionamiento del córtex visual del ojo humano para detectar características en las entradas, lo que permite que pueda identificar objetos. Por tanto, se relacionan directamente con la detección de accidentes y se detallarán a continuación. Un concepto a tener en cuenta serán los filtros o “kernel”. Dichos filtros son matrices cuadradas que, al aplicarlas sobre los datos de entrada, consiguen detectar patrones presentes en la imagen original. Se detallará su arquitectura, la cual está basada en el apilamiento de diferentes tipos de capas y procesos según el objetivo deseado: [12][15]

- **Datos de entrada (Píxeles).** Para empezar, la red toma los píxeles de una imagen como entrada. El tamaño y número de neuronas de la capa de entrada dependerá en gran parte de los colores presentes en la imagen. Si la imagen únicamente presenta un color, es decir, es en escala de grises, sólo sería necesario un canal. En caso de que se tuvieran más colores serían necesarios tres canales (rojo, azul y verde). [15]
- **Pre-procesamiento.** Es necesario normalizar los valores de entrada antes de alimentar la red. El valor del píxel está entre 0 y 255, por lo que se transformará para obtener siempre un valor entre 0 y 1. [15]
- **Convoluciones.** Este proceso es el que distingue a las redes neuronales convolucionales. Se basa en tomar grupos cercanos de píxeles y aplicar el producto escalar sobre el kernel y una parte de la matriz de píxeles de entrada del mismo tamaño, obteniendo de esta manera el valor de la matriz de salida en dicha posición. Se repite el proceso desplazando el kernel de arriba a abajo y de izquierda a derecha hasta completar todas las posiciones de la matriz de salida. Con el objetivo de simplificar la convolución se suele aplicar la técnica del “Zero Padding”, la cual consiste en rodear de ceros la zona seleccionada de la matriz de entrada (normalmente los márgenes de la imagen). Esta matriz de salida se conoce como mapa de características y representa los patrones detectados. [15]


Figura 6. Visualización del proceso de convolución.



Fuente: Diego Calvo, 2017.

- **Función de activación.** Tal y como se mencionó anteriormente, la función de activación más común en este tipo de redes neuronales es la ReLU. [15]
- **Submuestreo con Max-Pooling.** Tras una convolución el número de neuronas aumenta considerablemente lo que provoca que si se realizara otra convolución el número de neuronas continuaría creciendo y sería excesivo. Para solucionar esta problemática se lleva a cabo un proceso de submuestreo en el que se reducirá el tamaño de las imágenes filtradas pero manteniendo las características más importantes detectadas por el filtro. Existen varios tipos, pero el más utilizado es el Max-Pooling. Este recorrerá la imagen de arriba a abajo y de izquierda a derecha tomando los píxeles de 2x2 en lugar de un píxel, quedándose con el valor más elevado de esos cuatro píxeles. Con este método se reducirá prácticamente en un cuarto el tamaño de las siguientes capas, preservando las características más importantes. [15]

Figura 7. Submuestreo con Max-Pooling

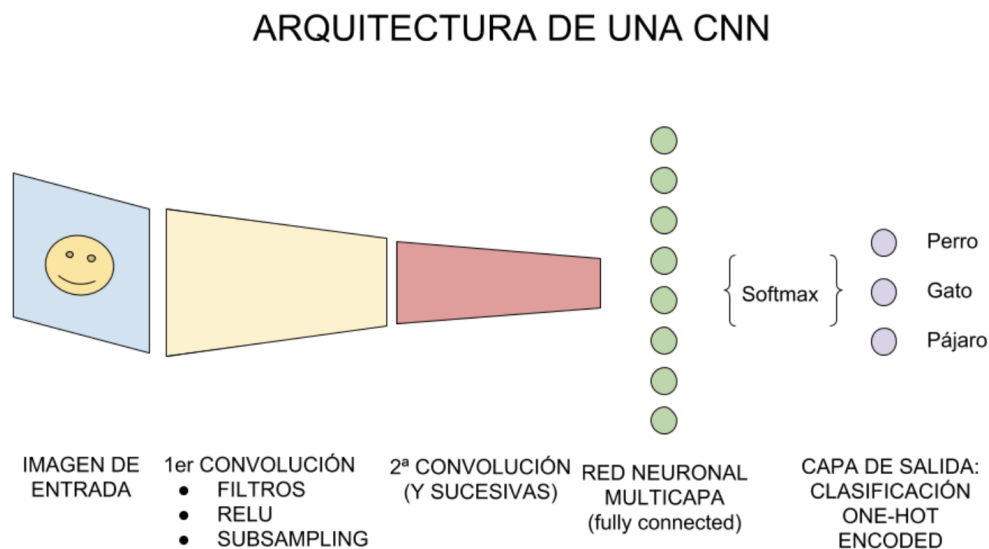


SUBSAMPLING:
Aplico Max-Pooling de 2x2
y reduzco mi salida a la mitad

Fuente: Aprendemachinelearning.com, 2018.

- **Convoluciones sucesivas.** La primera convolución es capaz de detectar líneas o curvas, sin embargo, a medida que aumente el número de convoluciones la red neuronal será capaz de identificar formas más complejas. [15]
- **Red neuronal multicapa.** Se toma la última capa oculta sobre la que se realiza el submuestreo, la cual presenta una especie de estructura tridimensional. Se aplican una serie de transformaciones con el objetivo de eliminar este comportamiento tridimensional, “aplanándola”, y pasa a ser una capa de neuronas “tradicionales”. En este punto, a esta nueva capa “tradicional”, se le aplica una función llamada Softmax la cual se encarga de convertir a probabilidad a las neuronas de salida. [15]

Figura 8. Arquitectura de una red neuronal convolucional.



Fuente: Aprendemachinelarning.com, 2018.

- Backpropagation.** Este concepto corresponde al proceso de aprendizaje de las redes neuronales convolucionales y se basa en optimizar el valor de los pesos de entrada a las neuronas, los cuales son inicializados aleatoriamente, hasta lograr la máxima precisión posible en la salida. Esta optimización es llevada a cabo comparando la salida con el resultado exacto mediante una función de pérdida, para posteriormente aplicar la técnica del gradiente descendente hasta encontrar la combinación de pesos que genere el mejor resultado. [15]

Desarrollo matemático de las redes neuronales

Para un mejor entendimiento de lo explicado anteriormente, se procederá a detallar el desarrollo matemático y demostración del proceso al construir un modelo mediante redes neuronales como el de este estudio. [11]

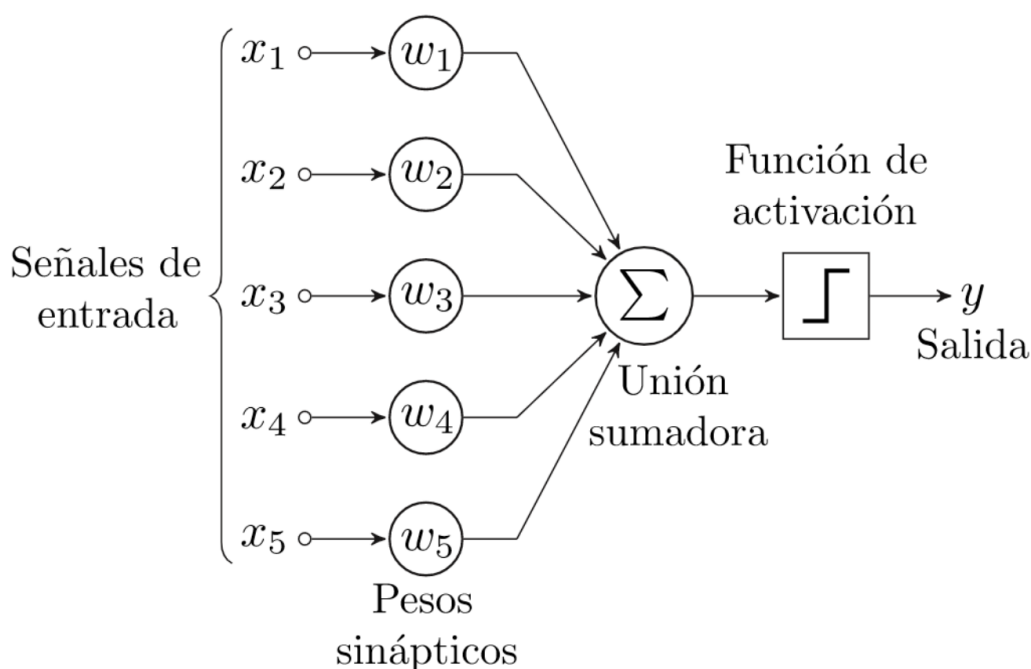
Se supone que cada neurona presenta su propio modelo de regresión lineal, compuesto por unos datos de entrada, pesos, un sesgo y una salida. La fórmula sería: [13]

$$\sum_{i=1}^m w_i x_i + sesgo = w_1 x_1 + w_2 x_2 + w_3 x_3 + sesgo$$

$$salida = f(x) = 1 \text{ si } \sum w_1 x_1 + b \geq 0; 0 \text{ si } \sum w_1 x_1 + b < 0$$

La información que recibe la neurona artificial son variables independientes. Los valores de entrada son multiplicados por sus respectivos pesos anteriormente asignados en función de la importancia de las variables, teniendo las más significativas un peso superior en comparación con otras entradas. Este proceso de multiplicación de las variables por su peso es el descrito en la ecuación anterior y tiene como resultado una combinación lineal de las entradas y los pesos, denominado función de ponderación. [13]

Figura 9. Desarrollo matemático de una neurona.



Fuente: Think Big, 2019.

El siguiente paso, como se ha explicado anteriormente, sería aplicar una función de activación, que como se ha dicho se encarga de transmitir la información resultante de la combinación lineal de los pesos y entradas:


$$\phi\left(\sum_{i=1} x_i * w_i\right)$$

El resultado puede ser la nueva entrada de una neurona, formando las redes neuronales, o puede ser el resultado final. Esta sería la forma de algunas de las funciones de activación descritas anteriormente: [13]

- **Sigmoide.** $\phi(x) = \frac{1}{1+e^{-x}}$
- **Tangente hiperbólica.** $\phi(x) = \frac{1-e^{-2x}}{1+e^{-2x}}$
- **ReLU.** $\phi(x) = \max\{0, x\}$, siendo $x \geq 0$

En resumen, el proceso se podría definir como un grafo. Se determinan unas capas de entrada, se asignan y se aplican los pesos correspondientes a cada variable dando lugar a una combinación lineal de entradas y pesos, se utiliza una función de activación para enviar la información a la siguiente capa y así sucesivamente. [11][13]

Figura 10. Proceso de una red neuronal.



Fuente: Think Big, 2019.

2.1.4 Detección de objetos

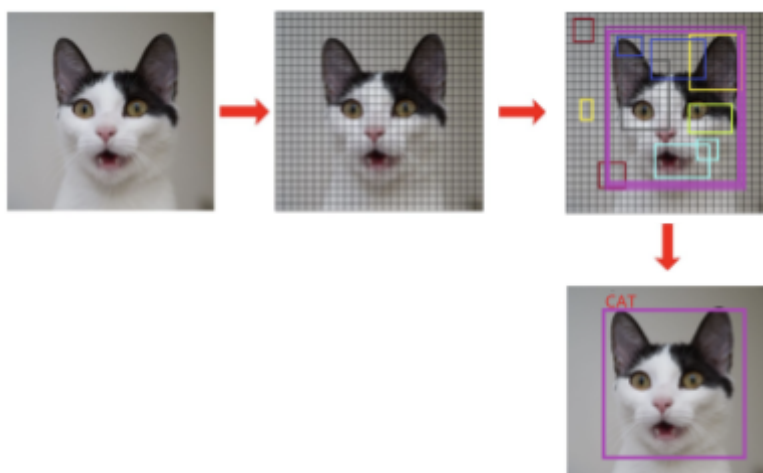
Como se ha introducido anteriormente, la visión artificial (computer vision) es un campo centrado en la automatización y el estudio de tareas de percepción visual. Una de las aplicaciones más útiles, aunque sustancialmente más difíciles de este campo es la detección de objetos. [16]

El objetivo final de la detección de objetos es localizar la posición de los objetos deseados, y encuadrarlos en el momento de procesar una imagen. Para llevar esto a cabo, es necesario entrenar a la máquina indicando la clase del objeto, en este caso accidentes de tráfico, y su posición dentro de la imagen (X, Y, ancho y alto). Para obtener esta localización es necesario llevar a cabo un proceso de etiquetado de imágenes, cuyo resultado será un archivo tipo XML que contará con esta posición. [17]

Por norma general, el proceso de la detección de objetos se lleva a cabo en tres pasos: [18]

1. Genera pequeños segmentos en la imagen de entrada conformando un gran conjunto de cajas de delimitación que abarcan toda la imagen.
2. Se lleva a cabo una extracción de características (“features”) para cada área rectangular segmentada, con el objetivo de detectar si el rectángulo contiene un objeto que reconozca.
3. Las cajas superpuestas se combinan en un único rectángulo delimitador donde se encuentra el objeto.

Figura 11. Proceso de la detección de objetos



Fuente: GreatLearning Blog, 2021.

Una herramienta que permite desarrollar proyectos de este tipo es “TensorFlow Object Detection”, y será la utilizada para este estudio.

2.2 Contexto y justificación

El transporte por carretera beneficia tanto al país como a sus habitantes, facilitando el movimiento de bienes y personas, permitiendo un mejor acceso a los empleos, los mercados económicos, la educación, ocio y atención médica, y por lo tanto tienen, o deberían tener, un efecto positivo en la salud de la población. [1]

Sin embargo, el transporte por carretera se involucra de forma directa con la consecución de accidentes de tráfico, los cuáles son uno de los problemas más graves de la sociedad actual ya que dan lugar a víctimas mortales de forma diaria.

Según la OMS, se estima que los accidentes de tráfico causan más de 3.500 muertes de forma diaria, lo que equivale a 1,3 millones de fallecimientos anuales y se estima por tanto que en la próxima década causarán otras 13 millones de muertes. Además, afirma que esta problemática es la octava causa de muerte en el mundo, siendo la principal en jóvenes de 5 a 29 años. En España se considera como una de las causas principales de muerte no natural, manteniéndose en jóvenes la tendencia mundial [2]. Se puede observar, en el gráfico a continuación, el porcentaje por país de los fallecidos en accidentes de tráfico por cada 100.000 habitantes.

Figura 12. Fallecidos en el mundo por accidentes de tráfico.

La inseguridad de las carreteras

Muertos en accidentes de tráfico por cada 100.000 habitantes (2017)




Gráfico:
Álvaro Merino (2020)
Fuente:
Organización para la Cooperación y el Desarrollo Económicos (2017)



Fuente: El Orden Mundial - EOM, 2020.


Se considera que los accidentes de tráfico son prácticamente inevitables, atribuyéndole en muchas ocasiones la culpabilidad al azar debido a que los factores que los propician son diversos, tales como el consumo de alcohol, el estado del asfalto, errores humanos etc.

El dato proporcionado por la OMS que da valor a este proyecto es que la mayor parte de las lesiones que provocan los accidentes de tráfico no son mortales, siendo las demoras para detectar la necesidad de ofrecer asistencia las que propician que aumente la gravedad de las mismas, ya que según asegura la organización: “Unos pocos minutos de demora pueden bastar para pasar de la vida a la muerte”. Entre 20 y 50 millones de personas sufren traumatismos no mortales que muchos de ellos provocan una discapacidad y que el mencionado retraso en el tratado inmediato de los mismos conllevan la muerte [1].

Las defunciones en los accidentes de tráfico presentan, en el ámbito del tiempo, una característica distribución trifásica: [26]

- **Fase 1.** Tiene lugar en los primeros segundos o minutos tras el accidente, constituye el 10% de todas las muertes y son muy complicados de evitar, ya que son debidos a lesiones severas.
- **Fase 2.** Constituye la primera o segunda hora tras el accidente. Representa el 75% de las muertes y es la fase que se enmarca este estudio, en la que se pueden evitar la mayor parte de los fallecimientos.
- **Fase 3.** Días o semanas tras el accidente. Originan el 15% de las muertes totales y se deben principalmente a complicaciones con el tratamiento.

Figura 13. Distribución por fases de las muertes en accidentes de tráfico.



Fuente: Sanidad.gob.es, 2010.

Este gráfico representa a la perfección el problema a solucionar. En él se puede destacar que la mayoría de las víctimas se producen entre las dos primeras horas desde que tuvo lugar el accidente. Es inevitable pensar que si se reducen al mínimo los tiempos de espera para la atención sanitaria, se podrían evitar gran parte de los fallecimientos.

Además, esto se enmarca en el contexto actual y emergente de ciudades inteligentes o “Smart Cities” derivado de un auge en la digitalización. Una ciudad inteligente es aquella que es capaz de utilizar la tecnología de la información y la comunicación (TIC) con el objetivo de crear una mejor infraestructura para sus ciudadanos. En definitiva, es una combinación de personas, tecnología y creatividad para hacer que cualquier ciudad del mundo sea más sostenible y eficiente. En cierto modo, las “Smart Cities” brindan a los ciudadanos las herramientas para agregar más valor a la ciudad. [22][23]

Un ejemplo es Barcelona, reconocida en 2014 por la Comisión Europea como la capital de la innovación, está considerada como la ciudad inteligente por excelencia. Algunos proyectos que han convertido a la ciudad condal en referente en este campo son por ejemplo su sistema de eliminación de residuos, el cual presenta contenedores inteligentes, o su alumbrado público, el cual está basado en LEDs con el objetivo de disminuir el consumo eléctrico y aumentar la eficiencia energética. [24]

Fuera de España se pueden encontrar ciudades como Londres, la cual según datos de la segunda edición del Índice IESE Cities in Motion (ICIM), elaborado por el Centro de Globalización y Estrategia del “IESE Business School”, se postula como la ciudad más inteligente del mundo. La capital inglesa consigue detectar el problema y explota la información disponible con el fin de maximizar la innovación tecnológica. Para ello, ha desarrollado proyectos como la utilización del río Támesis para la calefacción de los hogares o la creación de una plataforma para el intercambio de servicios entre ciudadanos. [25]

La detección automática de accidentes en tiempo real contribuiría a que municipios como Madrid pudieran maximizar la eficiencia y la innovación tecnológica implementando un sistema presente en ciudades como Nueva York, líder en el marco de las “Smart Cities”.

2.3 Planteamiento del problema

La cuestión que se tratará en este proyecto y que se intentará solucionar será la demora en la atención a las víctimas de accidentes de tráfico mediante la construcción de una red neuronal para la detección automática de los mismos.

La casi totalidad de los accidentes de circulación con resultado de víctimas o cuantiosos daños, suele detectarse por medio de un aviso telefónico. Los servicios sanitarios y de Protección Civil establecen actualmente el protocolo P.A.S de actuación que responde a las siglas proteger, avisar y socorrer. Con esta guía se presenta cada una de las pautas, consejos e instrucciones básicas necesarias de cara a reducir el número de muertes sobre el asfalto. En ella se establece como primer paso proteger, evitar los riesgos, que el alertante no exponga su vida utilizando una correcta señalización, los triángulos de emergencia o el chaleco reflectante. La siguiente acción sería avisar, se recomienda mantener la calma e informar a los servicios de emergencia empleando mensajes cortos. El último paso sería socorrer a la víctima haciendo uso de las técnicas de primeros auxilios si es que presentan el conocimiento, en caso negativo paliar obstrucciones respiratorias y hemorragias. [18]

Por parte de los servicios sanitarios, estos reciben el aviso, extraen toda la información necesaria y evalúan la demanda sanitaria accediendo al sistema. En este tiempo toman decisiones en cuanto a la respuesta sanitaria más adecuada, y se realiza una función de apoyo y consejo al alertante, con recomendaciones previas a la llegada del recurso. [19]

Tratando de mejorar este sistema de detección se pueden encontrar proyectos similares como el de la OMS. Esta organización ha propuesto intentar reducir al 50% las víctimas por accidentes de tráfico hasta 2030. Con ese objetivo ha lanzado su programa de Seguridad en Carretera 2021-2030. Para ello, la organización en colaboración con las comisiones regionales de las Naciones Unidas para la Seguridad Vial, han desarrollado un Plan Global para la Década de Acción. Este plan incluye la promoción de transportes alternativos, mejor atención a las víctimas y mejorar la seguridad de las calles. Esta propuesta aportará con total seguridad una solución válida y eficiente a la problemática, sin embargo, al igual que se ha descrito en apartados anteriores, la prevención de los accidentes de tráfico es realmente difícil, ya que prácticamente son inevitables. Por tanto se cree que esta idea de aplicar el foco en la disminución de los tiempos de espera para la atención a las víctimas a pesar de no tener una repercusión en la disminución del número de accidentes, como sí tiene la OMS, sí la tendrá en la disminución de víctimas mortales provocadas por los mismos. [21]

Por otro lado, también Apple estaría planteando incorporar en sus dispositivos la funcionalidad de detección de accidentes de tráfico. Este proyecto intentará mediante el uso de los sensores del teléfono o del reloj, detectar cambios bruscos que podrían indicar que se ha producido un accidente y avisar inmediatamente a los servicios sanitarios y contactos de emergencia. Parece ser que Google habría añadido algo similar a sus Google Pixel. La funcionalidad presentada por estas dos empresas realmente es un proyecto similar al propuesto, ya que también se centra en la detección de accidentes mediante Inteligencia Artificial para el avisado inmediato a los servicios de emergencia, una solución realmente útil y que será de gran ayuda para reducir las víctimas mortales. Sin embargo, la diferenciación que presenta el proyecto descrito en este documento es la detección de los accidentes por medio del análisis de imágenes captadas por cámaras de seguridad. Probablemente si tiene lugar una colisión de un vehículo, esto derive en que el dispositivo sufra daños, que deje de funcionar o que se produzca una rotura del mismo. Por lo que se cree que la detección de accidentes de tráfico mediante cámaras de seguridad tendrá una mayor efectividad, es decir, se identificará un mayor número de accidentes en comparación con los que el dispositivo los detecta a través de cambios bruscos en sus sistemas de acelerómetro, GPS, etc. [20]

Por todo lo expuesto anteriormente, se establece la prevención de los mismos como una tarea realmente complicada, por lo que el proyecto estará centrado en la reducción de esos minutos de espera hasta que tiene lugar la identificación de la necesidad de atención médica.

Dicha disminución del tiempo de espera reducirá con total seguridad las cifras de muertes por accidentes de tráfico.

Capítulo 3. OBJETIVOS

3.1 Objetivos generales

El objetivo general es conseguir identificar accidentes de tráfico en una imagen en tiempo real y de esta manera reducir los tiempos de espera para la atención a las víctimas.

3.2 Objetivos específicos

Tras definir el objetivo general de este proyecto, se procederá a definir los objetivos específicos:

- En primer lugar, se explorarán diversas fuentes que puedan ser útiles para el desarrollo del proyecto y se recopilará información relevante.
- A continuación, se realizará un análisis exhaustivo de los datos que han sido recopilados, mostrando información visual, con el objetivo de sacar conclusiones que faciliten la implementación del modelo óptimo.
- Realizar un análisis de las zonas con mayor accidentalidad de Madrid para ubicar el sistema en la mejor localización posible.
- Seguidamente, se recopilarán vídeos de accidentes de tráfico, a través de los cuales se entrenará posteriormente la red neuronal.
- El siguiente paso será cargar los vídeos en el entorno de trabajo y aplicar las diferentes transformaciones sobre ellos necesarias para crear el conjunto de datos con el que la red neuronal será entrenada.
- Una vez el conjunto de datos haya sido creado, se construirá la red neuronal.
- Posteriormente se interpretarán los resultados y se incorporarán los óptimos.
- Finalmente, será posible mostrar una imagen en tiempo real y que la red neuronal detecte un accidente.

3.3 Beneficios del proyecto

La identificación automática de accidentes de tráfico presenta múltiples beneficios además de los ya mencionados.

En primer lugar, recopilar y analizar información permitirá conocer de manera fiable lo sucedido. De esta manera se podrán identificar las causas de accidentes pasados además de detectar nuevos peligros y así transmitirlo de una forma más nítida a la red neuronal.

Analizar la accidentalidad por zonas de Madrid permitirá extraer conclusiones sobre las ubicaciones en las que el sistema tendrá un impacto mayor, es decir, se realizará un estudio sobre las localizaciones óptimas para instalarlo. De esta manera se podrá acceder a las cámaras ubicadas en estas zonas y recopilar las imágenes de las mismas. Estas serían las que observaría nuestro sistema instalado. La red neuronal sería entrenada con estas imágenes, lo que otorgaría gran robustez al modelo.

Finalmente, estos análisis otorgarían gran calidad a la red neuronal que una vez construida servirá para automatizar el proceso de notificación a emergencias además de conseguir inmediatez y eficacia en la detección de accidentes. Esto derivaría en una reducción considerable de las víctimas mortales.

Capítulo 4. DESARROLLO DEL PROYECTO

4.1 Planificación del proyecto.

Tabla 1. Planificación del proyecto.

Actividad	Descripción
1. Exploración de referencias.	Se realizará una exploración inicial con el fin de recopilar información relevante.
1.1 Exploración de fuentes que puedan ser útiles.	Se tienen en cuenta diferentes plataformas de datos y se investiga cuáles contienen información sobre accidentes de tráfico en la ciudad de Madrid.
1.2 Recopilación de información que pueda ser relevante.	Se recopila la información potencialmente valiosa de las fuentes exploradas.
2. Extracción de datos para el análisis.	Se hará uso de las fuentes exploradas para extraer las bases de datos necesarias para realizar el análisis de accidentalidad.
2.1 Acceso a bases de datos públicas de accidentes en Madrid.	Se accede al portal de datos abierto del Ayuntamiento de Madrid y otras fuentes públicas de datos.
2.2 Solicitud de acceso a datos que pudieran enriquecer el análisis al ayuntamiento.	Se solicita al Ayuntamiento de Madrid la cesión de algunos datos que otorguen valor al análisis.
2.3 Integración de técnicas para la construcción de la colección de datos.	Se procede a combinar toda la información extraída para formar el conjunto de datos.
3. Preparación de datos para el análisis.	Se procederá a preparar los datos extraídos aplicando las transformaciones necesarias con el fin de mostrar de una forma clara y nítida la información en el análisis.
3.1 Unión de los archivos de datos.	Se combinan todos los conjuntos de datos en uno.

3.2 Tratamiento de valores nulos.	Análisis y tratamiento de nulos.
3.3 Eliminación de outliers.	Análisis y eliminación de outliers.
3.4 Eliminación de ruido.	Análisis y eliminación de ruido.
3.5 Aplicación de transformaciones sobre los datos.	Creación de campos calculados y otras transformaciones que aporten valor al análisis.
3.6 Recapitulación de procesos para la mejora de los mismos.	Revisión del proceso e incorporación de mejoras.
4. Análisis de accidentalidad.	En este punto se llevará a cabo el análisis de la accidentalidad de Madrid y se extraerán conclusiones útiles para el desarrollo.
4.1 Extracción de estadísticos principales.	Análisis descriptivo de los datos.
4.2 Diseño y elaboración de gráficos.	Representación visual de la información.
4.3 Implementación de gráficos y estadísticos en un cuadro de mandos.	Combinar toda la información en un cuadro de mandos.
4.4 Extracción de conclusiones.	Se observa el cuadro de mandos y se extraen conclusiones valiosas para el análisis.
5. Recopilación de vídeos.	Se hará uso nuevamente de las fuentes exploradas en el primer punto para recopilar los vídeos de accidentes que alimentarán la red neuronal.
5.1 Exploración de imágenes públicas de accidentes.	Se lleva a cabo una investigación a partir de diversas fuentes y se recopilan imágenes públicas que cumplan las características para ser incluidas en el entrenamiento.

5.2 Petición de acceso a imágenes en los organismos pertinentes.	Se solicitará a las entidades correspondientes la cesión de algunos datos que otorguen valor al análisis.
5.3 Integración de técnicas para la unión de la información recopilada.	Se aplican las técnicas necesarias para la unión de la información extraída.
6. Tratamiento de imágenes.	Se aplicarán las transformaciones necesarias sobre las imágenes para el entrenamiento, así como para otorgar robustez al modelo.
6.1 Transformación de los vídeos en "frames".	La red neuronal debe ser entrenada con imágenes estáticas por lo que se lleva a cabo una división en "frames" de los vídeos recopilados.
6.2 Eliminación de imágenes defectuosas e irrelevantes.	En estos vídeos existen "frames" sin importancia o en los que no se aprecia la información, por lo que estos son descartados ya que podrían sesgar el modelo.
7. Preparación del entorno.	Se adquirirán e instalarán los requisitos necesarios para la consecución del proyecto.
7.1 Análisis de requisitos.	Se observan las características necesarias para el desarrollo del modelo.
7.2 Instalación de las herramientas necesarias.	Aprovisionamiento de lo necesario para la construcción de la red neuronal.
8. Etiquetado de imágenes.	Se llevará a cabo el proceso de etiquetado mencionado anteriormente. En él se especificará la posición en la imagen del accidente, lo que alimentará a la red neuronal.
8.1 Identificación y etiquetado de la posición del accidente en la imagen.	Se indica la posición del accidente en la imagen.

8.2 Construcción del conjunto de datos.	Se combinan todas las imágenes etiquetadas en un mismo conjunto de datos.
8.3 Revisión de procesos.	Análisis del proceso e incorporación de mejoras.
9. Construcción de la red neuronal.	Tras contar con las imágenes preparadas se puede proceder a construir el modelo.
9.1 División del conjunto de datos en entrenamiento y test.	Se reservan el 10% de las imágenes para la evaluación del modelo.
9.2 Entrenamiento del modelo.	Se entrenan diferentes algoritmos con el fin de encontrar el que produzca un mejor ajuste a los datos.
9.3 Evaluación del modelo.	Obtención de las métricas para la evaluación del modelo de cada algoritmo.
9.4 Interpretación de resultados y selección del modelo óptimo.	Se analizan los resultados de los diversos algoritmos para seleccionar el más óptimo.
10. Pruebas.	Se realizarán pruebas para la corrección de errores e implementación de mejoras.
10.1 Prueba de funcionamiento.	Pruebas sobre el sistema y posible descubrimiento de errores.
10.2 Corrección de errores e incorporación de mejoras.	Eliminación de estos errores si existiesen e implementación de posibles mejoras.
11. Preparación de la demo.	Se preparará la versión inicial del sistema que sería incorporado en las cámaras.
12. Elaboración de documentación.	Se redacta el proceso.

Tabla 2. Diagrama de Gantt del proyecto.

Nombre de la tarea	Mes					N.º horas
	Enero	Febrero	Marzo	Abril	Mayo	
Exploración de referencias						
Exploración de fuentes que puedan ser útiles						20
Recopilación de información relevante						
Extracción de datos para el análisis						
Acceso a bases de datos públicas de accidentes en Madrid						30
Solicitud de datos que pudieran enriquecer el análisis al ayuntamiento						
Integración de técnicas para la construcción de la colección de datos						
Preparación de datos para el análisis						
Unión de los archivos de datos						40
Tratamiento de valores nulos						
Eliminación de outliers						
Eliminación de ruido						

Calle	Calle del suceso. Si un accidente presenta dos calles se refiere a un cruce
Número	Número de la calle
Distrito	Nombre del distrito
Tipo accidente	Colisión doble, colisión múltiple, alcance, vuelco, caída, atropello, choque contra elemento de la vía u otras causas
Estado meteorológico	Estado meteorológico en el momento del accidente
Tipo vehículo	Tipo de vehículo afectado
Tipo persona	Conductor, peatón, testigo o viajero
Tramo edad	Tramo de edad de la persona afectada
Sexo	Sexo de la persona afectada
Lesividad	Leve, grave o fallecido. Estas tres categorías se desglosan más según la asistencia sanitaria.
Coordenada X (UTM)	Coordenada X del accidente en formato UTM.
Coordenada Y (UTM)	Coordenada Y del accidente en formato UTM.
Positivo en alcohol	Variable binaria que responde a si la persona resultó positiva en consumo de alcohol.
Positivo en droga	Variable binaria que responde a si la persona resultó positiva en consumo de droga.

- Datos de las activaciones del SAMUR desde el año 2019.** Obtenidos mediante descarga del “Portal de datos abiertos del Ayuntamiento de Madrid” tras contactar con este organismo. Recoge el detalle de las activaciones llevadas a cabo por SAMUR–Protección Civil, definiendo activación como encargos de asistencia sanitaria que supone que se active un recurso sanitario u otro tipo de vehículo. Esta información resulta útil para conocer los accidentes que han sido alertados y cuál ha sido la respuesta. [27]

Tabla 4. Variables del dataset de activaciones de emergencia de Madrid.

Variable	Descripción
Año	Año de la intervención
Mes	Mes de la intervención
Hora solicitud	Hora de la activación del recurso
Hora intervención	Hora de llegada al incidente
Código	Se clasifica el accidente en función de la información del demandante
Distrito	Distrito en el que ocurrió
Hospitales	Hospital público de traslado. En blanco si no acabó con traslado hospitalario

- Vídeos de accidentes de tráfico para entrenar la red neuronal.** Se realizó una propuesta de cesión de los datos a la Dirección General de Tráfico cuya respuesta fue negativa. Esta solicitud se produjo a través de canales oficiales y buscaba enriquecer la red neuronal con un mayor número de imágenes. Además, se hubiera podido otorgar robustez al modelo, pudiendo ser alimentado con las imágenes de las cámaras reales en las que este podría implementarse. Esta solicitud se encuentra en el “Anexo 1”.

Ante la negativa de acceso a estos recursos, se decidió recurrir a imágenes públicas de accidentes captadas por cámaras de seguridad en otras ciudades o incluso países. En la plataforma “YouTube” se podían encontrar recopilaciones de este tipo de imágenes, incluso dentro del perfil oficial de la Dirección General de Tráfico en esta plataforma. Mediante la librería de Python “PyTube” se automatizó el proceso de descarga y almacenamiento de estos vídeos para posteriormente comenzar su procesamiento. El aspecto final del conjunto de datos será una sucesión de archivos en formato XML en los cuales estará especificada la ubicación en la imagen del accidente de tráfico.

Tratamiento de datos para el análisis

Se ha realizado un tratamiento de los datos que serán empleados para el análisis, en este caso accidentes en Madrid y activaciones del SAMUR, con el fin de adecuar los datos a los formatos válidos para el análisis, descartar información irrelevante y representar la que aporta valor de una forma más nítida.

Se tomarán inicialmente los datos de los accidentes ocurridos en Madrid desde el año 2019:

- En primer lugar, el conjunto de datos venía segmentado en varios según el año, por lo que se decidió combinar todos en uno mismo con el fin de compactar la información y poder trabajar con ella de una forma más cómoda, además de generar nuevas posibilidades de visualización. Tras esto, se posee un único archivo de datos con 117290 observaciones y 28 variables.
- A continuación, se realizó una exploración sobre las categorías de la variable “tipo_lesividad”.

Figura 14. Distribución de la variable “tipo_lesividad”.

	tipo_lesividad	num_expediente
7	Se desconoce	5
4	Fallecido 24 horas	68
6	Ingreso superior a 24 horas	947
0	Asistencia sanitaria ambulatoria con posterior...	1139
3	Atención en urgencias sin posterior ingreso	2226
1	Asistencia sanitaria inmediata en centro de sa...	2377
5	Ingreso inferior o igual a 24 horas	3467
2	Asistencia sanitaria sólo en el lugar del acci...	11459
8	Sin asistencia sanitaria	25985

- Tras este proceso se decidieron descartar los accidentes cuyo “tipo_lesividad” fuera “Se desconoce”, “Sin asistencia sanitaria” y “Asistencia sanitaria ambulatoria con posterioridad”. Esto se debe a que el problema propuesto se basa en las demoras en la atención sanitaria a las víctimas, por lo que únicamente se analizarán los accidentes que derivaron en una alerta a los servicios de emergencias y posterior intervención de los mismos.
- Se continuó con el análisis del conjunto de datos y se decidieron descartar las siguientes variables por los motivos indicados:

Tabla 5. Variables descartadas en el dataset de accidentes de tráfico.

Variable	Motivo
Lesividad	Misma información recogida en "tipo_lesividad". Además, presenta 65% de valores nulos
Positiva_alcohol	Información irrelevante para el análisis
Positiva_droga	Información irrelevante para el análisis. Además, presenta 84% de valores nulos
Tipo_vehículo	Variable duplicada
Cod_lesividad	Información irrelevante para el análisis, misma información recogida en "tipo_lesividad"
Cod_distrito	Información irrelevante para el análisis, misma información recogida en "Distrito"

- Tras el descarte de estas variables, se procedió a evaluar el número de nulos de las columnas restantes:

Figura 15. Valores nulos por variable en el dataset de accidentes.

coordenada_x_utm	11
coordenada_y_utm	11
distrito	4
estado_meteorológico	11681
fecha	0
hora	0
localizacion	0
num_expediente	0
numero	4
rango_edad	0
sexo	0
tipo_accidente	4
tipo_lesividad	78354
tipo_persona	3
tipo_vehículo	42080

- Se puede observar que la variable **“tipo_lesividad”** presenta un elevado número de valores nulos, sin embargo, su información es considerada para este análisis como muy valiosa debido a su relación con las alertas a los servicios de emergencia y activación de los mismos. Por esta razón se ha decidido descartar los valores nulos de esta variable, lo que ha provocado indirectamente haber eliminado todos los valores nulos en las demás variables. Esto indica que gran parte de los nulos presentes en los datos correspondían a los mismos accidentes.
- Seguidamente se ha procedido a convertir la variable **“Fecha”** a su tipo correspondiente, y se ha igualado el formato a **“dd/mm/aaaa”**.
- Finalmente, **se presentan las variables “coordenada_x_utm” y “coordenada_y_utm”**. Estas variables serán de gran utilidad para poder representar en un mapa cada uno de los accidentes. No obstante, el sistema de referencia en el que se encontraban era UTM, lo que hacía estrictamente necesario convertirlas a geográficas para su posterior representación. Esto fue posible gracias al uso de la instrucción **“utm.to_latlon”** de la librería **“utm”**. Inicialmente se ajustó la disposición de la variable, la cual originalmente aparecía multiplicada por 1000, para posteriormente aplicar la instrucción a las columnas mediante un bucle.

Tras este tratamiento, la dimensión final del conjunto de los datos que será utilizado para analizar la accidentalidad de Madrid es de **20513 observaciones y 17 variables**.

A continuación se detallará el tratamiento llevado a cabo sobre los datos de activaciones del SAMUR-Protección Civil desde el año 2019:

- Inicialmente, de la misma forma que con los datos anteriores, se procedió a combinar los datos, que originalmente estaban dispuestos por año, en un mismo conjunto. Tras esto, se posee un único archivo de datos con 353837 observaciones y 10 variables.
- A continuación, se realizó una exploración de los valores nulos del conjunto de datos:

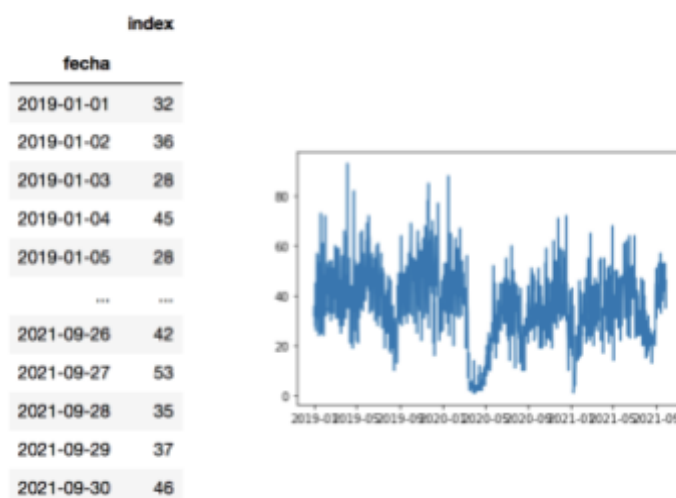
Figura 16. Valores nulos por variable en el dataset de activaciones

Año	0
Código	268
Distrito	2828
Hora Intervención	32450
Hora Solicitud	3804
Hospital	247512
Mes	0

- Se debe mencionar que los valores nulos en la variable **“Hospital”** hacen referencia a que la asistencia no concluyó con un traslado al hospital, y los presentes en la variable **“Hora Intervención”** significan una cancelación en la activación y por lo tanto dicha intervención no llegó a producirse. Por este motivo se decidió eliminar los valores nulos de la variable **“Hora Intervención”** y modificar los de la variable **“Hospital”** a **“Sin traslado”**. Este proceso ha provocado indirectamente la eliminación de los valores nulos restantes, algo lógico teniendo en cuenta que los mismos podían venir derivados de la mencionada cancelación en la activación.
- Por otro lado, se observó que la variable **“Código”** contaba con más de 90 categorías diferentes, es decir, las activaciones del SAMUR no se producían únicamente por accidentes de tráfico, si no que existían llamadas por robos, intoxicación etílica, violencia de género y más incidencias. De esta manera, se decidió descartar todas las categorías excepto las relacionadas con accidentes de tráfico, siendo estas únicamente nueve y reduciendo considerablemente el tamaño del dataset.
- Seguidamente, se puede observar que están presentes las variables **“Mes”, “Año” y “Hora”**, en cambio no existe una variable que contenga el día en el que ocurrió la llamada. Se considera esta información como valiosa por lo que se procedió a su obtención. Esta se llevó a cabo a partir de la hora y el mes, es decir, se desarrolló un **“script”** automático que fuera observando la hora de cada llamada, y en cuanto esta fuese menor que la de la llamada anterior se sumaría un día. Es decir, en el conjunto de datos se recogen las horas de 00:00 a 23:59, de esta manera cuando a las 00:00 se iniciase un nuevo día, este sería el único momento en que la hora de la llamada observada es menor a la de la observación anterior, por tanto se suma un día.

Tras la ejecución de este proceso, se contaba con la fecha de cada llamada perfectamente extraída.

Figura 17. Resultado de la creación de la variable **“fecha”** en el dataset de activaciones.



- En último lugar, se observó la presencia de las variables “Hora Solicitud” y “Hora Intervención”, de esta manera se decidió crear un campo calculado a partir de la resta de las dos anteriores denominado “Demora”. Se consideró como importante recoger esta información para el análisis debido a que la reducción de dicha demora es el principal objetivo de este proyecto.

De esta forma se concluye el tratamiento sobre los datos de activaciones del SAMUR con una dimensión del conjunto final de **36323 observaciones y 10 variables**.

Tratamiento y etiquetado de imágenes

Se ha realizado un tratamiento de los datos que serán empleados para desarrollar el modelo, en este caso vídeos de accidentes, con el fin de adecuar los datos a los formatos válidos de entrada y de descartar imágenes irrelevantes o defectuosas.

Como se ha comentado anteriormente, se han seleccionado varios vídeos públicos de accidentes de tráfico captados por cámaras de seguridad presentes en la plataforma YouTube. Una vez han sido seleccionados, a partir de la librería “PyTube” se pudo automatizar el proceso de descarga de los mismos.

Figura 18. Automatización de descarga de los vídeos.

```
https://www.youtube.com/watch?v=oNd6ODbSZFM
https://www.youtube.com/watch?v=hw0Rnfs1MRU
https://www.youtube.com/watch?v=r1qExNyIPtA
https://www.youtube.com/watch?v=RMzXNQihv5Y
https://www.youtube.com/watch?v=QvAU-LddfiQ
https://www.youtube.com/watch?v=5bzMUDqgP2E
https://www.youtube.com/watch?v=0IHjhMuPkzM
https://www.youtube.com/watch?v=VNe6aFm80dE
https://www.youtube.com/watch?v=Dj54DyZvs7w
https://www.youtube.com/watch?v=Xx4zFDMACME
https://www.youtube.com/watch?v=r4e4l3Rul2k
https://www.youtube.com/watch?v=gWbAt6xzoAY
downloading : Colisión en una intersección with url : https://youtube.com/watch?v=oNd6ODbSZFM
downloading : Accidente múltiple provocado por camión with url : https://youtube.com/watch?v=hw0Rnfs1MRU
downloading : Se sale de la carretera y vuelca with url : https://youtube.com/watch?v=r1qExNyIPtA
downloading : Sin control with url : https://youtube.com/watch?v=RMzXNQihv5Y
downloading : Una incorporación con accidente with url : https://youtube.com/watch?v=QvAU-LddfiQ
downloading : Accidente en incorporación with url : https://youtube.com/watch?v=5bzMUDqgP2E
downloading : Accidente por pérdida de control with url : https://youtube.com/watch?v=0IHjhMuPkzM
downloading : Accidente por salida de la vía with url : https://youtube.com/watch?v=VNe6aFm80dE
downloading : Accidentes: es cuestión de un segundo with url : https://youtube.com/watch?v=Dj54DyZvs7w
downloading : Espectacular accidente en la m-45 (1) with url : https://youtube.com/watch?v=Xx4zFDMACME
downloading : Triple choque with url : https://youtube.com/watch?v=r4e4l3Rul2k
downloading : Accidente con LLuvia with url : https://youtube.com/watch?v=gWbAt6xzoAY
```

Tras esto, se contaba con varios archivos de vídeo en formato MP4, sin embargo, el aspecto final del conjunto de datos de entrada debería ser una sucesión de archivos en formato XML en los cuales esté especificada la ubicación en la imagen del accidente de tráfico. Dichos archivos XML son obtenidos a partir del proceso de etiquetado del suceso en una imagen, por lo que se comenzó a diseñar un proceso automático de extracción de los “frames” de un vídeo con una frecuencia de un “frame” por segundo. Haciendo uso de la librería de Python “cv2” se pudo llevar a cabo este proceso.

Figura 19. Proceso de extracción de “frames”.

```
Extracting... frame0.jpg  
Extracting... frame1.jpg  
Extracting... frame2.jpg  
Extracting... frame3.jpg  
Extracting... frame4.jpg  
Extracting... frame5.jpg  
Extracting... frame6.jpg  
Extracting... frame7.jpg  
Extracting... frame8.jpg  
Extracting... frame9.jpg  
Extracting... frame10.jpg
```


Figura 20. Ejemplo de “frame” extraído.



Habiendo finalizado este proceso, se obtienen varios archivos de imagen en formato JPG como el que se muestra en la figura 20. Como se ha podido intuir, las imágenes extraídas corresponden a todos los “frames” de los vídeos, por lo que existían diversas imágenes en las que no ocurría ningún accidente. Estas fueron descartadas debido a que no se podía etiquetar ningún suceso en ellas que entrenara a la red neuronal. Otras podían haber sido recopiladas en un momento de movimientos muy rápidos, lo que provocaba que no se pudiera observar con nitidez estas imágenes, por lo que también se excluyeron del modelo.

En este punto, se contaba con todo lo necesario para comenzar el proceso de ubicar los accidentes de tráfico en las imágenes y obtener los archivos XML que alimentarán a la red neuronal. Este proceso fue llevado a cabo mediante el uso de la herramienta “LabelIMG”. Esta es una herramienta gratuita y de código abierto para etiquetar gráficamente imágenes y cuya instalación precisa de una serie de requisitos que lo convierten en un proceso extenso y costoso de forma computacional.

Figura 21. Interfaz gráfica de la herramienta “LabelIMG”.



Se puede observar en la figura 21 la funcionalidad de la herramienta. Se aprecia la inserción de una imagen, en formato JPG, sobre la cual se dibuja un rectángulo (“Bounding Box”) encima del objeto a ubicar, en este caso el accidente de tráfico. Tras guardar el trabajo realizado, se generará el archivo XML, el cual alimentará al modelo, y en el que se detalla la posición del objeto en la imagen de la siguiente manera:

Figura 22. Ejemplo de archivo de entrada a la red neuronal.

```

1 <annotation>
2   <folder>down loadss</folder>
3   <filename>frame7.jpg</filename>
4   <path>D:\down loadss\frame7.jpg</path>
5   <source>
6     <database>Unknown</database>
7   </source>
8   <size>
9     <width>1280</width>
10    <height>720</height>
11    <depth>3</depth>
12  </size>
13  <segmented>0</segmented>
14  <object>
15    <name>accident</name>
16    <pose>Unspecified</pose>
17    <truncated>0</truncated>
18    <difficult>1</difficult>
19    <bndbox>
20      <xmin>351</xmin>
21      <ymin>351</ymin>
22      <xmax>560</xmax>
23      <ymax>461</ymax>
24    </bndbox>
25  </object>
26 </annotation>
27

```

Este proceso será repetido con todas las imágenes previamente seleccionadas y el conjunto de datos de entrada al modelo será conformado. Es necesario realizar este trabajo de etiquetado de forma manual debido a la variedad de posiciones que presentan los sucesos dependiendo de la imagen, factor que también otorgará robustez al modelo. También, el hecho de haber llevado a cabo la creación de un conjunto de datos propio proporciona valor al proyecto, así como la posibilidad de ayudar a otros investigadores presentándose dichos datos ya tratados y etiquetados.

Construcción de la red neuronal

La API de detección de objetos de TensorFlow es un marco de trabajo de código abierto construido sobre TensorFlow que facilita la construcción, el entrenamiento y el despliegue de modelos de detección de objetos, por tanto se ha hecho uso de esta herramienta para el desarrollo de la red neuronal. En esta API ya existen modelos pre-entrenados que se denominan “Model Zoo”, los cuales han sido entrenados con varios conjuntos de datos. Se detalla a continuación el proceso llevado a cabo:

División del conjunto de datos en entrenamiento y test. Una vez que se dispone del conjunto de datos completo, es conveniente utilizar únicamente una parte de las imágenes para el entrenamiento, y el resto para la evaluación. En este caso se utilizará el 90% para el entrenamiento y un 10% para la evaluación, una distribución habitual en este tipo de proyectos que cobra sentido al presentar un conjunto de datos reducido. Para ello, se creará una carpeta en la que se incluirán los archivos XML destinados al entrenamiento, y en otra los correspondientes a la evaluación.

Creación del “Label Map”. TensorFlow requiere un mapa de etiquetas o “Label Map”, que asigna a cada una de las etiquetas utilizadas un valor entero (un identificador). En el caso de este estudio únicamente será necesaria una etiqueta, “accident”. Este mapa de etiquetas es utilizado tanto por el proceso de entrenamiento como por el de detección.

Tabla 6. “LabelMap” de la red neuronal.


<code>[{'name':'accident', 'id':1}]</code>
--

Creación de los “TensorFlow Records”. En este punto se deben convertir los archivos XML a formato “TFRecord”. Este es un formato sencillo para almacenar una secuencia de registros binarios, de esta manera se contará con un archivo “TFRecord” correspondiente al entrenamiento y otro a la evaluación. Para realizar esta conversión se desarrolla un “script” automático que recorra todos los archivos XML de las carpetas de entrenamiento y test, y genere un archivo “TFRecord” para cada una de ellas.

Preparación para el entrenamiento del modelo. Para el propósito de este proyecto se utilizará una de las redes neuronales pre-entrenadas proporcionadas por TensorFlow. Se realizarán pruebas con tres redes distintas y se tomará una decisión viendo los resultados generados por cada una de ellas.

Se probarán con las siguientes redes neuronales pre-entrenadas:


- **SSD MobileNet v2.** Este es un modelo con la arquitectura de una red neuronal convolucional pero que en lugar de utilizar las capas de convolución estándar, utiliza capas de convolución separables por profundidad. Anteriormente ya ha sido explicada la arquitectura de las redes neuronales convolucionales. Lo que hace que este modelo destaque es que se necesita una potencia computacional muy baja para ejecutar o aplicar el aprendizaje. [30][35]



Fuente: Saeed Arabi, researchgate.com, 2019.

- **EfficientDet D7.** De forma reciente, el equipo de “Google Brain” ha publicado su propia red neuronal convolucional llamada “EfficientNet”, la cual constituye la columna vertebral de la arquitectura “EfficientDet”, por lo que se explicará esta inicialmente. “EfficientNet” se propuso estudiar el proceso de escalado de las arquitecturas de las redes neuronales convolucionales y comenzó añadiendo más parámetros a esta. Sin embargo, este es un proceso excesivamente tedioso por lo que “EfficientNet” se propuso definir un procedimiento automático para escalar las arquitecturas de los modelos convolucionales. Este trataba de optimizar el rendimiento descendente dado el rango libre sobre la profundidad, la anchura y la resolución, al tiempo que se mantenía dentro de las restricciones de memoria. De esta forma descubrieron que su metodología de escalado mejoraba la optimización de redes convolucionales anteriores, así como su arquitectura “EfficientNet”. Una vez creada esta nueva técnica de escalado se creó una nueva arquitectura que mejoraba los resultados, “EfficientDet”. [31][36]


Figura 24. Arquitectura de una “EfficientDet D7”.



Fuente: Google AI Blog, 2020

- CenterNet HourGlass.** Continúa la tendencia de las anteriores presentando una arquitectura basada en las redes neuronales convolucionales, no obstante en este caso sigue el enfoque basado en puntos clave para la detección de objetos. Considera el centro de una caja como un objeto, así como un punto clave y, a continuación, utiliza este centro previsto para encontrar las coordenadas/conjuntos del suceso etiquetado. [32][37]

Figura 25. Arquitectura de una “CenterNet”.



Fuente: (Trivedi, 2020)

Cabe recordar que la salida en todas las redes neuronales pre-entrenadas recientemente explicadas será una probabilidad. El accidente se etiquetará como tal si la probabilidad es mayor de un determinado umbral.

En este punto se deben descargar dichas redes de la API de detección de objetos de TensorFlow para poder ajustar la secuencia de pasos o “pipeline” a este proyecto.

Configuración del “pipeline”. Este viene ya definido en la red neuronal pre-entrenada, sin embargo, se deben ajustar determinadas características de cara a utilizarlas en el proyecto. En definitiva, principalmente se ha modificado el número de clases, determinados parámetros del modelo, métricas y funciones a utilizar entre otros. Con cada algoritmo se ha optado por un “pipeline” distinto por lo que este será detallado en el apartado de “Resultados”.

Entrenamiento del modelo. Llegados a este punto, se ejecuta el “pipeline” y se procede a entrenar la red neuronal con las imágenes seleccionadas para ello. Se ha llevado a cabo un entrenamiento con más de 3000 iteraciones. Tras este proceso la red neuronal estará construida.

Figura 26. Ejemplo de resultado de la red neuronal.



4.3 Recursos requeridos

Se ha utilizado la API “TensorFlow Object Detection”, la herramienta “LabelIMG”, las herramientas “Tableau” y “Carto” de visualización de datos y el lenguaje de programación de Python con las siguientes librerías, la mayoría de ellas requisitos para el funcionamiento de las herramientas anteriores:

- absl-py
- apache-beam
- astunparse
- avro-python3
- backcall
- cached-property
- cachetools
- certifi
- chardet
- colorama
- contextlib2
- cycler
- cython
- dataclasses
- decorator
- flatbuffers
- gast
- gin-config
- google-api-python-client
- google-auth
- google-auth-oauthlib
- google-cloud-bigquery
- google-pasta
- grpcio
- h5py
- idna
- importlib-metadata
- ipykernel
- ipython
- ipython-genutils
- jedi
- jupyter-client
- jupyter-core
- kaggle
- keras-nightly
- Keras-Preprocessing
- kiwisolver

- lvis
- lxml
- Markdown
- matplotlib
- numpy
- oauth2client
- oauthlib
- object-detection
- opencv-python
- opencv-python-headless
- opt-einsum
- pandas
- parso
- pickleshare
- pillow
- pip
- prompt-toolkit
- protobuf
- psutil
- py-cpuinfo
- pyarrow
- pyasn1
- pyasn1-modules
- pycocotools
- pydot
- Pygments
- pymongo
- pyparsing
- PyQt5
- PyQt5-Qt5
- PyQt5-sip
- python-dateutil
- PyTube
- pytz
- pywin32
- pyyaml
- pyzmq
- requests
- requests-oauthlib
- rsa
- scipy
- sentencepiece

- sequeval
- setuptools
- six
- slim
- tensorboard
- tensorboard-plugin-wit
- tensorflow
- tensorflow-addons
- tensorflow-datasets
- tensorflow-hub
- tensorflow-model-optimization
- termcolor
- tf-estimator-nightly
- tf-models-official
- tf-slim
- tornado
- traitlets
- typing-extensions
- urllib3
- wcwidth
- Werkzeug
- wget
- wheel
- wrapt
- zipp

4.4 Presupuesto

Tabla 7. Presupuesto del proyecto.

Tipo de coste	Valor	Comentarios
Horas de trabajo en el proyecto	3835.2 €	340 horas trabajadas por 11.28 €/hora.
Equipo técnico utilizado	1999 €	PC Portátil. Recurso ya adquirido, valor actual de mercado.
Software utilizado	0 €	Python es un lenguaje gratuito y Jupyter Notebook es un software libre, así como las librerías y herramientas utilizadas.
Estudios e informes	0 €	
Materiales empleados	0 €	

4.5 Viabilidad

Cabe destacar que este proyecto actualmente es un prototipo. Está preparado para realizar una propuesta a los clientes potenciales, pero no para su implementación. En caso de alcanzar un acuerdo con alguna entidad interesada sería necesario que esta aportase una serie de recursos que otorgarían un gran salto de calidad al sistema. En este sentido, se ha realizado un “Business Model Canvas” para analizar la viabilidad de la propuesta a los potenciales compradores.

Se puede encontrar el “Business Model Canvas” en el “Anexo 2”.

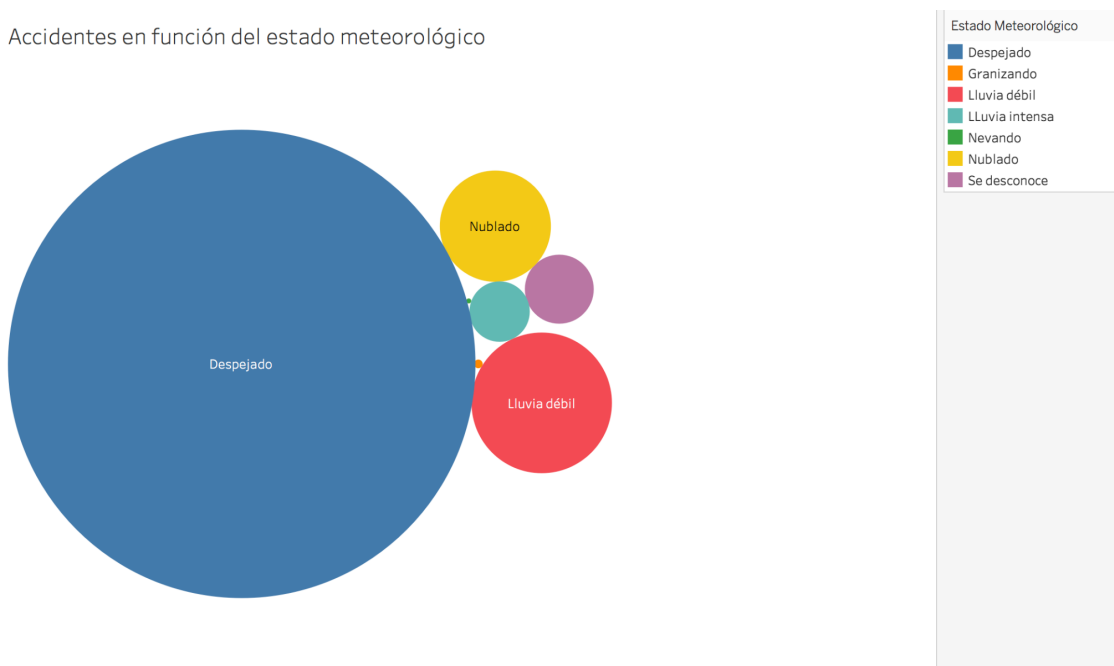
4.6 Resultados del proyecto

Se procederá en este punto a discutir los resultados obtenidos durante el desarrollo del proyecto. En primer lugar se detallarán los resultados obtenidos del análisis de la accidentalidad y posteriormente los de la red neuronal.

Resultados del análisis


Para este análisis se ha hecho uso de la herramienta de visualización de datos “Tableau” y en primer lugar, se obtendrán conclusiones generales del patrón seguido por los accidentes de tráfico en Madrid y su relación con las activaciones de emergencias. De esta manera será más sencilla la tarea de selección de las localizaciones idóneas para el sistema, que se desarrollará inmediatamente después.

Figura 27. Accidentes en función del estado meteorológico.



Se ha realizado en primer lugar un gráfico que relacione el número de accidentes ocurridos con el estado meteorológico, es decir, cuál es el clima habitual cuando se produce un accidente de tráfico. Se puede observar que la mayoría se han producido con un clima “Despejado”. Se puede llegar a pensar que los accidentes aumentan su frecuencia cuando existe lluvia o nieve, ya que posiblemente el estado del asfalto sea peor, sin embargo se puede observar que no.


Figura 28. Accidentes en función de la hora y damnificado.



En este gráfico se puede observar el número de accidentes que ocurren según la hora y la persona damnificada. Se puede observar cómo el mayor porcentaje de accidentalidad tiene lugar a las 14:00 y a las 20:00, esto cobra sentido ya que probablemente sean horas con una gran afluencia de tráfico coincidiendo con la hora de la comida y la salida del trabajo respectivamente. Además, se puede observar que la tendencia es ascendente durante las primeras horas del día alcanzando un máximo en las horas de comer, para posteriormente producirse un descenso progresivo hasta que se acerca el atardecer, cuándo se vuelve a producir un nuevo ascenso con un máximo en la hora de salida del trabajo. En cuanto al damnificado, se puede observar que mayoritariamente el conductor suele ser el más perjudicado, siguiendo esta variable la tendencia horaria general.

Figura 29. Activaciones de emergencias en función de la hora.

Llamadas en función de la hora



Para comprobar la tendencia horaria se realizó un gráfico similar al anterior pero con las activaciones de emergencias. Se puede verificar que, efectivamente, el mayor volumen de llamadas ocurre en las horas de la comida y a la salida del trabajo, confirmándose la distribución anterior.

Figura 30. Accidentes en función de la hora y el sexo.

Accidentes en función de la hora y sexo





Figura 31. Accidentes en función de la hora y la atención sanitaria.



Se han realizado algunos gráficos más con el fin de observar cómo se comportan otras variables en función de la hora. Se puede observar que la figura 28, en la cuál se observa la distribución por sexo, la tendencia aproximadamente sigue la general, en cambio en la figura 30, en la que se observa la atención sanitaria, se pueden obtener determinados matices. En primer lugar, se observa que gran parte de los accidentados han presentado asistencia sanitaria únicamente en el lugar del suceso pero además, cabe destacar que la gravedad del accidente aumenta en las últimas horas del día y es menor en las primeras. Es decir, en las últimas horas se pueden observar más ingresos y fallecidos que en las primeras. Cabe destacar que el aumento en el volumen de accidentes que ocurre en las horas anteriormente explicadas, propicia también un aumento de la gravedad de los mismos.

Figura 32. Accidentes según la edad.

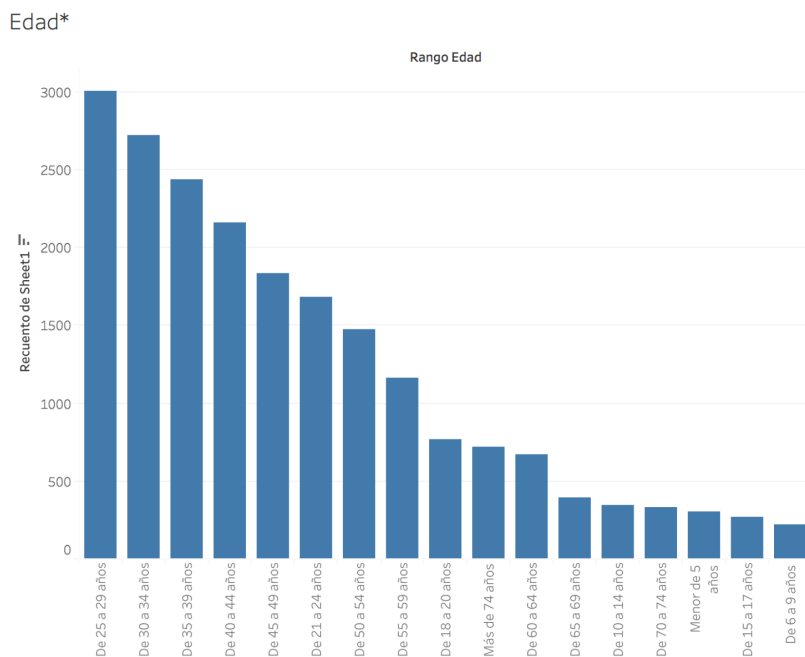

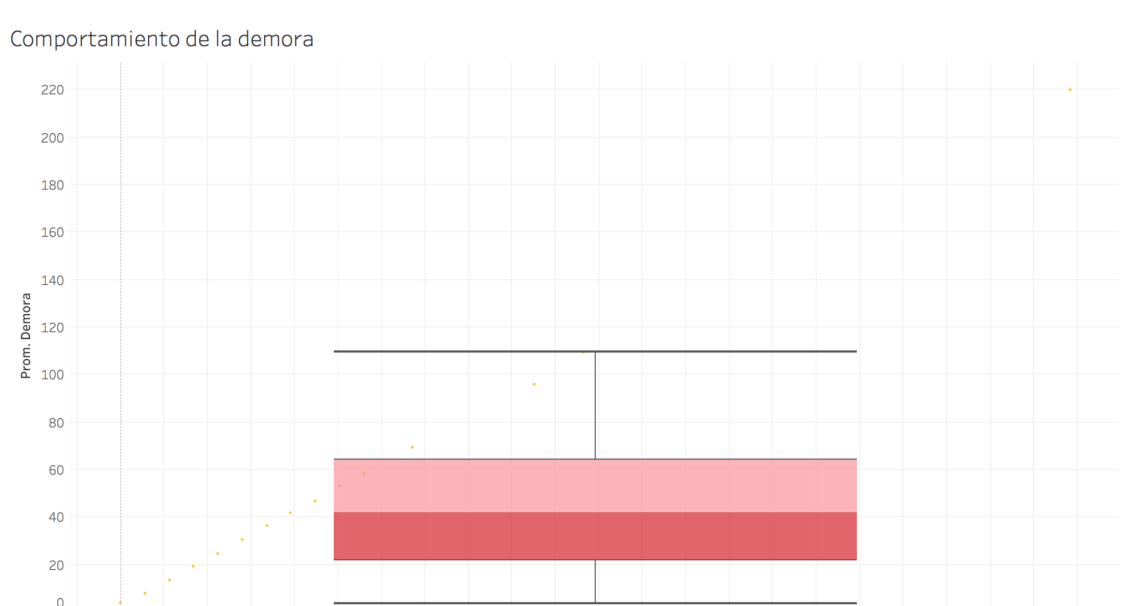


Figura 33. Accidentes por vehículo y sexo.



Se decidió representar la relación de la edad y el tipo de vehículos con los accidentes a partir de los gráficos anteriores. En el caso de la edad se puede observar que el grupo que sufre mayor número de accidentes se encuentra entre los 25-29 años, para posteriormente disminuir progresivamente de forma homogénea a medida que aumenta la edad, encontrando excepciones en los grupos menores de 20 años, los cuáles sufren menos accidentes. Por otro lado, se ha realizado un análisis del tipo de vehículo involucrado en función del sexo, obteniendo algunos resultados sorprendentes. Se puede observar que el género masculino en general, sufre más accidentes que el femenino, sin embargo, se puede apreciar que el turismo es el tipo de vehículo en el que se han producido un mayor número de accidentes con diferencia. Observando únicamente este vehículo, el género femenino sufriría más accidentes que el masculino. En cambio, analizando los accidentes en motocicleta el número de accidentes del género masculino es muy superior al femenino, también debido a que este grupo probablemente haga un menor uso de estos vehículos, por lo que la estadística final muestra un mayor número de accidentes con un hombre como víctima. Además, destacar que en los accidentes en autobús el género femenino tiene una presencia mayor. En resumen, el género masculino ha sido víctima de un mayor número de accidentes en todos los tipos de vehículo, a excepción del turismo y el autobús.


Figura 34. Comportamiento de la demora para la atención sanitaria a las víctimas.



Se ha decidido incorporar al análisis el comportamiento de la variable “Demora” anteriormente calculada. Esta variable presenta una función clave ya que, como se ha dicho, su valor representa el objetivo principal de este proyecto. En este diagrama de caja y bigotes se puede observar su comportamiento, del cuál se identifica que el bigote inferior se encontraría en 3,6 minutos, el cuartil inferior corresponde a 21,8 minutos, la mediana 41,9 minutos, el cuartil superior 64 minutos y el bigote superior 109,4 minutos. Así, se puede observar que han existido tiempos de espera muy elevados en numerosos accidentes.


Tras este análisis de características se procederá al objetivo principal, encontrar las localizaciones óptimas para ubicar el sistema. Para esto se realizará un análisis por zona de la accidentalidad en Madrid.

Figura 35. Accidentes por distritos de Madrid.



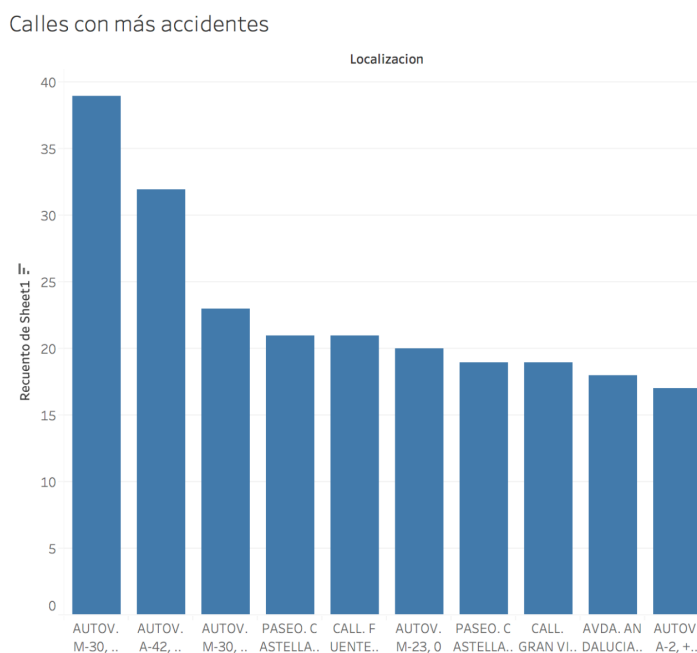
Se puede observar que el distrito en el que ocurre un mayor número de accidentes es “Salamanca”, seguido por “Chamartín”, “Puente de Vallecas” y “Carabanchel”. El siguiente lugar lo ocuparían “Retiro”, “Centro” y “Ciudad Lineal” terminando con “Chamberí”, “San Blas-Canillejas” y “Fuencarral-El Pardo”.

Figura 36. Activaciones de emergencia por distrito.



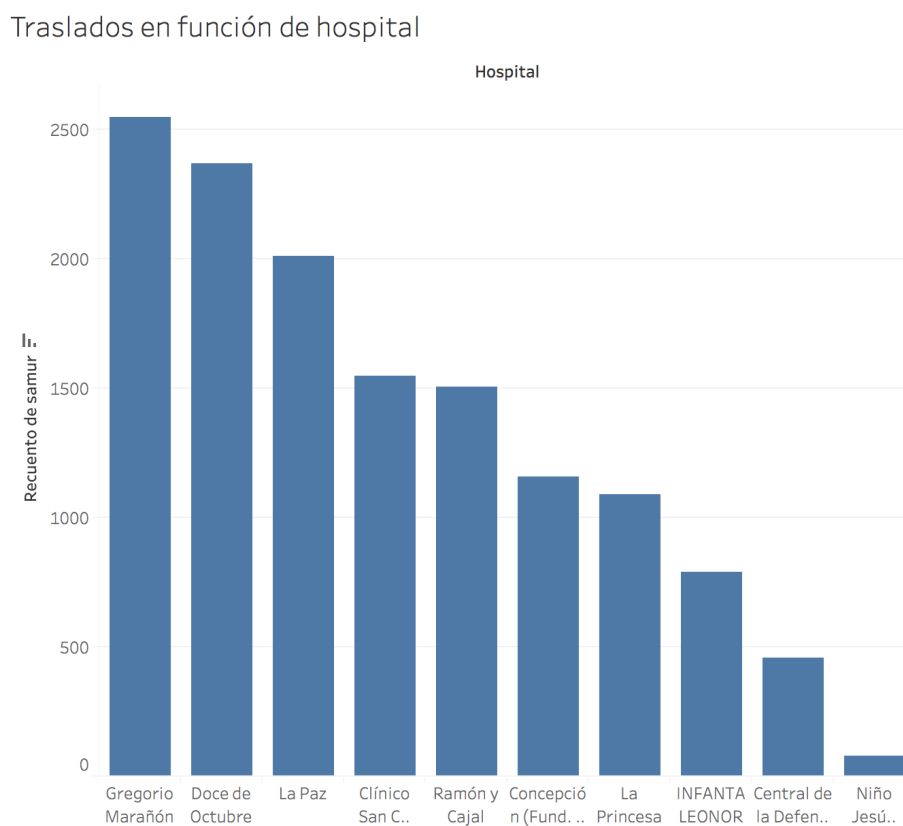
Se observa que la tendencia de las activaciones de emergencia es bastante similar a la de los accidentes anteriormente comentada, por lo que por el momento se podrían definir “Salamanca”, “Chamartín”, “Puente de Vallecas”, “Carabanchel”, “Moncloa”, “Centro”, “Retiro” y “Ciudad Lineal” como ubicaciones clave para el sistema.

Figura 37. Calles con mayor número de accidentes.




Se observa que en las primeras posiciones se encuentra la M-30 en diferentes puntos kilométricos, en este caso, ambos corresponden al distrito “Puente de Vallecas”. También se observa la A-42, a la altura de “Carabanchel”. También el Paseo de la Castellana en diferentes cruces, uno con la calle Raimundo Fernández Villaverde y otro con la plaza de Cuzco. Esto continúa con la tendencia dada anteriormente en la agrupación por distritos y además, se pueden definir unas localizaciones más exactas para el sistema.

Figura 38. Traslados en función del hospital.



Se muestra una representación de los hospitales que han recibido un mayor número de traslados de accidentes de tráfico. Cabe destacar que gran parte de los accidentes de tráfico finalizaron sin traslado, en cambio, estos se han excluido para poder observar localizaciones que estas sirvan de ayuda para las ubicaciones del sistema. Se puede ver que los hospitales que más víctimas de accidentes de tráfico han recibido son Gregorio Marañón, Doce de Octubre y La Paz, siendo estos también hospitales de gran importancia en la capital.

Figura 39. Mapa de la accidentalidad de Madrid.



A modo de conclusión del análisis se ha realizado un mapa interactivo a través de la herramienta “Carto”. En él se observa un mapa de calor en el cuál el color rojo más intenso representa las zonas más afectadas por los accidentes de tráfico. Se pueden observar también diversos puntos de color negro por todo el mapa, estos corresponden a las cámaras de tráfico actualmente instaladas. Las ubicaciones potencialmente valiosas para ubicar el sistema se confirman con este mapa, corroborando además que las cámaras actuales han sido instaladas siguiendo un análisis similar ya que, como se puede observar, la mayoría están ubicadas en los lugares con mayor intensidad del color rojo. De esta manera se cree que la mejor opción será implementar el sistema en las cámaras actuales presentes en las zonas propuestas. Además, se propone la instalación de nuevas cámaras con el sistema implementado en zonas como “Puente de Vallecas”, “Salamanca” o “Carabanchel” entre otras, que debido a su alto grado de accidentalidad podrían considerarse insuficientes las actualmente instaladas.

Figura 40. Cuadro de mandos de activaciones de emergencia.

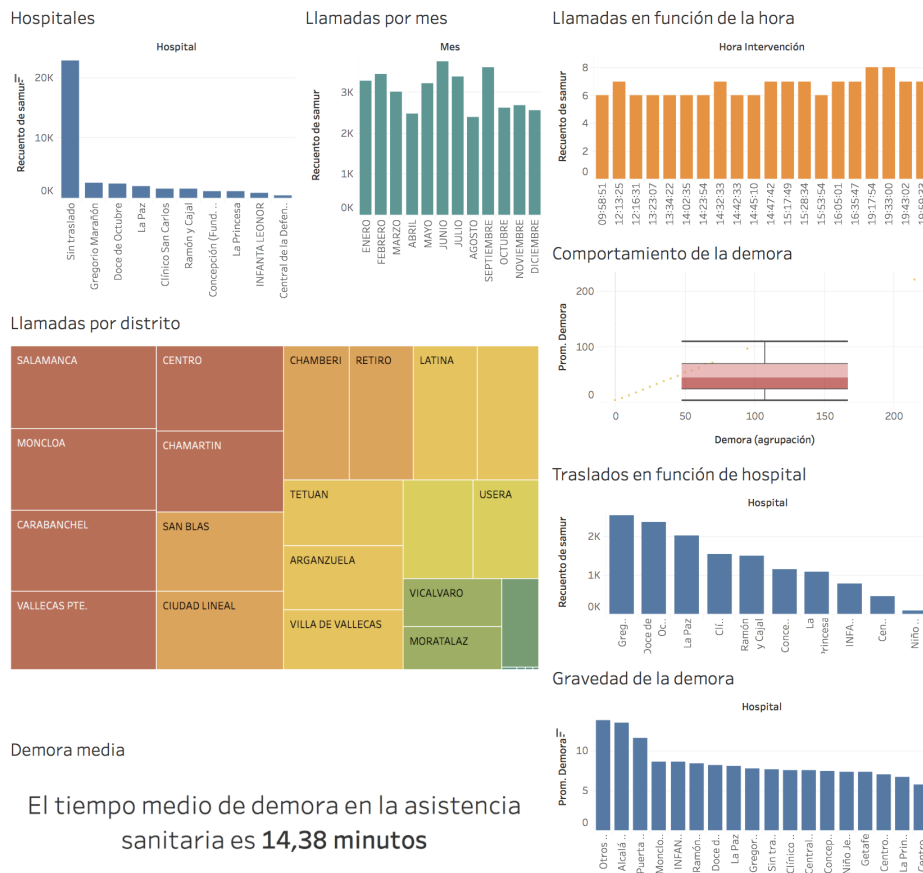
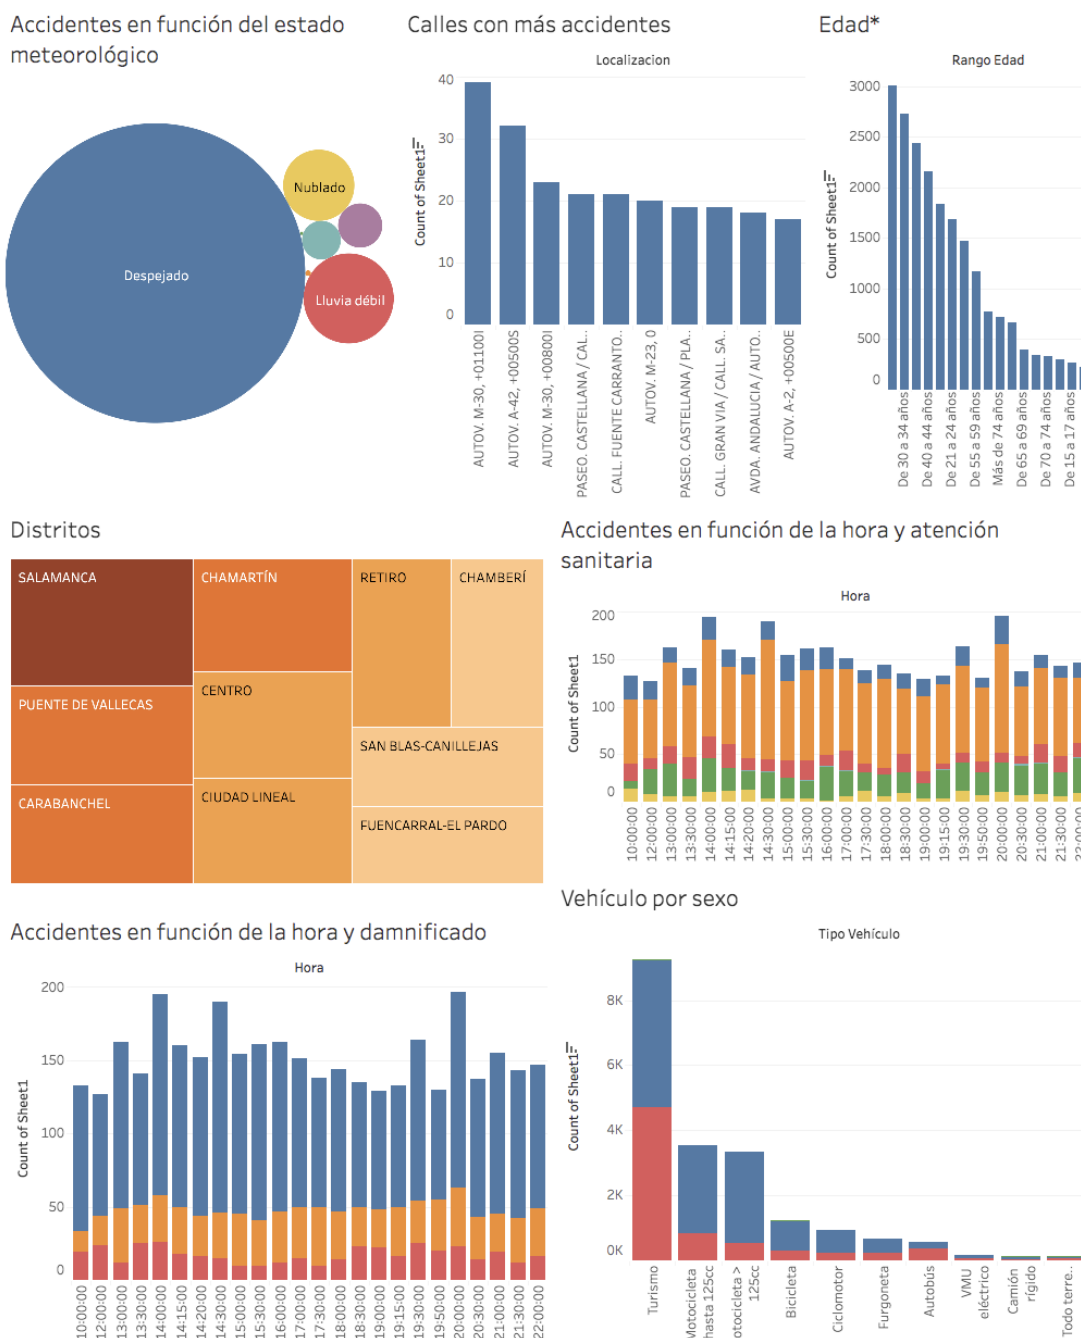


Figura 41. Cuadro de mandos de accidentes en Madrid.



Se adjunta finalmente una visualización de los cuadros de mandos creados a partir de los gráficos anteriormente comentados. Ambos son interactivos y sus gráficos actúan como filtro. Se podrá encontrar el enlace para acceder a ellos en el "Anexo 3".

Resultados del modelo

Para evaluar el rendimiento de los distintos algoritmos utilizados se usarán las siguientes métricas: [33][34]

- **“Mean Average Precision”**. Esta métrica compara la “bounding box” original con la detectada y devuelve una puntuación. Dicha puntuación será el porcentaje de predicciones emitidas que fueron correctas. Por tanto, cuanto mayor sea, más preciso será el modelo en sus detecciones.

$$MAP = \frac{TP}{TP + FP}$$

siendo “TP” “True Positive”, objeto que estaba realmente detectado correctamente. Y “FP” “False Positive”, objeto detectado que no existía realmente.

- **“Recall”**. Se diferencia con la precisión en que esta mide la probabilidad de detectar correctamente los objetos originales. Es decir, el porcentaje de objetos reales que se predicen correctamente.

$$RECALL = \frac{TP}{TP + FN}$$

siendo “FN” “False Negative”, fallo al detectar un objeto que existía.

- **“Total loss”**. Es un valor que representa la suma de errores en el modelo. Si los errores son altos, la pérdida será alta. Para calcularla, se utiliza una función de pérdida o de coste y existen varias funciones diferentes que se pueden utilizar. Para este proyecto se usará la función de pérdidas recomendada para cada red neuronal pre-entrenada.

De esta manera se obtuvieron los siguientes resultados en función del algoritmo empleado:

Tabla 8. Resultados del modelo.

<i>Red neuronal</i>	<i>Mean Average Precision</i>	<i>Recall</i>	<i>Total loss</i>
SSD MobileNet v2	0,4387	0,4600	0,2075
EfficientDet D7	0,2436	0,2514	1,3085
CenterNet HourGlass	0,2180	0,2459	1,3465

Como se puede observar, la red neuronal “SSD MobileNet v2” es la que mejor resultado ha proporcionado. De hecho, este modelo ha arrojado unos resultados óptimos teniendo en cuenta el conjunto de datos empleado y la diferencia de patrones en los accidentes de tráfico. Esto se ve reflejado en los modelos construidos a partir del resto de algoritmos, los cuales no arrojan un resultado muy bueno.

Por tanto, se han representado visualmente los resultados del modelo final desarrollado en un cuadro de mandos interactivo construido a partir de la herramienta “TensorBoard” propia de la API de detección de objetos de TensorFlow. “TensorBoard” permite monitorizar métricas como la función de pérdida y la precisión de modelos de aprendizaje profundo tanto en el conjunto de entrenamiento como en el conjunto de evaluación.

Figura 42. Evolución del “MAP”.

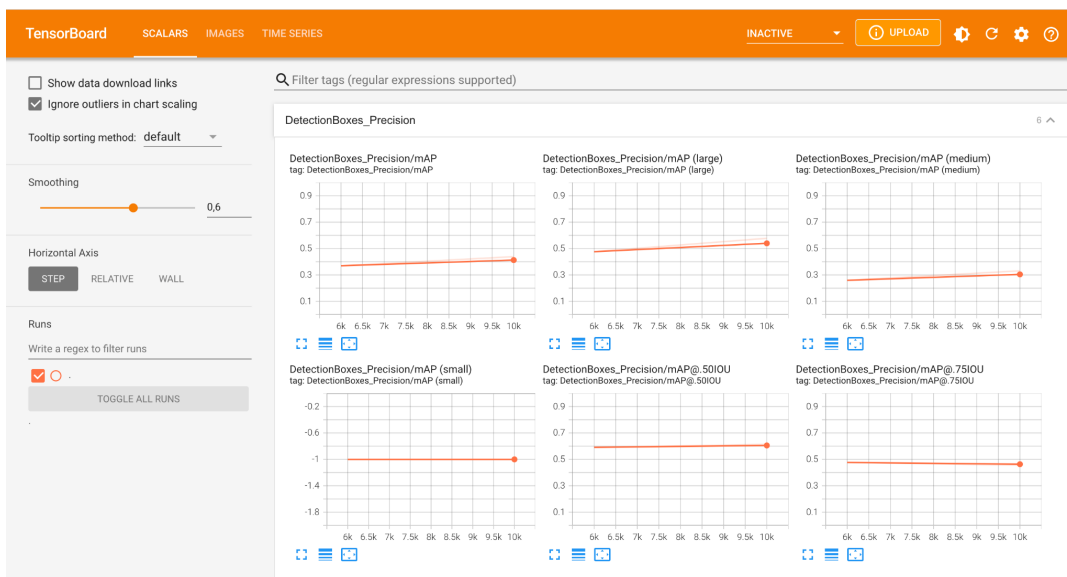
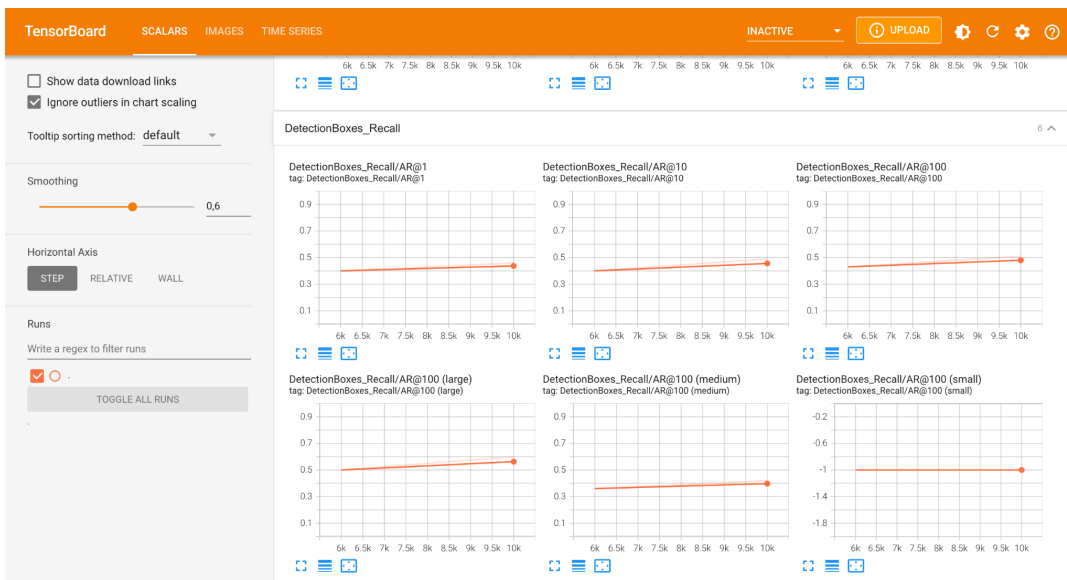
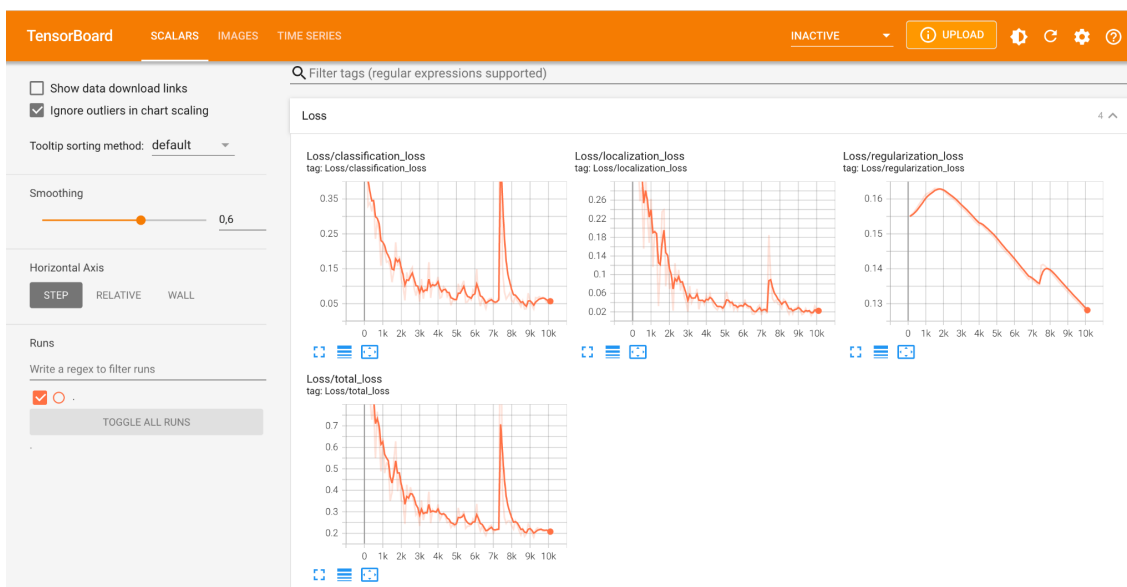


Figura 43. Evolución del “Recall”.



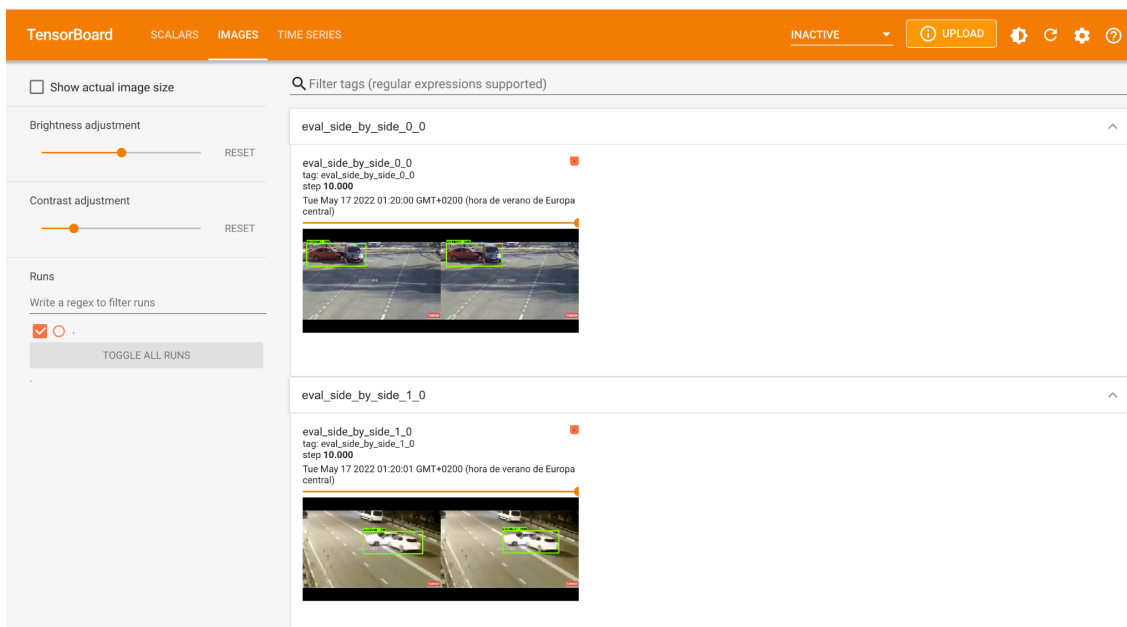
Se observa en el gráfico la evolución del “Mean Average Precision” y del “Recall” durante las diferentes épocas de la red neuronal. En total se ha entrenado una red neuronal con 10 mil épocas, mostrándose en pantalla desde la número 6 mil. Se puede apreciar que desde esta, ambas métricas han variado insignificantemente, por lo que el resultado obtenido es óptimo.

Figura 44. Evolución de la pérdida.



Se muestra la evolución de la pérdida a lo largo de las diferentes épocas. Se puede apreciar que esta tiende a cero, alcanzando un mínimo en la última época, por tanto el resultado es considerablemente bueno.

Figura 45. Resultados de la evaluación.



Se muestran también dos ejemplos de imágenes del conjunto de test, las cuales durante la evaluación se han detectado los accidentes presentes en ellas correctamente.

Además, se ha conseguido desarrollar un proceso a partir del cuál la red neuronal sea capaz de detectar accidentes de tráfico a partir de imágenes en tiempo real.

Capítulo 5. DISCUSIÓN

Este estudio nace del interés en aplicar y entender las redes neuronales convolucionales combinándolas con el concepto de “Smart Cities”, pretendiendo implementar una solución que aporte valor en estas.

Se ha podido realizar un análisis de las zonas potenciales para ubicar el sistema, extrayendo conclusiones valiosas tanto para este objetivo como para el posterior desarrollo del modelo. Este ha concluido con unos resultados óptimos. Así, se pretende destacar la maximización del potencial de los recursos para la obtención de estos resultados. De esta forma, se han encontrado diversas limitaciones que han impedido que este prototipo sea implementable a corto plazo.

En primer lugar, la negativa a la cesión de las imágenes por parte de la Dirección General de Tráfico ha limitado el poder conformar un conjunto de datos voluminoso que pudiera generar un modelo más preciso que el actual. Por esta razón se ha tenido que recurrir a una extracción de imágenes públicas. Por lo tanto, se capturaron accidentes de tráfico captados por cámaras de seguridad donde se encontró una gran escasez de fuentes, debido a que pocas legislaciones permitían la publicación de estos datos. La mayoría de las imágenes públicas de accidentes de tráfico eran o bien filmadas desde el salpicadero de otro vehículo o tomadas por periodistas una vez ya había tenido lugar el suceso. Este problema se solventó realizando una exhaustiva búsqueda por la plataforma “YouTube” y por los diversos medios de comunicación a los que se les habían cedido dichas imágenes en ciertas ocasiones.

Seguidamente, otro de los obstáculos que se encontró este proyecto fue la necesidad de una capacidad de procesamiento y almacenamiento elevada. Los vídeos e imágenes son archivos pesados por lo que, además de contar con una escasa selección de datos, los existentes necesitaban de recursos para su tratamiento. Por este motivo, se creó la necesidad de desarrollar un prototipo óptimo, el cual sería mejorado en caso de lograrse su implementación. Esta solución pretendía facilitar al máximo la posibilidad de su futura implementación ya que, en caso de conseguirse, únicamente sería necesaria la cesión de los datos y una potente capacidad de procesamiento, lo cual sería sencillo de aportar por una entidad interesada en la adquisición de un servicio de este estilo.

Así, se considera grave la gran problemática de los accidentes de tráfico, y que los proyectos destinados a su prevención generan leves mejoras, si es que estas existen. Este proyecto pretende enfocar este problema desde un enfoque novedoso, centrándose en la minimización de los daños en lugar de su complicada prevención.

Para finalizar, se pretende destacar que los resultados de este proyecto se consideran satisfactorios, debido a que los objetivos establecidos al inicio del proyecto han sido cumplidos a pesar de las múltiples dificultades encontradas durante el transcurso.

Capítulo 6. CONCLUSIONES

6.1 Conclusiones del trabajo

Se ha podido conocer el impacto de la grave problemática que suponen los accidentes de tráfico, causando el fallecimiento de miles de personas de forma diaria. Así, esta se establece como la octava causa de muerte en el mundo y la principal en jóvenes de 5 a 29 años. Además, se han podido conocer los diferentes proyectos destinados a acabar con esta situación, los cuales enfocan su solución en evitar que estos sucesos ocurran. De esta forma, se decidió para el desarrollo de este proyecto tomar un enfoque novedoso basado en minimizar los daños producidos por estos, ya que se considera que la prevención de los mismos es una tarea considerablemente complicada debido a los múltiples factores que los rodean. Para ello se definió como objetivo general emplear técnicas de la inteligencia artificial para conseguir detectar accidentes de tráfico en una imagen en tiempo real. Dicha solución propuesta permitiría reducir considerablemente los tiempos de espera de atención a las víctimas, lo que reduciría con seguridad el número de fallecidos.

De esta forma, se ha conseguido realizar un análisis de la accidentalidad de Madrid lo que ha permitido concluir con los distritos de “Salamanca”, “Chamartín”, “Puente de Vallecas”, “Carabanchel”, “Retiro”, “Centro” y “Ciudad Lineal” como los más óptimos dentro de la ciudad para ubicar el sistema. Así como la M-30, A-42, Paseo de la Castellana y Gran Vía como localizaciones clave para ello.

En este contexto se ha desarrollado un prototipo basado en una red neuronal convolucional para la detección de accidentes en imágenes en tiempo real, por lo que cabe destacar la dificultad de conseguir esto con un conjunto de datos y una capacidad de procesamiento limitados.

Lógicamente disponiendo de un mejor conjunto de datos inicial, el modelo sería mucho más preciso, robusto y óptimo. Sin embargo, se considera que cualquier entidad interesada en implementar un servicio de este tipo contaría con información, imágenes y recursos que atribuirían estas características a la red neuronal.

Se concluye este estudio destacando que los objetivos del mismo han sido completados satisfactoriamente a pesar de los múltiples obstáculos. Además, las técnicas y herramientas han sido empleadas correctamente, teniendo en cuenta que en algunos casos ha sido necesario superar un proceso de adaptación o aprendizaje.

6.2 Conclusiones personales

Se expondrán a continuación la experiencia y aprendizaje adquiridos durante el desarrollo de este proyecto, para lo que me permitiré hablar desde un tono más personal.

Este proyecto surgió del interés por aumentar mi aprendizaje en las técnicas de inteligencia artificial y las redes neuronales. Además, el concepto de las “Smart Cities” fue algo que también me generó mucho interés, por lo que pretendí desarrollar un proyecto que combinara todo. En este sentido, expuse estos argumentos a mi tutor y ambos conseguimos crear una idea atractiva, útil y con todas las características requeridas.

Nos hemos encontrado varios obstáculos tal y como se ha comentado durante el desarrollo de este estudio, como por ejemplo el tener que aprender y adaptarnos a nuevas técnicas y herramientas completamente nuevas. Además, la preparación del entorno para el funcionamiento de estas fue una tarea realmente complicada debido a la cantidad de requisitos computacionales de las mismas. Dicho proceso podría generar la sensación de no avanzar con el proyecto, sin embargo, es importante no ceder en el empeño e insistir, siempre buscando soluciones a los problemas encontrados.

Por ello, concluyo este apartado mostrando mi satisfacción por el trabajo realizado y los resultados obtenidos. En especial, destacar el aprendizaje adquirido tanto en el aspecto técnico como en el personal, llevándome grandes valores.

Capítulo 7. FUTURAS LÍNEAS DE TRABAJO

En este apartado se expondrán los próximos pasos a seguir para la mejora y la maximización del rendimiento de este modelo.

En primer lugar, sería importante aumentar la capacidad de procesamiento y almacenamiento para poder alimentar a la red neuronal con un mayor volumen de datos, y de esta forma, poder construir un modelo mucho más preciso y robusto. Para ello, la opción más destacada sería emplear servicios en la nube como Google Cloud Platform (GCP) o Amazon Web Services (AWS).

Estos recursos serían de gran utilidad, como ya se ha mencionado, para procesar rápidamente grandes volúmenes de datos. Por tanto, sería necesario contar con un conjunto de datos de imágenes contundente para poder maximizar los beneficios de los servicios en la nube y otorgar más valor al modelo.

Así, el gran objetivo sería lograr la venta de este sistema a alguna entidad interesada. Para lograr esto, se podría diseñar una campaña de publicidad adaptada al servicio prestado y presentar la propuesta a diversos clientes potenciales, que podrían ser tanto la Dirección General de Tráfico como los distintos ayuntamientos del territorio nacional. En caso de captar su interés, sería necesaria una cesión de las imágenes por parte de la entidad compradora. Así, la red neuronal sería mucho más precisa al ser entrenada con un mayor volumen de datos, además de aumentar considerablemente su robustez al realizar este proceso con imágenes captadas desde las propias cámaras de seguridad en las que el sistema estaría instalado.

En caso de que esto llegara a suceder y la red neuronal fuera implementada en cámaras de seguridad reales, sería imprescindible desplegar la funcionalidad del aviso inmediato emergencias. Para ello, se diseñaría una estrategia basada en establecer el umbral de puntuación mínimo a partir del cuál se produciría la llamada. Dicha estrategia sería establecida a partir de las diversas pruebas que se deberían realizar sobre el algoritmo tras añadir las mejoras.

En último lugar y a largo plazo sería la monitorización del funcionamiento del sistema para la corrección de posibles errores, así como el re-entrenamiento periódico de la red neuronal con el fin de continuar mejorando la precisión de la misma.

Capítulo 8. REFERENCIAS

- [1] **World Health Organization. 2021.** *Traumatismos causados por el tránsito.* [En línea]. <https://www.who.int/es/news-room/fact-sheets/detail/road-traffic-injuries>. [Consultado el 5 de mayo de 2022].
- [2] **Pan American Health Organization / World Health Organization.** *Nuevo informe de la OMS destaca que los progresos han sido insuficientes en abordar la falta de seguridad en las vías de tránsito del mundo.* [En línea]. https://www3.paho.org/hq/index.php?option=com_content&view=article&id=14857:new-who-report-highlights-insufficient-progress-to-tackle-lack-of-safety-on-the-world-s-roads&Itemid=1926&lang=es [Consultado el 5 de mayo de 2022].
- [3] **Romero, J., Dafonte Ángel, C., Fernando, G., Penousal, J., Fundación, A. and Brañas (n.d.).** *INTELIGENCIA ARTIFICIAL Y COMPUTACIÓN AVANZADA.* [En línea]. <https://cdv.dei.uc.pt/wp-content/uploads/2014/03/ms07.pdf> [Consultado el 5 de mayo de 2022].
- [4] **SAS.com. (2022).** *Inteligencia Artificial: Qué es y Por Qué Importa.* [En línea]. https://www.sas.com/es_es/insights/analytics/what-is-artificial-intelligence.html [Consultado el 5 de mayo de 2022].
- [5] **IBM.com. (2020).** *¿Qué es machine learning?* [En línea]. <https://www.ibm.com/es-es/cloud/learn/machine-learning> [Consultado el 6 de mayo de 2022].
- [6] **UCB-UMT. (2020).** *What Is Machine Learning (ML)?* [En línea]. <https://ischoolonline.berkeley.edu/blog/what-is-machine-learning> [Consultado el 6 de mayo de 2022].
- [7] **datos.gob.es (2020).** *¿Cómo aprenden las máquinas? Machine Learning y sus diferentes tipos.* [En línea]. <https://datos.gob.es/es/blog/como-aprenden-las-maquinas-machine-learning-y-sus-diferentes-tipos> [Consultado el 6 de mayo de 2022].
- [8] **SAS.com. (2017).** *¿Qué es deep learning?* [En línea]. https://www.sas.com/es_es/insights/analytics/deep-learning.html [Consultado el 6 de Mayo de 2022].
- [9] **Nebulova.es. (2021).** *Nebulova - Qué es Computer Vision.* [En línea]. [https://www.nebulova.es/blog/computer-vision#:~:text=El%20t%C3%A9rmino%20Computer%20Vision%20\(Visi%C3%B3n,én%20im%C3%A1genes%20como%20en%20videos](https://www.nebulova.es/blog/computer-vision#:~:text=El%20t%C3%A9rmino%20Computer%20Vision%20(Visi%C3%B3n,én%20im%C3%A1genes%20como%20en%20videos) [Consultado el 6 de mayo de 2022].
- [10] **Jorge Pérez Colín. (2021).** *¿Qué es computer vision y cómo funciona? - Jorge Pérez Colín.* [En línea]. <https://blog.jorgeperezcolin.mx/que-es-computer-vision-y-como-funciona/> [Consultado el 6 de mayo de 2022].

[11] **IBM Cloud Education (2020)**. *What are Neural Networks?* - *Ibm.com*. [En línea]. <https://www.ibm.com/cloud/learn/neural-networks> [Consultado el 6 de Mayo de 2022].

[12] **V7labs.com. (2021)**. *The Essential Guide to Neural Network Architectures*. [En línea]. <https://www.v7labs.com/blog/neural-network-architectures-guide#:~:text=The%20Neural%20Network%20architecture%20is,various%20components%20of%20a%20neuron.&text=Input%200%2D%20It%20is%20the%20set,model%20for%20the%20learning%20process> [Consultado el 6 de mayo de 2022].

[13] **Think Big. (2020)**. *Las matemáticas del Machine Learning: Funciones de activación* - *Think Big Empresas*. [En línea] <https://empresas.blogthinkbig.com/las-matematicas-del-machine-learning-funciones-de-activacion/> [Consultado el 6 de mayo de 2022].

[14] **Calvo, D. (2018)**. *Función de activación - Redes neuronales* - *Diego Calvo*. [En línea] <https://www.diegocalvo.es/funcion-de-activacion-redes-neuronales/> [Consultado el 7 de mayo de 2022].

[15] **Aprendemachinelearning.com. (2018)**. *Convolutional Neural Networks: La Teoría explicada en Español | Aprende Machine Learning*. [En línea]. <https://www.aprendemachinelearning.com/como-funcionan-las-convolutional-neural-network-s-vision-por-ordenador/> [Consultado el 7 de mayo de 2022].

[16] **DataSmarts Español. (2020)**. *¿Qué es la Detección de Objetos?* - *DataSmarts Español*. [En línea]. <https://datasmarts.net/es/que-es-la-deteccion-de-objetos/> [Consultado el 9 de mayo 2022].

[17] **Aprendemachinelearning.com. (2020)**. *Modelos de Detección de Objetos | Aprende Machine Learning*. [En línea]. <https://www.aprendemachinelearning.com/modelos-de-deteccion-de-objetos/> [Consultado el 9 de mayo de 2022].

[18] **GreatLearning Blog: Free Resources what Matters to shape your Career! (2021)**. *Real-Time Object Detection Using TensorFlow*. [En línea]. <https://www.mygreatlearning.com/blog/object-detection-using-tensorflow/#:~:text=The%20TensorFlow%20Object%20Detection%20API,referred%20to%20as%20Model%20Zoo> [Consultado el 11 de mayo de 2022].

[19] **Fundtrafic. (2022)**. *Actividad Protocolo P.A.S. (Proteger, avisar y socorrer)*. [En línea]. <https://fundtrafic.org/protocolo-p-a-s-proteger-avisar-y-socorrer/#:~:text=El%20protocolo%20PAS%20responde%20a,de%20muertes%20sobre%20el%20asfalto> [Consultado el 9 de mayo de 2022].

[20] **Revistamédica. (2020)**. *Actuación servicios de emergencias ante un accidente de tráfico. Revisión bibliográfica. Ocronos - Editorial Científico-Técnica*. [En línea] <https://revistamedica.com/actuacion-servicios-emergencias-accidente-de-trafico/> [Consultado el 9 de mayo de 2022].

[21] **Iván Ramírez (2021)**. *Apple prepara la detección de accidentes de tráfico para iPhone y Apple Watch, según WSJ - Xatakamovil.com*. [En línea] <https://www.xatakamovil.com/apple/apple-prepara-deteccion-accidentes-trafico-para-iphone-apple-watch-wsj> [Consultado el 9 de mayo de 2022].

[22] **RTVE.es/AGENCIAS (2021)**. *OMS se propone reducir un 50% las muertes en carretera*. RTVE.es. [En línea] <https://www.rtve.es/noticias/20211029/oms-propone-reducir-50-ciento-muertes-carretera/2208440.shtml>

[23] **Iberdrola. (2021)**. *Smart cities: la transformación digital de las ciudades - Iberdrola*. [En línea] <https://www.iberdrola.com/innovacion/smart-cities> [Consultado el 9 de mayo de 2022].

[24] **panelesach (2018)**. *¿Qué son las Smart cities o ciudades inteligentes y cómo funcionan? - Blog paneles ACH*. [En línea]. <https://panelesach.com/blog/smart-cities-o-ciudades-inteligentes-que-son/> [Consultado el 9 de mayo de 2022].

[25] **Martín, E. (2020)**. *Descubre los ejemplos de Smart Cities más destacadas - Grupocibernos.com*. [En línea]. <https://www.grupocibernos.com/blog/descubre-los-ejemplos-de-smart-cities-ms-destacadas> [Consultado el 9 de mayo de 2022].

[26] **Marta (2020)**. *Smart is the new sustainable. Londres quiere ser una smart city - Blog de HolaLuz.com*. [En línea] <https://blog.holaluz.com/london-smart-city/> [Consultado el 9 de mayo de 2022].

[27] **Ministerio de Sanidad y Política Social (2010)**. *Protocolo de actuación y buenas prácticas en la atención sanitaria inicial al accidentado de tráfico* [En línea] <https://www.sanidad.gob.es/eu/profesionales/saludPublica/prevPromocion/Prevencion/SeguridadVial/Jornadaaccidentetrafico/docs/Buenaspracticasaccidentadotrafico.pdf> [Consultado el 9 de mayo de 2022].

[28] **Madrid.es. (2017)**. *Activaciones del SAMUR-Protección Civil - Portal de datos abiertos del Ayuntamiento de Madrid*. [En línea]. <https://datos.madrid.es/portal/site/egob/menuitem.c05c1f754a33a9fbe4b2e4b284f1a5a0/?vgnextoid=50d7d35982d6f510VgnVCM1000001d4a900aRCRD&vgnextchannel=374512b9ace9f310VgnVCM100000171f5a0aRCRD&vgnextfmt=default> [Consultado el 10 de mayo de 2022].

[29] **Madrid.es. (2019)**. *Accidentes de tráfico de la Ciudad de Madrid - Portal de datos abiertos del Ayuntamiento de Madrid*. [En línea]. <https://datos.madrid.es/portal/site/egob/menuitem.c05c1f754a33a9fbe4b2e4b284f1a5a0/?vgnextoid=7c2843010d9c3610VgnVCM2000001f4a900aRCRD&vgnextchannel=374512b9ace9f310VgnVCM100000171f5a0aRCRD&vgnextfmt=default> [Consultado el 10 de mayo de 2022].

[30] **Mehta, V. (2021)**. *Object Detection using SSD Mobilenet V2 - Vidish Mehta - Medium*. [En línea].

<https://vidishmehta204.medium.com/object-detection-using-ssd-mobilenet-v2-7ff3543d738d>
[Consultado el 11 de mayo de 2022].

[31] **Solawetz, J. (2020)**. *A Thorough Breakdown of EfficientDet for Object Detection*. [online] <https://towardsdatascience.com/a-thorough-breakdown-of-efficientdet-for-object-detection-dc6a15788b73> [Consultado el 11 de mayo de 2022].

[32] **Trivedi, S. (2020)**. *CenterNet: Objects as Points Review | VisionWizard*. [En línea]. <https://medium.com/visionwizard/centernet-objects-as-points-a-comprehensive-guide-2ed9993c48bc> [Consultado el 11 de mayo de 2022].

[33] **Ahmed Fawzy Gad (2020)**. *Mean Average Precision (mAP) Explained | Paperspace Blog*. [En línea]. <https://blog.paperspace.com/mean-average-precision/> [Consultado el 17 de mayo de 2022].

[34] **Riva, M. (2021)**. *Interpretation of Loss and Accuracy for a Machine Learning Model | Baeldung on Computer Science*. [En línea]. <https://www.baeldung.com/cs/ml-loss-accuracy> [Consultado el 17 de mayo de 2022].

[35] **Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L.-C. (2018)** - **Autores de la red neuronal**. *MobileNetV2: Inverted Residuals and Linear Bottlenecks*. arXiv.org [En línea] doi:10.48550/arXiv.1801.04381

[36] **Google Research, Brain Team. (2020)** - **Autores de la red neuronal**. *EfficientDet: Scalable and Efficient Object Detection*. (n.d.). [En línea]. https://openaccess.thecvf.com/content_CVPR_2020/papers/Tan_EfficientDet_Scalable_and_Efficient_Object_Detection_CVPR_2020_paper.pdf

[37] **Duan, K., Bai, S., Xie, L., Qi, H., Huang, Q. and Tian, Q. (2022)** - **Autores de la red neuronal**. *CenterNet++ for Object Detection*. arXiv.org [En línea] doi:10.48550/arXiv.2204.08394

Capítulo 9. ANEXOS

ANEXO 1. Solicitud oficial de acceso a los datos.









RECIBO DE PRESENTACIÓN EN OFICINA DE REGISTRO

Oficina:	Registro General de la Dirección General de Tráfico - O0009247		
Fecha y hora de registro en	22/04/2022 13:27:28 (Horario peninsular)		
Fecha presentación:	22/04/2022 13:26:23 (Horario peninsular)		
Número de registro:	REGAGE22e00014460150		
Tipo de documentación física:	Documentación adjunta digitalizada		
Enviado por SIR:	No		

Interesado

Identificación:	Nombre:	PABLO NEIRA	
País:	Municipio:		
Provincia:	Dirección:		
Código Postal:	Teléfono:		
Canal Notif:	Correo		
	Observaciones:		

Información del registro

Tipo Asiento:	Entrada		
Resumen/Asunto:	SOLICITA ACCESO A LAS CAMARAS DE CARRETERA PARA TRABAJO FIN DE GRADO.		
Unidad de tramitación destino/Centro directivo:	S.G. de Gestión de la Movilidad y Tecnología - E04632002 / Jefatura Central de Tráfico		
Ref. Externa:			
Nº. Expediente:			

Adjuntos

Nombre:	mail.pdf		
Tamaño (Bytes):	29.733		
Validez:	Copia Electrónica Auténtica		
Tipo:	Documento Adjunto		
CSV:	GEISER-9399-6ccd-5025-48f5-89f2-dcc0-37e4-b19d		
Hash:	897a972032e87b4ea199f482a50cd40fb1e8bf0cd23b20cb98c6057a8701d128f1a0b303399e66100a8ea44e494dc79f879db4fd39e375ba8052d264d13a7f3		
Observaciones:			

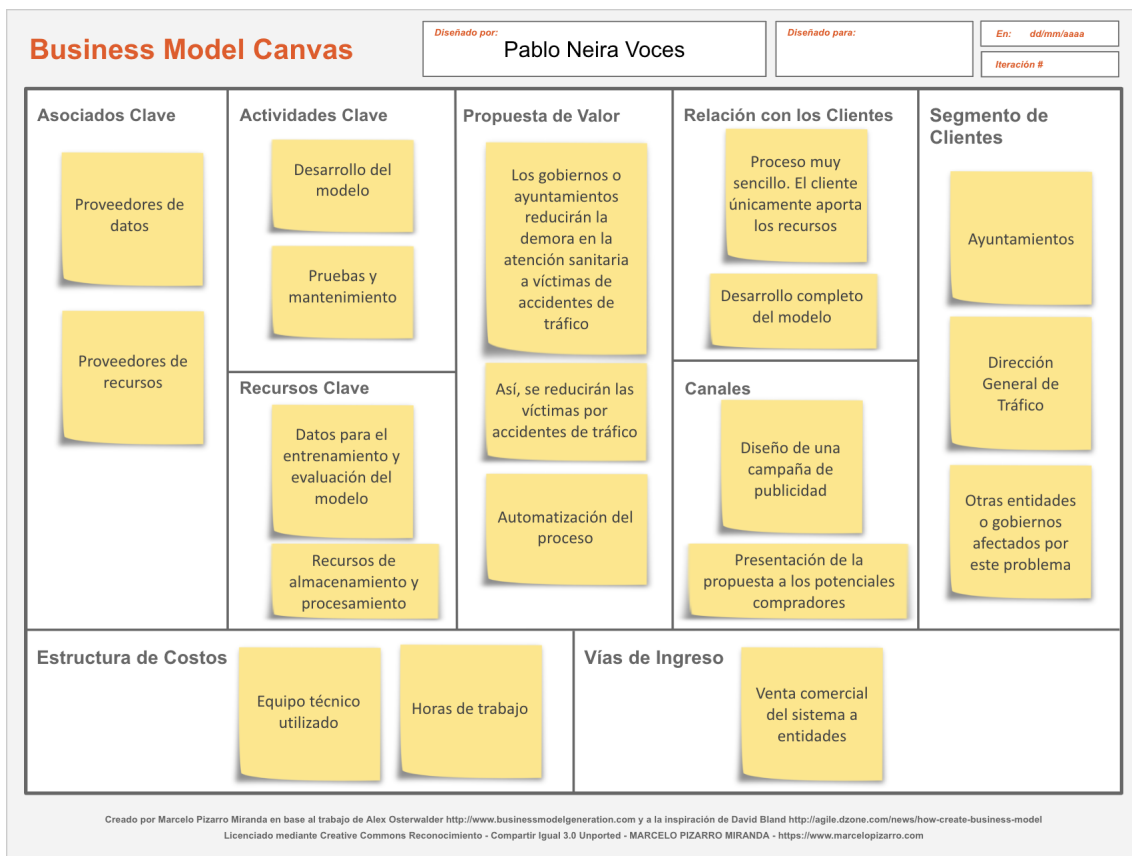
La Oficina de Registro Registro General de la Dirección General de Tráfico declara que las imágenes electrónicas anexadas son imagen fiel e íntegra de los documentos en soporte físico origen, en el marco de la normativa vigente.

El registro realizado está amparado en el Artículo 16 de la Ley 39/2015.
De acuerdo con el art. 31.2b de la Ley 39/15, a los efectos del cómputo de plazo fijado en días hábiles, y en lo que se refiere al cumplimiento de plazos por los interesados, la presentación en un día inhábil se entenderá realizada en la primera hora del primer día hábil siguiente salvo que una norma permita expresamente la recepción en día inhábil.
Podrán consultar el estado de su registro en Carpeta ciudadana. <https://sede.administracion.gob.es/carpeta/>

ÁMBITO-PREFIJO	CSV	FECHA Y HORA DEL DOCUMENTO
GEISER	GEISER-5ddc-f430-3b5e-4a9c-9ff-2c16-616b-544f	22/04/2022 13:27:28 (Horario peninsular)
Nº REGISTRO	DIRECCIÓN DE VALIDACIÓN	VALIDEZ DEL DOCUMENTO
REGAGE22e00014460150	https://sede.administracionespublicas.gob.es/valida	Original

Código seguro de Verificación : GEISER-5ddc-f430-3b5e-4a9c-9ff-2c16-616b-544f | Puede verificar la integridad de este documento en la siguiente dirección : <https://sede.administracionespublicas.gob.es/valida>

ANEXO 2. Business Model Canvas.



ANEXO 3. Código y cuadros de mando.

Modelo: https://github.com/PabloNeiraUniversidadEuropea/TFG_PabloNeira

Cuadros de mando:

https://public.tableau.com/app/profile/pablo.neira.voces/viz/TFG_16505672601400/Dashboard1

<https://public.tableau.com/app/profile/pablo.neira.voces/viz/LlamadasTFG/Dashboard1>

Mapa:

<https://gcp-europe-west1.app.carto.com/map/b9a6c639-9658-4982-95e1-9dd7e213e4af>

