



# Octava Edición

2019 - 2020

## Trabajo ganador - Texto completo

**Sistema integral para el mantenimiento eficiente de pavimentos urbanos**

**Autores:**

**Eugenio Pellicer Armiñana.** Catedrático  
Grupo de Gestión del Proceso Proyecto-Construcción  
Universitat Politècnica de València

**Roberto Paredes Palacios.** Profesor titular de Universidad  
Centro de Investigación Pattern Recognition and Human  
Language Technology  
Universitat Politècnica de València

**Jesús Felipo Sanjuán.** Director Técnico  
Pavasal Empresa Constructora, S.A.

**Juan Sánchez-Robles Bello.** Técnico Director de  
Proyectos y Obras  
CPS Infraestructuras Movilidad y Medio Ambiente, S.L.

## Índice de contenidos

<b>RESUMEN</b> .....	<b>1</b>
<b>1. INTRODUCCIÓN</b> .....	<b>1</b>
1.1 EVALUACIÓN DE LA CONDICIÓN DEL PAVIMENTO .....	2
1.2 PREDICCIÓN DE LA CONDICIÓN DEL PAVIMENTO .....	3
1.3 PRIORIZACIÓN DE ACTUACIONES .....	4
<b>2. OBJETIVOS</b> .....	<b>6</b>
<b>3. METODOLOGÍA</b> .....	<b>7</b>
<b>4. INSPECCIÓN AUTOMATIZADA</b> .....	<b>7</b>
4.1 SISTEMA DE ADQUISICIÓN DE IMÁGENES.....	7
4.2 FILTRADO Y PROCESAMIENTO DE DATOS .....	10
4.3 OBTENCIÓN DE IMÁGENES DEL PAVIMENTO.....	11
<b>5. EVALUACIÓN DE LA CONDICIÓN DEL PAVIMENTO</b> .....	<b>12</b>
5.1 IDENTIFICACIÓN DE DETERIOROS .....	12
5.2 DETERMINACIÓN DE LA CONDICIÓN DEL PAVIMENTO .....	16
<b>6. PREDICCIÓN DE LA CONDICIÓN DEL PAVIMENTO</b> .....	<b>17</b>
6.1 INFLUENCIA DE LA EDAD DEL PAVIMENTO.....	18
6.2 INFLUENCIA DE LA CAPACIDAD DEL PAVIMENTO .....	19
6.3 INFLUENCIA DEL VOLUMEN DE TRÁFICO .....	21
6.4 INFLUENCIA DE LAS CONDICIONES CLIMÁTICAS .....	22
6.5 INFLUENCIA GLOBAL.....	24
<b>7. OPTIMIZACIÓN MULTIOBJETIVO</b> .....	<b>26</b>

<b>7.1</b>	<b>BASE DE DATOS DE ACTUACIONES DE MANTENIMIENTO.....</b>	<b>27</b>
<b>7.2</b>	<b>DEFINICIÓN DE CRITERIOS Y FUNCIONES OBJETIVO.....</b>	<b>29</b>
7.2.1	FUNCIÓN OBJETIVO 1: COSTE ECONÓMICO .....	29
7.2.2	FUNCIÓN OBJETIVO 2: EMISIONES.....	31
7.2.3	FUNCIÓN OBJETIVO 3: AFECCIÓN A LOS USUARIOS DE LA RED VIARIA.....	31
7.2.4	FUNCIÓN OBJETIVO 4: NIVEL DE IMPORTANCIA DE LAS VÍAS.....	31
7.2.5	FUNCIÓN OBJETIVO 5: MEJORA DEL ESTADO DE LAS ACTUACIONES O EFECTIVIDAD .....	32
<b>8.</b>	<b><u>TÉCNICAS DE DECISIÓN .....</u></b>	<b><u>32</u></b>
<b>9.</b>	<b><u>DESARROLLO DEL SOFTWARE .....</u></b>	<b><u>36</u></b>
9.1	REPRESENTACIÓN DE LA RED A TRAVÉS DE UN SIG .....	37
9.2	IDENTIFICACIÓN DE DAÑOS Y EVALUACIÓN DE LA CONDICIÓN DEL PAVIMENTO.....	37
9.3	PREDICCIÓN DEL DETERIORO .....	38
9.4	OPTIMIZACIÓN DE LA PLANIFICACIÓN DE LAS ACTUACIONES DE MANTENIMIENTO.....	39
<b>10.</b>	<b><u>CONCLUSIONES.....</u></b>	<b><u>40</u></b>
	<b><u>REFERENCIAS BIBLIOGRÁFICAS .....</u></b>	<b><u>42</u></b>

## Resumen

La red vial es uno de los mayores bienes patrimoniales de un país y proporciona una base fundamental para su desarrollo económico y social. Al mismo tiempo, su construcción, mantenimiento y explotación produce un significativo impacto medioambiental. Por ello, el mantenimiento de una red vial en buen estado es vital para reducir costes de transporte de personas y bienes, así como para no incurrir en sobrecostes por mantenimientos tardíos que obligan a una rehabilitación o reconstrucción. En este sentido, es necesario promover una adecuada gestión que proporcione y mantenga los pavimentos en condiciones aceptables para los usuarios al menor coste de ciclo de vida. Sin embargo, la gestión actual del pavimento urbano se caracteriza, principalmente, por: (i) inexistencia de métodos eficientes para la detección de daños debido principalmente a la subjetividad de la metodología actual basada en la inspección visual y la insuficiencia de datos históricos; (ii) carencia de mantenimiento predictivo debido a la escasez y dispersión de modelos de predicción del deterioro; y (iii) ausencia de factores relacionados con la sostenibilidad social y medioambiental en la toma de decisiones.

De aquí surge el proyecto SIMEPU – “Sistema Integral de Mantenimiento Eficiente de Pavimentos Urbanos”, financiado por el Ministerio de Ciencia, Innovación y Universidades en la convocatoria “Retos-Colaboración 2017”, cuyo objetivo principal es diseñar una nueva herramienta para la monitorización, evaluación y predicción automática de la condición de pavimentos urbanos a partir del procesado de imágenes procedentes de sistemas de bajo coste que permita la optimización y priorización de las actuaciones de mantenimiento bajo condicionantes económicos, sociales y medioambientales.

Esta herramienta, que está basada en un Sistema de Información Geográfica, incorpora diversos modelos que han sido desarrollados específicamente en el marco de este proyecto y permiten: (i) la automatización de las tareas de auscultación a través de la obtención de imágenes con cámaras convencionales y procesamiento posterior de las mismas mediante técnicas de aprendizaje profundo, evitando la subjetividad derivada de la inspección visual y reduciendo tiempos y costes de la evaluación del pavimento; (ii) la homogeneización de la predicción futura del estado del firme al incorporar, además de variables técnicas, variables relacionadas con el volumen de tráfico, la precipitación y la temperatura, favoreciendo la aplicación del software desarrollado a otras regiones geográficas; y (iii) la incorporación de un modelo de optimización y toma de decisiones que incluye criterios como las emisiones de CO<sub>2</sub> o la proximidad a infraestructuras de desarrollo social y económico con el fin de reducir los costes también desde una perspectiva social y medioambiental.

Además, cabe destacar que el software ha sido diseñado con el fin de ofrecer al usuario una interfaz y una visualización gráfica sencilla de los resultados que se van obteniendo a lo largo de las diferentes etapas que se deben llevar a cabo para obtener una planificación óptima de las

actuaciones de mantenimiento. En este sentido, el software muestra, en primer lugar, cuál es el estado actual de la red tomando como input la grabación en vídeo del pavimento de un determinado tramo de la red o de la totalidad de la misma. A partir de la condición actual del pavimento, el software es capaz de predecir el estado futuro de la red vial en base a los modelos de predicción que incorpora. Finalmente, el software permite determinar cuál es la planificación óptima de las actuaciones de mantenimiento y rehabilitación en base a una optimización multiobjetivo que considera, junto a los habituales criterios económicos y técnicos, criterios relacionados con la afección a los ciudadanos, las emisiones de CO2 relacionadas con la actuación y la proximidad a puntos de interés.

Como conclusión, el desarrollo del proyecto SIMEPU ha permitido el desarrollo de una aplicación sencilla basada principalmente en una interfaz visual muy amigable para el usuario que permite:

- la identificación y cuantificación de deterioros en el pavimento de manera automática;
- conocer cuál será el estado de la red en un futuro; y
- establecer una programación eficiente y proactiva de las actuaciones de mantenimiento y rehabilitación del pavimento urbano a medio-largo plazo.

## 1. Introducción

La red vial es uno de los mayores bienes patrimoniales de un país y proporciona una base fundamental para su desarrollo económico y social. Al mismo tiempo, su construcción, mantenimiento y explotación produce un significativo impacto medioambiental (Santero y Horvath, 2009). Por ello, el mantenimiento de una red vial en buen estado es vital para reducir costes de transporte de personas y bienes (Bull, 2003), así como para no incurrir en sobrecostes por mantenimientos tardíos que obligan a una rehabilitación o reconstrucción (Hajj et al., 2010). En este sentido, es necesario promover una adecuada gestión que proporcione y mantenga los pavimentos en condiciones aceptables para los usuarios al menor coste de ciclo de vida (AASHTO, 2011).

La gestión de pavimentos tiene como objetivo fundamental la utilización de información segura y consistente para el desarrollo de criterios de decisión, planteamiento de alternativas realistas de inversión y contribución a la eficiente toma de decisiones. Por tanto, un Sistema de Gestión de Pavimentos (SGP) eficiente es aquel capaz de mantener la red de carreteras en un nivel de servicio aceptable, permitiendo bajos costes a sus usuarios y utilizando el menor presupuesto posible, sin afectar de manera significativa al medio ambiente, a la seguridad vial y a las actividades de la sociedad (Fwa et al., 2000). Estos requisitos definen los objetivos y restricciones del sistema, que es comúnmente resumido de manera esquemática a través de la Figura 1.



Fig. 1 – Esquema de un Sistema de Gestión de Pavimentos (FHWA, 1999).

A la vista de las distintas etapas o fases de las que consta un SGP, se deben destacar tres operaciones fundamentales: (i) la evaluación de la condición del pavimento; (ii) la predicción de la condición del pavimento; y (iii) la priorización de actuaciones de acuerdo a ciertos objetivos y

restricciones. Así pues, los siguientes epígrafes presentan cuál es la práctica actual en cada uno de estos campos relacionados con el mantenimiento de pavimentos urbanos.

### 1.1 Evaluación de la condición del pavimento

Un aspecto importante del mantenimiento de pavimentos es la evaluación de su condición. Para ello existen dos tipos de inspección: (1) inspección mediante auscultaciones y (2) inspección visual. Mientras que la inspección mediante auscultaciones está basada principalmente en indicadores objetivos obtenidos a través de ciertos instrumentos de medida estándar, la inspección visual se lleva a cabo mediante la experiencia profesional de técnicos que evalúan el estado del pavimento a partir de su apariencia, lo que introduce cierta subjetividad en la evaluación del daño.

A pesar de dicha subjetividad, en el entorno urbano el método más común de inspección es el visual, principalmente, debido a la dificultad de obtener indicadores objetivos en un entorno caracterizado por la presencia de intersecciones, variaciones significativas de la velocidad de circulación y fluctuaciones importantes del tráfico (Reggin et al., 2008; Wang et al., 2013). Para minimizar la subjetividad ligada a la inspección visual, esta debe basarse en criterios lo más sencillos posibles (Kraemer et al., 2004). Para ello, un apoyo fundamental son los catálogos de firmes o manuales en los que aparecen los tipos de deterioros con imágenes, descripciones y modos de cuantificación.

No obstante, el tratamiento automático de imágenes se postula como el futuro de la evaluación de la condición del pavimento, puesto que permite desarrollar modelos capaces de realizar de manera objetiva y automática dicha evaluación (Maeda et al., 2018). Estos métodos destacan por su versatilidad, ya que no son únicamente capaces de brindar buenos resultados en tareas de clasificación, sino que suministrando la información de forma correcta el modelo puede detectar objetos dentro de una imagen y segmentar el área que estos ocupan.

Los primeros estudios llevados a cabo sobre la detección de deterioros en el pavimento a través de imágenes se centraron fundamentalmente en la identificación, clasificación y cuantificación de grietas mediante algoritmos de procesamiento digital de imágenes (Chambon y Moliard, 2011; Zou et al., 2012; Oliveira y Correia, 2013; Amhaz et al., 2016; Shi et al., 2016). Sin embargo, en los últimos años ha cobrado especial relevancia la detección y evaluación automatizada de deterioros a partir de métodos basados en técnicas de aprendizaje profundo o Deep Learning, más concretamente a través del entrenamiento de Redes Neuronales Convolucionales (Zhang et al., 2016; Wang y Hu, 2017; Cha et al., 2017; Jenkins et al., 2018; Carr et al., 2018; Park et al., 2019).

Finalmente, en cuanto a los distintos indicadores para evaluar el estado del pavimento, cabe destacar el Índice de Condición del Pavimento (*PCI, Pavement Condition Index*), que es una de

las metodologías más conocidas y empleadas a nivel mundial para la evaluación y calificación de pavimentos flexibles y rígidos (ASTM, 2018). De hecho, este índice ha sido recientemente considerado por la Asociación Española de la Carretera para el desarrollo de la guía de firmes para las carreteras locales (AEC, 2020). Esta metodología, que no requiere de herramientas especializadas, se basa en la evaluación de un total de 19 tipos de daños, determinando su severidad y midiendo su cantidad. De esta manera se obtiene un índice numérico que varía desde 0, para los pavimentos que se encuentran en mal estado, hasta 100, indicando los pavimentos que se encuentran en perfecto estado.

## 1.2 Predicción de la condición del pavimento

Otro aspecto importante a la hora de determinar sobre qué vía actuar es conocer el estado del pavimento a corto y largo plazo. Para ello es imprescindible disponer de modelos que permitan predecir cómo una determinada vía va a deteriorarse a lo largo del tiempo.

A lo largo de la vida útil de un firme, estos son sometidos a diversas solicitaciones que provocan el deterioro del mismo. Estas no solo se deben al paso del tráfico, sino también a las condiciones climatológicas, como por ejemplo las acciones térmicas o los fenómenos de erosión e infiltración. Por ello, es primordial predecir el estado futuro del firme para poder actuar a tiempo y no incurrir en sobrecostos ni en riesgos adicionales.

En este sentido, George et al. (1989) señalaron que la medición y predicción del rendimiento de un pavimento debe ser un elemento crítico de cualquier sistema de gestión de pavimentos. Por tanto, los modelos de predicción de la condición del pavimento cobran especial relevancia en los sistemas de gestión de infraestructuras permitiendo una efectiva planificación presupuestaria a largo plazo así como la posibilidad de coordinar actividades de mantenimiento.

Los distintos métodos o modelos para predecir la condición del pavimento se pueden agrupar en las siguientes categorías: (i) regresiones numéricas, (ii) redes neuronales; (iii) modelos bayesianos; y (iv) cadenas de Markov y simulaciones de Monte Carlo (Osorio-Lird et al., 2018; Ragnoli et al., 2018). Aunque la calibración de modelos de regresión requiere una gran cantidad de datos históricos, estos han sido los más empleados debido a que permiten a los ingenieros de carreteras predecir de manera sencilla la condición del pavimento y entender la influencia de los parámetros o factores introducidos en el modelo (Arambula et al., 2011; Dong et al., 2014; Hassan et al., 2015). Ante las debilidades de los modelos de regresión, surgen los métodos basados en cadenas de Markov y simulaciones de Monte Carlo, que son capaces de representar adecuadamente el proceso de degradación del pavimento a lo largo del tiempo mediante el uso de una matriz de transición de probabilidades (Hassan et al., 2015; Osorio-Lird et al., 2018; Moreira et al., 2018). No obstante, estos métodos presentan dos importantes desventajas: (i) su desarrollo requiere la evaluación de la condición del pavimento en un número suficiente de tramos a lo largo de, al menos, cinco años; y (ii) no es posible conocer las causas del deterioro.

Finalmente, es importante resaltar que diversas investigaciones indican que las variables meteorológicas, como la temperatura y la precipitación, poseen un gran impacto en el deterioro del pavimento (Qiao et al., 2013; Mohd Hasan et al., 2016). Sin embargo, la mayoría de los modelos de predicción han sido desarrollados para una cierta región o país con condiciones del tráfico similares, por lo que no incluyen variables esenciales como pueden ser los factores climáticos.

### 1.3 Priorización de actuaciones

Una vez evaluada la condición del pavimento y su evolución a lo largo del tiempo, la última etapa del proceso de gestión del mantenimiento de pavimentos tiene como objetivo determinar en qué vías actuar. En este sentido, se han llevado a cabo distintos estudios con objetivos o estrategias diferentes.

Torres-Machi et al. (2017) plantean como objetivos la maximización de la efectividad a largo plazo y la minimización de las emisiones de gases de efecto invernadero. Como restricciones incluye que el presupuesto a utilizar no puede ser mayor al disponible y que la condición, que hace referencia al estado del pavimento, no puede ser menor a un umbral mínimo establecido. Bajo este esquema se realiza una búsqueda de la óptima combinación de mantenimiento de cada vía en un periodo determinado de análisis. Los autores concluyeron que el uso de la herramienta desarrollada permite, con un presupuesto similar, incrementar hasta un 22% la efectividad del tratamiento y disminuir un 12% las emisiones de gases de efecto invernadero a la atmósfera.

Otra investigación interesante en este ámbito es la desarrollada por Meneses y Ferreira (2015), que buscan minimizar los costes de mantenimiento y rehabilitación y maximizar el valor residual de la red de pavimentos considerando como restricciones el umbral mínimo de condición y el presupuesto máximo anual.

Por otro lado, Wu y Flintsch (2009) proponen una optimización multiobjetivo cuya función objetivo se define a partir de la maximización del nivel de servicio de la red vial y la minimización del coste de rehabilitación y mantenimiento. Las restricciones consideradas fueron: (i) no superar un presupuesto anual, (ii) mantener menos del 10% de la red vial por debajo de un umbral mínimo, (iii) alcanzar un nivel de servicio al año horizonte no menor al del año cero, (iv) no permitir que más de la cuarta parte de la red vial reciba tratamientos cada año, y (v) no permitir que más del 15% de la red vial reciba mantenimiento de carácter preventivo anualmente.

Estas investigaciones previas están basadas en estrategias óptimas de mantenimiento a largo plazo. Sin embargo, Espinoza (2019) plantea una toma de decisiones anual que priorice las vías y seleccione aquellas sobre las que se debe actuar cada año en base al presupuesto disponible.

Para ello, los criterios a tener en cuenta son: (i) confort de los usuarios; (ii) coste de accidentalidad; (iii) eficiencia económica de la actuación; (iv) proximidad a infraestructura social y turística; (v) eficiencia ambiental de la actuación; y (vi) molestias generadas con la actuación.

A pesar de que son diversos y de distinta naturaleza los factores o criterios que estas investigaciones proponen a la hora de priorizar las actividades de mantenimiento de pavimentos, en la práctica son muy pocas las administraciones que tratan de aplicar este tipo de análisis multiobjetivo. En este sentido, la mayoría de las administraciones actúan de forma reactiva, es decir, toman las decisiones tras la observación de una degradación evidente del pavimento debido principalmente al escaso presupuesto destinado a estas operaciones fruto de la crisis económica sufrida en la última década.

En resumen, la gestión actual del pavimento urbano se caracteriza por: (i) heterogeneidad de la estructura del firme; (ii) diferencias jerárquicas en la red vial; (iii) limitados recursos económicos; (iv) inexistencia de métodos eficientes para la detección de daños debido principalmente a la subjetividad de la metodología actual basada en la inspección visual y la insuficiencia de datos históricos; (v) carencia de mantenimiento predictivo debido a la escasez y dispersión de modelos de predicción del deterioro; y (vi) ausencia de factores relacionados con la sostenibilidad social y medioambiental en la toma de decisiones.

De aquí surge el proyecto SIMEPU – “Sistema Integral de Mantenimiento Eficiente de Pavimentos Urbanos”, financiado por el Ministerio de Ciencia, Innovación y Universidades en la convocatoria “Retos-Colaboración 2017”, cuyo objetivo principal es diseñar una nueva herramienta para la monitorización, evaluación y predicción automática de la condición de pavimentos urbanos a partir del procesado de imágenes procedentes de sistemas de bajo coste que permita la optimización y priorización de las actuaciones de mantenimiento bajo condicionantes económicos, sociales y medioambientales.

De esta forma, el producto permitirá la implantación de un sistema integral de mantenimiento de pavimentos en entornos urbanos que, a partir de imágenes procedentes de dispositivos colocados en vehículos públicos, facilitará la optimización y la priorización de las actuaciones de mantenimiento de la red en base a criterios sostenibles.

## 2. Objetivos

El objeto fundamental de esta investigación es la propuesta de una nueva metodología para el mantenimiento de pavimentos urbanos que incorpore: (i) una evaluación automatizada del estado del pavimento a través del tratamiento de imágenes captadas con un sistema de bajo coste mediante técnicas de aprendizaje profundo; (ii) una predicción del estado del pavimento basada en variables operacionales y climáticas; y (iii) una optimización y toma de decisiones multiobjetivo para la elección óptima de las actividades de mantenimiento en base a criterios económicos, técnicos, sociales y medioambientales.

Para ello, se han definido los siguientes objetivos secundarios:

- Análisis bibliográfico del estado del conocimiento sobre modelos de predicción de la condición del pavimento, sistemas de detección automática de daños en el pavimento, modelos de decisión multiobjetivo para la priorización de alternativas.
- Evaluación de distintos sistemas de captación de imágenes de bajo coste para la evaluación automática de la condición del pavimento a través de técnicas de procesamiento digital de imágenes.
- Obtención de imágenes de daños en pavimentos urbanos para el desarrollo de una base de datos a partir del sistema de captación de imágenes de bajo coste propuesto.
- Entrenamiento de una Red Neuronal Convolutiva para la detección y cuantificación automática de los daños del pavimento a través del procesamiento digital de imágenes.
- Desarrollo de modelos de regresión para la predicción de la condición del pavimento urbano en base a variables climáticas, operacionales y estructurales.
- Definición de los criterios económicos, técnicos, sociales y medioambientales a incorporar en el modelo de optimización multicriterio.
- Programación de algoritmos para la optimización y toma de decisiones multiobjetivo que permita una priorización de las actuaciones de conservación y mantenimiento del pavimento urbano.
- Desarrollo de un software gráfico que incorpore todas las herramientas desarrolladas con el fin de tener una interfaz fácil y útil para los ingenieros, principalmente, de las administraciones que se encarguen de la tarea de la rehabilitación y conservación de la red vial.

### 3. Metodología

La metodología propuesta para la gestión eficiente de pavimentos urbanos se define a partir de cinco etapas: (1) inspección automática de pavimentos urbanos mediante cámaras; (2) evaluación de la condición del pavimento a través de técnicas de procesamiento de imágenes basadas en Redes Neuronales Convolucionales; (3) predicción de la condición del pavimento; (4) optimización multiobjetivo basada en criterios económicos, técnicos, sociales y medioambientales; y (5) técnicas de decisión para la priorización de actuaciones de acuerdo a las características de la red vial (Figura 2).

Adicionalmente, se desarrolla una última fase de desarrollo de un software que incorpora todas las fases o etapas definidas y muestra de manera gráfica los resultados obtenidos en cada una de estas. Este software, basado en un sistema GIS, permite la consulta visual de la inspección obtenida mediante el sistema de captación de imágenes, el conocimiento actual y futuro de la condición del pavimento de cada segmento de vía de la red y la visualización del resultado de la priorización de actuaciones fruto de la aplicación de la optimización multiobjetivo.

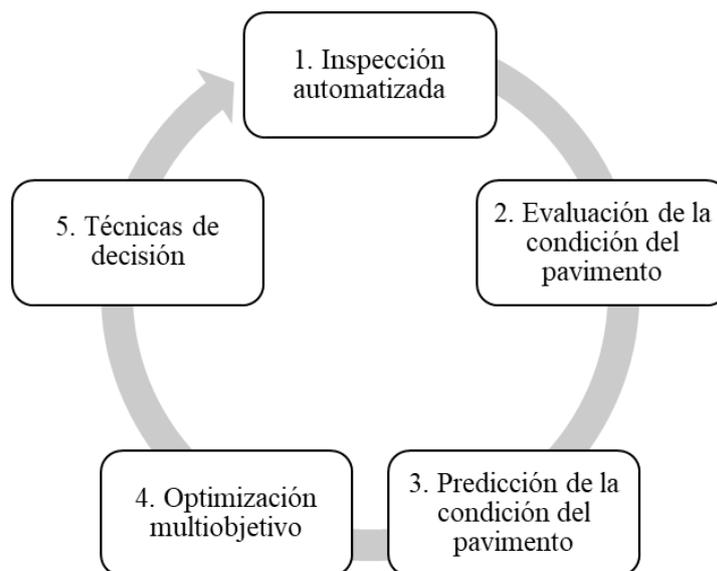


Fig. 2. Esquema de la metodología propuesta.

### 4. Inspección automatizada

#### 4.1 Sistema de adquisición de imágenes

Hasta la fecha, los estudios llevados a cabo para la detección automática de deterioros en el pavimento a través de imágenes se han centrado fundamentalmente en la identificación, clasificación y cuantificación de grietas, a pesar de que unos pocos estudios también han incorporado métodos de detección para el parcheo y los huecos. Sin embargo, el proyecto

SIMEPU se desarrolló en base a la identificación y cuantificación de todos aquellos deterioros que pudiesen ser detectados en base a imágenes 2D. De esta manera, se han considerado las siguientes tipologías de daños: (i) grietas longitudinales, (ii) grietas transversales, (iii) grietas en forma de piel de cocodrilo, (iv) meteorización y desprendimiento, (v) huecos y (vi) parcheo. A todos estos, se suman, además, las categorías definidas como (vii) alcantarillado, (viii) marcas viales y (ix) pavimento sin daños.

En cuanto a los sistemas de adquisición de imágenes, se puede diferenciar entre imágenes estáticas y grabación de videos. En este sentido, cabe destacar que la mayoría de las investigaciones realizadas hasta la fecha han empleado imágenes estáticas tomadas con cámaras convencionales o smartphones con resoluciones variables, desde 960 x 704 hasta 6.010 x 4.000. Solo unos pocos estudios se han desarrollado mediante videocámaras instaladas en vehículos, en cuyo caso es preferible situar dicho dispositivo en la parte trasera del vehículo de manera que el eje óptico de la videocámara sea perpendicular a la superficie del pavimento.

En cuanto a la frecuencia de toma de imágenes de las videocámaras, esta dependerá principalmente de la velocidad del vehículo con la que se realice la grabación. A mayor velocidad del vehículo, mayor deberá ser la frecuencia con el fin de obtener imágenes de toda la sección de carretera recorrida. En este sentido, suponiendo que el ancho de la imagen ( $w_i$ ) que posteriormente será procesada es de 1 m y la velocidad máxima del vehículo es 50 km/h ( $v$ ) en entorno urbano, la frecuencia requerida es aproximadamente de 15 fps ( $f = v/w_i$ ).

En base a los resultados de investigaciones previas, se llevó a cabo una prueba piloto con tres videocámaras convencionales de bajo coste y empleando diferentes modos de grabación con el fin de comparar la calidad de las imágenes obtenidas para su posterior tratamiento para la identificación de los deterioros presentes en el pavimento. Concretamente, se evaluaron las videocámaras *Garmin Virb Elite*, *GoPro Hero 3 Black* y *Garmin Dash Cam 45* bajo los modos de grabación que se indican en la Tabla 1.

Dispositivo	Modo de grabación
<i>Garmin Virb Elite</i>	1080p
<i>GoPro Hero 3 Black</i>	1080p
<i>GoPro Hero 3 Black</i>	4K
<i>Garmin Dash Cam 45</i>	1080p

Tabla 1. Modos de grabación evaluados en la prueba piloto.

Como se puede observar, la comparación entre las diferentes videocámaras se realizó principalmente considerando el modo de grabación 1080p. No obstante, también se llevó a cabo una grabación en 4K mediante la *GoPro Hero 3 Black* con el fin de determinar si la calidad de imagen obtenida con este modo de grabación era necesaria o suponía una mejora significativa

a la hora de identificar los daños en el pavimento. Finalmente, destacar que la frecuencia de toma de imágenes considerada en las pruebas fue entre 30 y 60 fps, la cual era muy superior a la mínima necesaria (15 fps) al circular por entorno urbano.

Como conclusión, se obtuvo que el modo 1080p ofrece una calidad de imagen suficiente para la evaluación de los deterioros y no es necesaria la utilización de imágenes obtenidas de grabaciones en modo 4K, la cual ralentizarían significativamente los tiempos de entrenamiento y ejecución de la red convolucional debido principalmente al gran tamaño de estas imágenes sin una mejora sustancial en la identificación de deterioros.

A pesar de que los tres dispositivos eran capaces de obtener imágenes de gran calidad, es necesario destacar que la *Garmin Virb Elite* y la *GoPro Hero 3 Black* presentan una importante ventaja en cuanto a la duración de la batería con respecto a la *Garmin Dash Cam 45*. Mientras las dos primeras están pensadas para su uso como cámaras de acción, por lo que garantizan una grabación superior a las 2 horas y una mejor estabilización de las imágenes reduciendo el ruido de las mismas, la última está diseñada para ser conectada a la alimentación del coche y estar en funcionamiento en la parte frontal interior del vehículo.

Asimismo, la videocámara *Garmin Virb Elite* presenta dos interesantes ventajas frente a las otras dos videocámaras evaluadas, ya que permite manejarla vía Wifi desde el interior del vehículo y es capaz de almacenar la trayectoria GPS del vehículo con una frecuencia de 1 Hz. Esto último supone la geolocalización de las imágenes captadas de manera cuasiautomática. Estas características hacen que esta videocámara sea la propuesta para el desarrollo del nuevo sistema de captación de imágenes.

Sin embargo, debido a que esta videocámara ya no se encuentra en el mercado, se propuso la sustitución de esta por el nuevo modelo que ofrece *Garmin* con las mismas prestaciones, la videocámara *Garmin Virb Ultra 30* que permite grabar con una resolución de 1920x1080 a 30 fps, con estabilizador de imagen, corrección de objetivo, GPS y conexión WIFI para control remoto (Figura 3). Esta cámara es colocada en la parte trasera del vehículo de manera que permita una grabación cenital del pavimento a partir de un sistema de ventosas y barras rígidas, con la ayuda de unos tirantes para evitar la caída del sistema en caso de fallo.



Fig. 3. Sistema de adquisición de imágenes.

#### 4.2 Filtrado y procesamiento de datos

Una vez realizada la toma de datos, cada uno de los videos obtenidos junto a su correspondiente archivo de geolocalización debe ser procesado. Esta etapa tiene como objetivo la extracción de fotogramas del video. Debido a que la velocidad de toma de datos es de 50 km/h y que la cámara está grabando a 30 fps, si se quiere obtener una imagen del pavimento cada metro, es suficiente obtener una imagen cada dos fotogramas.

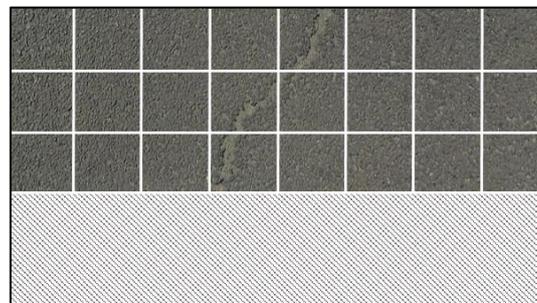
Finalmente, se lleva a cabo el proceso de filtrado de imágenes, con el objeto de eliminar las zonas de la imagen que no contengan información relevante para la identificación y evaluación de los deterioros presentes en el pavimento. Las imágenes estudiadas tendrán un ancho lineal de un metro. Por tanto, la información no contenida en dicho ancho, así como la información relativa a los otros carriles de circulación, se descartará (Figura 4).



(a) imagen bruta



(b) imagen filtrada



(c) matriz de imágenes a analizar

Fig. 4. Filtrado de imágenes.

Cabe destacar que tanto el procesamiento de los vídeos como el filtrado de las imágenes se realiza de manera automática a través de scripts programados en Python.

### 4.3 Obtención de imágenes del pavimento

Para la obtención de las imágenes del pavimento se desarrolló una metodología de toma de datos y tratamiento de imágenes basada en los procesos anteriormente descritos (Figura 5).



Fig. 5. Metodología de toma de datos.

Siguiendo esta metodología, el día 24 de julio de 2019, desde las 10:45 horas hasta las 13:45 horas, se recorrieron alrededor de 65 km de vía de la ciudad de Valencia (Figura 6). Como resultado, se obtuvieron 90,1 GB de información en 9 vídeos de 186 minutos de duración y 167.784 imágenes para la caracterización de los daños.

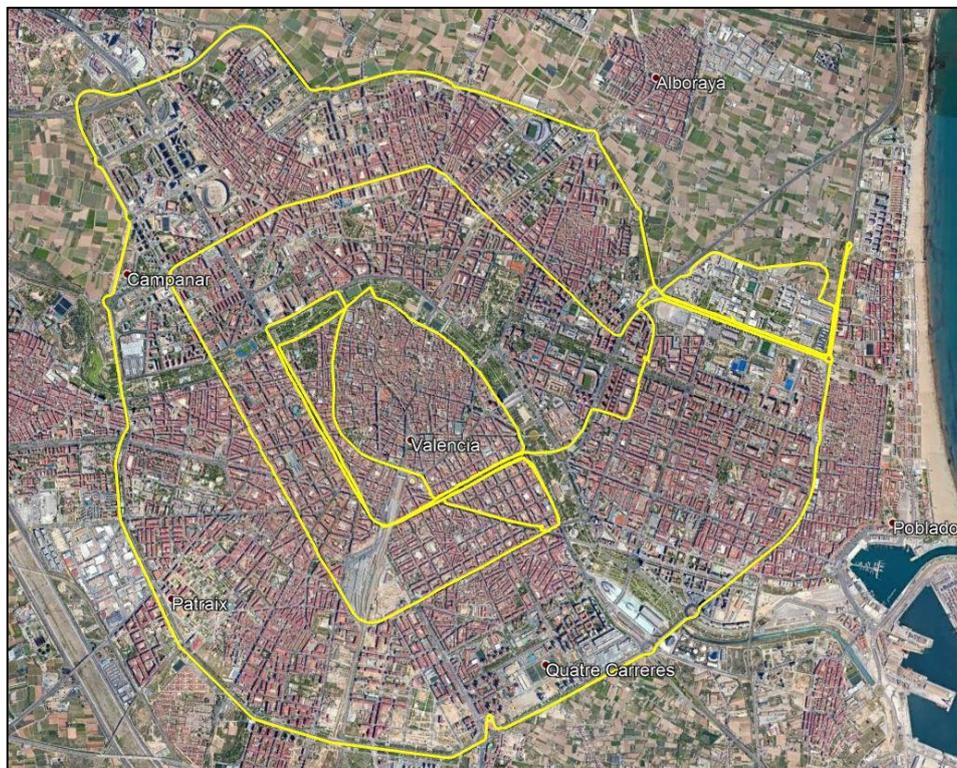


Fig. 6. Itinerario de toma de datos.

A partir de estas imágenes se desarrolló una base de datos de imágenes que servirían posteriormente para el entrenamiento y calibración de la Red Neuronal Convolucional que se ocupará más adelante de la identificación y cuantificación automática de los deterioros urbanos. En resumen, se obtuvieron el siguiente número de imágenes para cada deterioro: 1.201 de grietas longitudinales, 1.206 de grietas transversales, 195 de grietas en forma de piel de cocodrilo, 421 de meteorización y desprendimiento, 690 de huecos, 709 de parcheo, 972 de alcantarillado, 1.810 de marca vial y 2.560 sin daño.

## 5. Evaluación de la condición del pavimento

La etapa de evaluación de la condición del pavimento se divide en dos fases: (i) identificación de deterioros; y (ii) determinación de la condición del pavimento.

### 5.1 Identificación de deterioros

Un problema común al aplicar técnicas de aprendizaje profundo es la gran cantidad de datos que se necesita en la fase de entrenamiento para conseguir una adecuada generalización. Para hacer frente a esto, se utilizaron diferentes técnicas de aumentado de datos (*Data augmentation*). Estas técnicas consisten en realizar ligeras transformaciones a las imágenes de entrenamiento para crear nuevas imágenes lo suficientemente similares a las originales manteniendo así la clase original, pero introduciendo algunas variaciones para lidiar con nuevos factores que pueden no estar significativamente representados en el conjunto de datos original. Estas transformaciones se realizan iterando sobre el conjunto de datos de entrenamiento. Una vez modificadas las imágenes, estas se utilizan para el aprendizaje de la red y, finalmente, se descartan.

Las técnicas de aumentado de datos aplicadas en esta investigación fueron: (i) *Random Crop*, que consiste en tomar aleatoriamente una parte de la imagen original, (ii) *Horizontal Flip*, que voltea horizontalmente la imagen, y (iii) *Color Jitter*, que introduce ligeras modificaciones en brillo, contraste y saturación para simular variaciones de iluminación.

Para la caracterización de las imágenes se utilizó un procedimiento de dos pasos para reducir el número de falsos positivos (Figura 7). Primero, una red neuronal convolucional (CNN1) clasifica cada imagen en "dañada" o "no dañada" (sin deterioro del pavimento, marcas viales y alcantarillado), es decir, identifica si una imagen incluye algún tipo de daño o no. Posteriormente, las imágenes clasificadas como "dañadas" se introducen en una segunda red neuronal convolucional (CNN2) para identificar el tipo de deterioro (grieta longitudinal, grieta transversal, agrietamiento en forma de piel de cocodrilo, meteorización, hueco y parcheo).

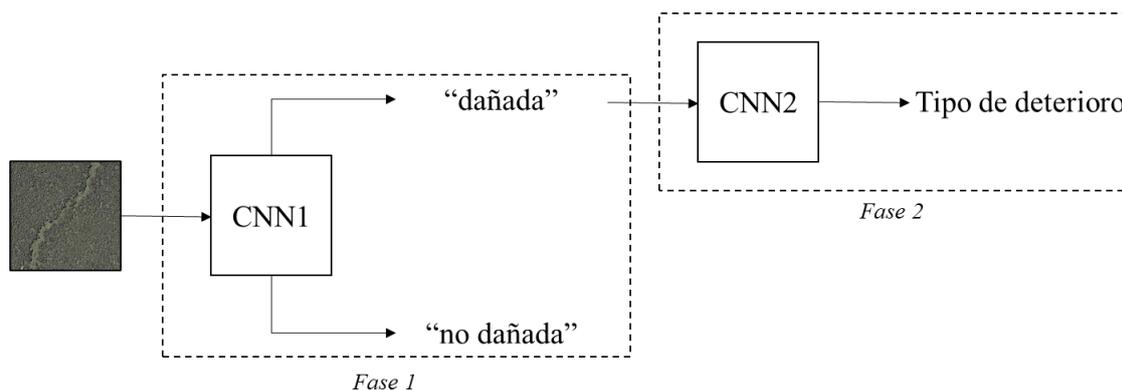


Fig. 7. Procedimiento de identificación de daños en dos fases.

Ambas redes se basan en una arquitectura ResNet (Figura 8), que fue presentada por He et al. (2016) y se ha aplicado a una variedad de problemas de clasificación de imágenes proporcionando excelentes resultados (Carr et al., 2018). Para la etapa de entrenamiento se consideró el algoritmo de optimización de Adam, que combina las mejores propiedades de los algoritmos AdaGrad y RMSProp para proporcionar un algoritmo de optimización que puede manejar gradientes escasos en problemas ruidosos (Kingma y Ba, 2015) y la función de pérdida de entropía cruzada. Los pesos previamente entrenados de ResNet en ImageNet, que es un esfuerzo de investigación en curso para proporcionar a los investigadores de todo el mundo una base de datos de imágenes de fácil acceso (Russakovsky et al., 2015), se utilizaron como valores iniciales para la formación. Para ello, las imágenes se redimensionaron a 224 x 224 píxeles para que coincidan con la configuración de ImageNet y se seleccionó una tasa de aprendizaje de 0,0001. Finalmente, se utilizó una validación cruzada para estimar la habilidad del modelo en nuevos datos.

En particular, esta investigación utiliza una arquitectura ResNet34 (Figura 8). La primera etapa en esta red, antes de ingresar al comportamiento de la capa común, es un bloque (Conv1) que consiste en una operación de convolución, normalización por lotes y agrupación máxima basada en un tamaño de kernel de 7 y un tamaño de mapa de características de 64. Teniendo esto en cuenta, el tamaño de salida de esa operación será un volumen (112 x 112). Dado que cada filtro de convolución (de los 64) proporciona un canal en el volumen de salida, el resultado es (112x112x64) volumen de salida. El siguiente paso es la normalización por lotes, que es una operación por elementos y, por lo tanto, no cambia el tamaño del volumen. De esta manera, se aplica una operación de agrupación máxima (3 x 3) con un paso de 2.

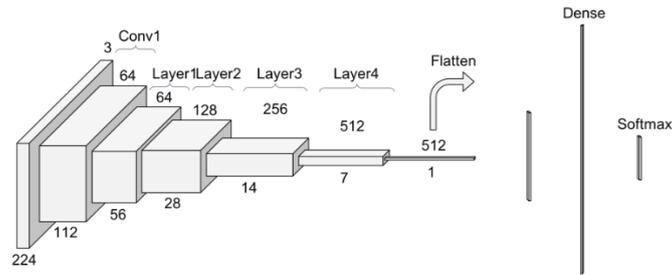


Fig. 8. Arquitectura de Red Neuronal Convolutiva ResNet34.

Posteriormente, la ResNet consta de cuatro bloques que siguen el mismo patrón. Cada bloque realiza una convolución de 3 x 3 con una dimensión de mapa de características fija (64, 128, 256, 512) respectivamente, omitiendo la entrada cada 2 convoluciones. Además, las dimensiones de ancho y alto permanecen constantes durante toda la capa. Como resultado, se obtienen 32 capas ocultas que junto a las dos capas ocultas iniciales conforman 34 capas ocultas. Finalmente, se emplean una capa de agrupación promedio y una capa densa para extraer las características finales y clasificar la imagen. El número total de operaciones de coma flotante (FLOP) es  $3,6 \cdot 10^9$ .

Según la descripción anterior, CNN1 aborda un problema de clasificación binaria que tiene como objetivo reducir la cantidad de imágenes sin daño que podrían clasificarse como "dañadas" si una sola CNN hubiera sido capacitada para clasificar directamente las imágenes considerando cada tipo específico de deterioro del pavimento e imágenes sin daños. Para eso, una vez que la red está entrenada, se selecciona un umbral para establecer una tasa deseable de falsos positivos mediante el uso de la curva de características operativas del receptor (ROC). Específicamente, una curva ROC es un gráfico que muestra el desempeño de un modelo de clasificación en todos los umbrales de clasificación. Esta curva traza dos parámetros, Tasa de verdaderos positivos (TPR) y Tasa de falsos positivos (FPR), a partir de los cuales se selecciona el umbral con el objetivo de minimizar la FPR y garantizar un TPR alto. Después de esta clasificación binaria, CNN2 solo evalúa aquellas imágenes etiquetadas como "dañadas" para identificar el tipo de daño.

Los resultados obtenidos de la primera red de clasificación binaria proporcionan un 99,34% de precisión. La Figura 9 muestra la curva ROC para CNN1. En este sentido, un buen umbral es aquel que establece un 0,4% de falsos positivos, es decir, cuatro de cada 1.000 imágenes que no contienen deterioros se clasifican como "dañadas", siendo la precisión para los verdaderos positivos todavía muy alta (98,27%).

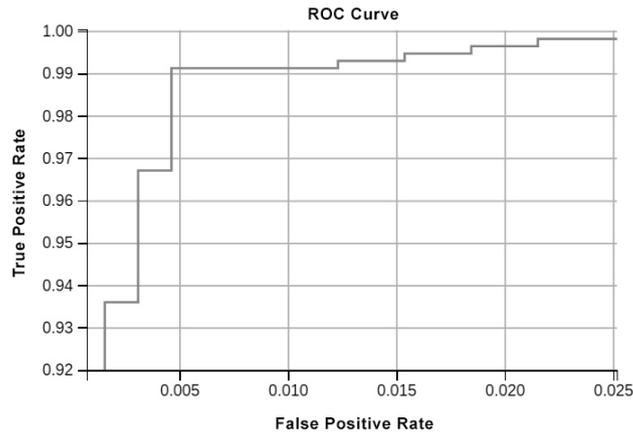


Fig. 9. Curva de características para la clasificación binaria (CNN1).

Por otro lado, CNN2, que se centra en un problema puramente de clasificación, arroja una precisión global del 99,14%. La Tabla 2 muestra la matriz de confusión. Como se puede observar en la diagonal principal de esta matriz, la tasa de aciertos para los diferentes tipos de deterioros es superior al 93%. Estos valores altos se deben principalmente a que las imágenes obtenidas para el entrenamiento tienen las mismas condiciones de iluminación, la cámara de video se colocó en una posición constante y los daños son suficientemente diferenciables. Esto es posible porque el estudio de la inspección del pavimento se puede replicar fácilmente, es decir, la toma de datos puede retrasarse esperando las condiciones climáticas y de iluminación óptimas. De esta manera, se puede obtener un conjunto de datos de alta calidad minimizando la intervariabilidad de las clases, lo que fomenta una clasificación de alta precisión y confiabilidad.

	Grieta longitudinal	Grieta transversal	Piel de cocodrilo	Meteorización	Huecos	Parcheo
Grieta longitudinal	1.0000	0.0000	0.0000	0.0000	0.0000	0.0000
Grieta transversal	0.0000	0.9839	0.0000	0.0000	0.0161	0.0000
Piel de cocodrilo	0.0000	0.0000	1.0000	0.0000	0.0000	0.0000
Meteorización	0.0238	0.0000	0.0000	0.9762	0.0000	0.0000
Huecos	0.0241	0.0000	0.0000	0.0241	0.9398	0.0120
Parcheo	0.0000	0.0000	0.0000	0.0000	0.0000	1.0000

Tabla 2. Matriz de confusión.

En cuanto a las clasificaciones incorrectas, el 1,6% de las imágenes de grietas transversales, principalmente de gran ancho de grietas, fueron etiquetadas como huecos, mientras que algunas imágenes clasificadas en primer lugar como meteorización y huecos se confundieron con grietas longitudinales. Estas últimas clasificaciones incorrectas se encontraron cuando el deterioro estaba particularmente en los bordes de la imagen. Además, algunos huecos que tomaban una gran área de la imagen se clasificaron erróneamente como meteorización y parches.

## 5.2 Determinación de la condición del pavimento

Una vez clasificada una imagen con daño, el siguiente paso es la cuantificación del mismo. Para ello se han calibrado distintas redes neuronales convolucionales para cada tipología de daño (Figura 10). A partir de estas redes se determina la longitud y amplitud de las grietas longitudinales y transversales, así como el área ocupada por el agrietamiento en forma de piel de cocodrilo, hueco y meteorización.

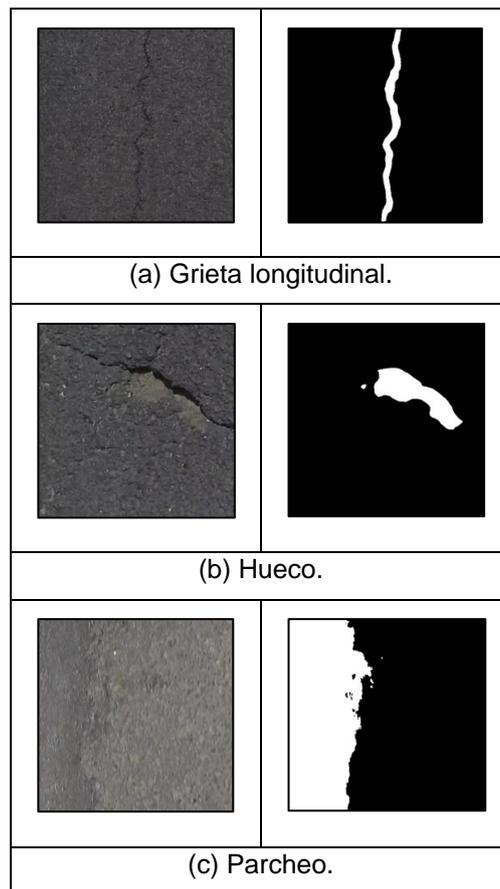


Figura 10. Cuantificación del daño.

En función de los valores obtenidos, cada uno de estos daños son calificados en distintos niveles de severidad según el Índice de Condición del Pavimento (*PCI, Pavement Condition Index*): baja, media y alta. El principal motivo del uso de este indicador es que es el más empleado y aceptado mundialmente y que, además, ha sido propuesto recientemente por la Asociación Española de la Carretera para el mantenimiento de carreteras locales (AEC, 2020).

Esta metodología, que no requiere de herramientas especializadas, se basa en la evaluación de un total de 19 tipos de daños, determinando su severidad y midiendo su cantidad. De esta manera se obtiene un índice numérico que varía desde 0, para los pavimentos que se encuentran en mal estado, hasta 100, indicando los pavimentos que se encuentran en perfecto estado. Entre estas 19 tipologías de daños se encuentran todas aquellas consideradas en esta investigación.

Finalmente, cabe destacar que el cálculo de este índice se ha programado de manera que una vez identificados y cuantificados los daños de una determinada sección de vía, que son agrupados en la red vial a partir de su geolocalización, se determina de manera automática el valor del PCI de la sección.

## 6. Predicción de la condición del pavimento

La predicción de la condición del pavimento permite predecir la condición futura del mismo con el fin de planificar acciones a largo plazo. Este paso es esencial para una programación eficiente del presupuesto tanto a corto como a largo plazo y para coordinar adecuadamente las actividades de mantenimiento en la red vial. Sin dicha programación y coordinación, seguramente el mantenimiento del pavimento sea más caro a largo plazo al mismo tiempo que se incurre en un peor estado de la red.

Como se ha descrito anteriormente, existen diferentes tipos de métodos para llevar a cabo la predicción de la condición del pavimento, presentando cada uno de ellos una serie de fortalezas y debilidades. En base a estas características, en esta metodología se propone el uso de modelos de regresión lineal con el fin de conocer qué factores o variables tienen una mayor influencia en el proceso de degradación del pavimento. En este sentido, cabe destacar el tráfico, la temperatura y la precipitación como los factores que mayor impacto tienen sobre el estado del pavimento y que serán considerados en la calibración de estos modelos.

Debido a que en España no se dispone de datos periódicos en cuanto a la evaluación del pavimento en área urbana, los primeros modelos se calibraron a partir de la base de datos americana proporcionada por el programa Long-Term Pavement Performance (LTPP). Esta base de datos contiene la evaluación del pavimento de multitud de secciones de vía urbana a lo largo de más de 20 años basándose, entre otros indicadores, en los deterioros incluidos en la estimación del parámetro PCI, que es el índice propuesto en esta metodología. Una vez puesta en marcha dicha metodología en una determinada ciudad o región, los modelos serán recalibrados de manera automática al mismo tiempo que se vayan tomando datos en la misma con la finalidad de conseguir modelos más precisos y adaptados a la región donde se está empleando la metodología propuesta.

Concretamente, para el desarrollo de estos primeros modelos se consideraron un total de 50 secciones de carretera urbana de Estados Unidos y Canadá, lo que supuso disponer de un total de 237 evaluaciones del pavimento. Para determinar los factores más importantes en el proceso de deterioro del pavimento se tuvieron en cuenta las siguientes variables junto a la edad del pavimento ( $p_a$ ):

- Capacidad del paquete de firme:

- Número estructural ( $SN$ ): es un valor numérico que indica la resistencia y capacidad del pavimento. De esta forma, la capacidad estructural del pavimento es mayor a medida que aumenta  $SN$  (AASHTO, 1993).
- Variables relacionadas con el tráfico:
  - Intensidad Media Diaria ( $IMD$ ) de tráfico (veh/día).
  - Intensidad Media Diaria ( $IMD_p$ ) de tráfico pesado (veh/día).
  - Carga equivalente de eje único ( $KESAL$ ) en miles.
- Variables con la climatología:
  - Precipitación anual media ( $AAP$ ) en mm, calculada como la precipitación de lluvia promedio anual (mm) durante la edad del pavimento ( $p_a$ ).
  - Altura anual media de nieve ( $AAS$ ), estimada como la precipitación de nieve promedio anual (mm) durante  $p_a$ .
  - Temperatura media anual ( $AAT$ ), obtenida como la temperatura media anual ( $^{\circ}C$ ) durante  $p_a$ .
  - Rango de temperatura medio anual ( $AART$ ), estimado como el promedio del rango de temperatura anual ( $^{\circ}C$ ) - calculado para cada año como la diferencia de temperatura entre el mes más frío y el más cálido - durante  $p_a$ .
  - Desviación estándar de temperatura ( $SDT$ ), calculada como la desviación estándar de la temperatura ( $^{\circ}C$ ) durante  $p_a$ .
  - Viento medio anual ( $W$ ), obtenido como la velocidad del viento promedio anual (km/h) durante  $p_a$ .
  - Humedad media anual ( $H$ ), estimada como la humedad media anual (%) durante  $p_a$ .

Para cada segmento de carretera y evaluación del pavimento se identificó las diferentes variables definidas anteriormente y se calculó el PCI en base al inventario de deterioros proporcionado. Con estos datos y empleando la técnica de validación cruzada *K-folds* se desarrollaron distintos modelos de regresión para determinar qué variables influyen significativamente en el deterioro de los pavimentos urbanos.

### 6.1 Influencia de la edad del pavimento

El factor principal en el proceso de deterioro del pavimento, que se considera un fenómeno estocástico, es la edad del pavimento ( $p_a$ ). Aunque este estudio consideró tramos de carretera caracterizados por condiciones de tráfico y climáticas muy diferentes,  $p_a$  pudo representar adecuadamente el proceso de deterioro del pavimento. La relación entre PCI y  $p_a$  se modeló mediante la Ecuación 1 que describe una disminución lineal de PCI a lo largo del tiempo (Figura 11). En concreto, el PCI de un tramo de carretera disminuye aproximadamente 5 unidades por año desde el primer año y medio de su construcción.

$$PCI = \text{Max}(0; \text{Min}(111,01 - 5,46 \cdot p_a; 100))$$

$$R_{test}^2 = 0,48 \quad (1)$$

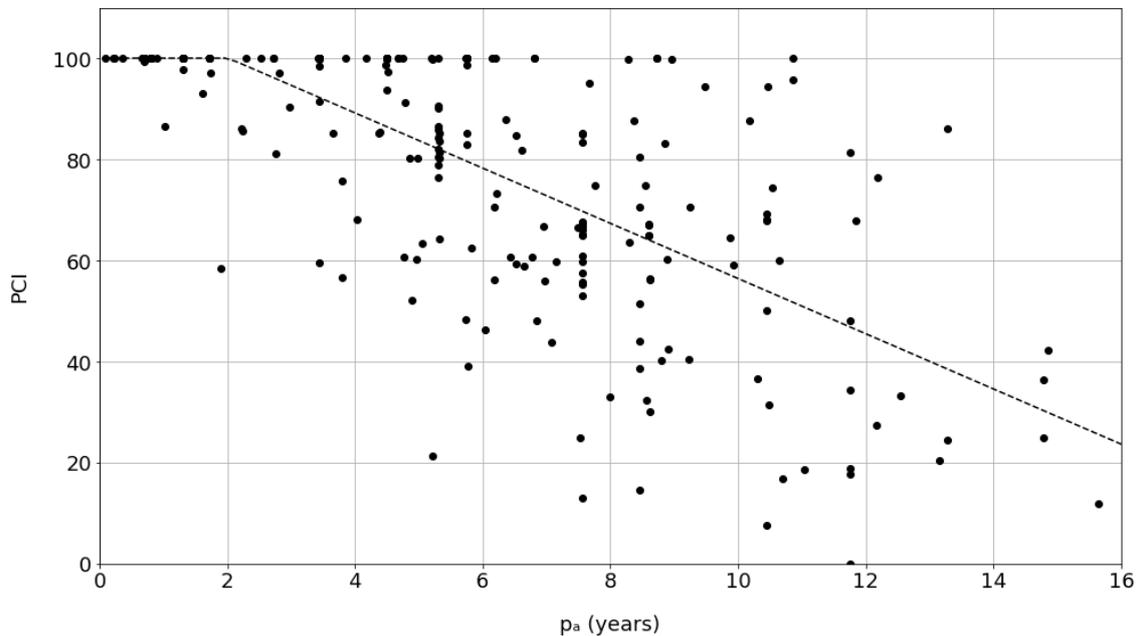


Fig. 11. Influencia de la edad del pavimento en el proceso de deterioro.

El modelo calibrado se limitó con un valor máximo de 100 y un valor mínimo de 0 según la definición del PCI. De esta forma se alcanzó un coeficiente de determinación de 0,48, lo que significa que la edad del pavimento ( $p_a$ ) es capaz de explicar hasta la mitad de la variabilidad del fenómeno y, por lo tanto, juega un papel crítico en el proceso de deterioro del pavimento.

## 6.2 Influencia de la capacidad del pavimento

La influencia de la capacidad del pavimento se estudió a partir del Número Estructural ( $SN$ ). Para determinar el impacto de la estructura del pavimento en el proceso de deterioro del pavimento, se estudiaron los residuos del modelo anterior (Ecuación 1) considerando  $SN$  (Figura 12). Este análisis mostró que la capacidad del pavimento no tiene un impacto significativo en el fenómeno estudiado porque los residuos son homocedásticos y aproximadamente de forma rectangular.

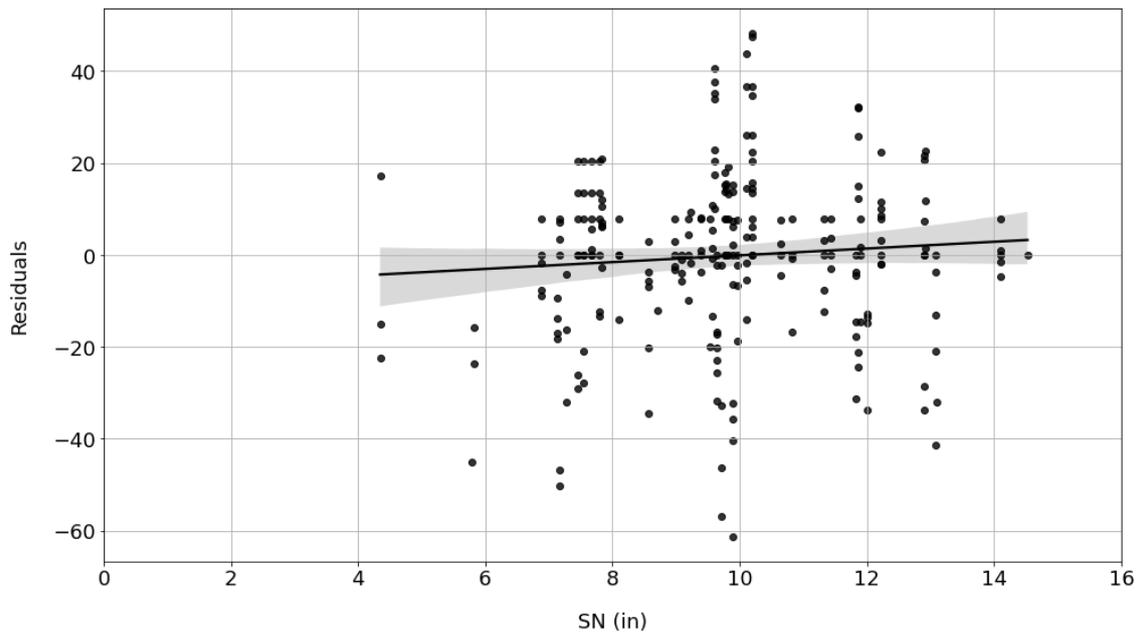


Fig. 12. Residuos de la Ecuación 1 Vs. Número Estructural.

Sin embargo, para valores de  $SN$  superiores a 10 pulgadas, los residuos tienden a ser positivos. Esto significa que se subestima el PCI previsto para aquellos pavimentos con una alta capacidad estructural. Por el contrario, el PCI predicho está sobreestimado para aquellos pavimentos con valores de  $SN$  inferiores a 10 pulgadas. Aunque se necesita más investigación para obtener conclusiones firmes, estos resultados sugieren que aquellos tramos de carretera caracterizados por un valor alto de  $SN$  retrasan el proceso de deterioro del pavimento.

La ecuación 2 muestra el modelo calibrado para predecir PCI a partir de la edad del pavimento ( $p_a$ ) y  $SN$ . Como se esperaba, este modelo no mejora la precisión de la predicción obtenida en la Ecuación 1 ya que el coeficiente de determinación no ha aumentado sustancialmente. En este sentido, la estructura del pavimento solo es capaz de explicar aproximadamente el 1% de la variabilidad.

$$PCI = \text{Max}(0; \text{Min}(99 - 44 - 5,54 \cdot p_a + 1,27 \cdot SN; 100)) \quad R_{test}^2 = 0,49 \quad (2)$$

La Figura 13 representa el modelo calibrado que describe adecuadamente la tendencia mencionada anteriormente. En este gráfico, el nivel de PCI se muestra en función de la edad y estructura del pavimento. Para una edad de pavimento específica, la condición del pavimento aumenta a medida que el  $SN$  es más alto.

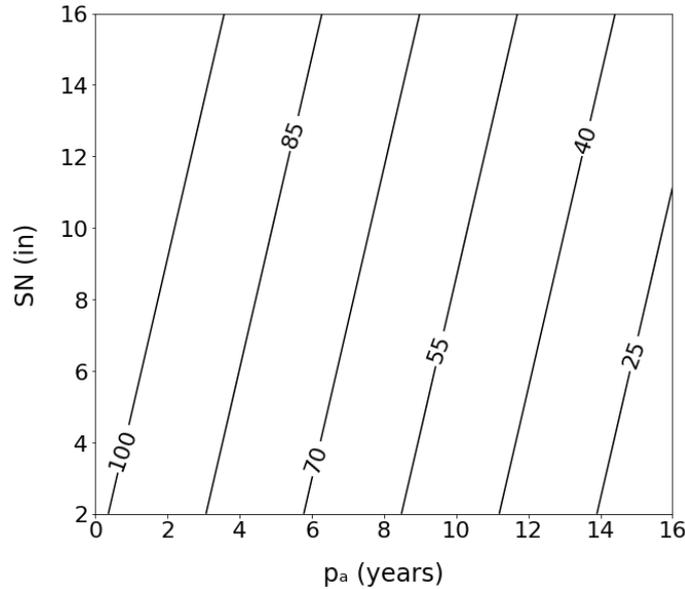


Fig. 13. Influencia de la edad y capacidad del pavimento en su deterioro.

Estos hallazgos pueden estar influenciados por el índice utilizado para la evaluación de la condición del pavimento y el plan de acción, es decir, cuándo se debe rehabilitar un pavimento. Aunque el PCI incluye deterioros del pavimento relacionadas con fallos estructurales, la evaluación del pavimento es superficial, por lo que no se consideran todos los fallos estructurales. Adicionalmente, una vía es habitualmente rehabilitada antes de sufrir importantes fallos estructurales para evitar su reconstrucción. Por lo tanto, el mantenimiento del pavimento podría estar más asociado con fallos superficiales que estructurales.

### 6.3 Influencia del volumen de tráfico

En esta investigación se propusieron tres variables de tráfico: *IMD*, *IMD<sub>p</sub>* y *KESAL*. Como se esperaba, estas variables presentaron correlaciones positivas moderadas y fuertes entre ellas, por lo que la influencia de todas ellas en el deterioro del pavimento podría considerarse similar. Para identificar esta influencia, se estudiaron los residuos del modelo descrito en la Ecuación 1 en función de las variables de tráfico. Como resultado, *IMD<sub>p</sub>* y *KESAL* mostraron una mayor influencia que *IMD*, por lo que los vehículos pesados juegan un papel crucial en el proceso de deterioro del pavimento.

En particular, *KESAL*, que es utilizado por la AASTHO para diseñar capas de pavimento, resultó ser el factor de tráfico más influyente. Así, se calibró un modelo combinado considerando esta variable junto con la edad del pavimento (Ecuación 3). Este modelo describe una reducción del PCI a medida que aumenta *KESAL*, es decir, la condición del pavimento empeora a medida que el tráfico pesado adquiere importancia (Figura 14).

$$PCI = \text{Max}(0; \text{Min}(121,96 - 5,80 \cdot p_a - 0,0296 \cdot KESAL; 100)) \quad R_{\text{test}}^2 = 0,55 \quad (3)$$

Como se puede observar, la inclusión de la carga de tráfico en el análisis de regresión aumentó significativamente la precisión del modelo. En particular, la variable *KESAL* es capaz de explicar el 7% de la variabilidad del fenómeno lo que significa una gran contribución en el proceso de deterioro del pavimento.

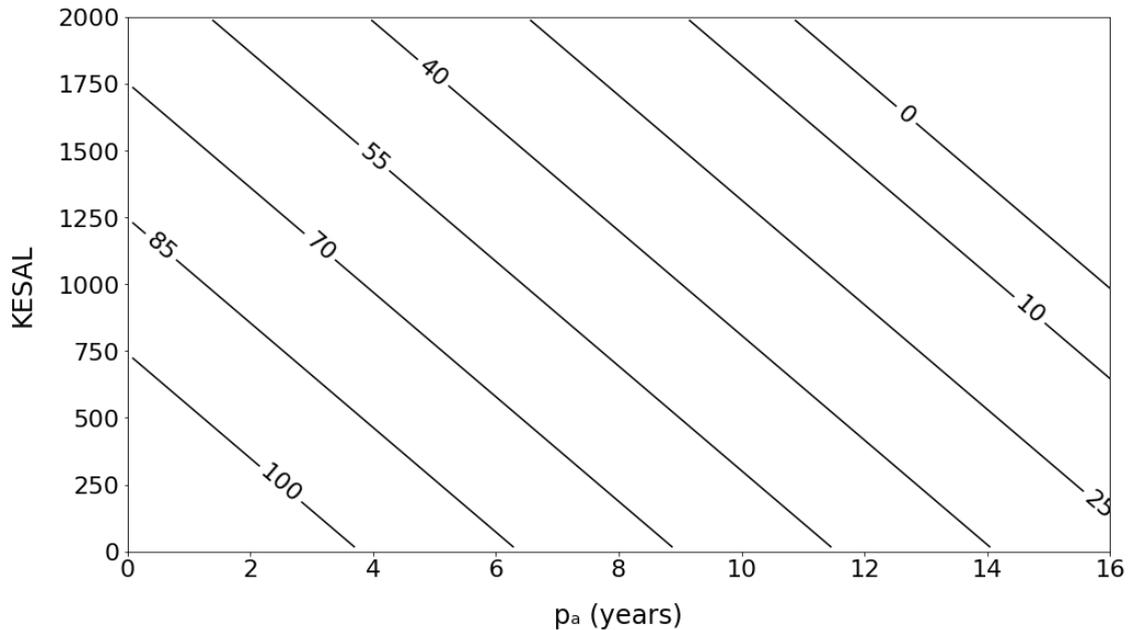


Fig. 14. Influencia del tráfico en el deterioro del pavimento.

#### 6.4 Influencia de las condiciones climáticas

Como se ha presentado anteriormente, se analizó la influencia de la precipitación, la temperatura, el viento y la humedad en el proceso de deterioro del pavimento. Para ello, se estudiaron los residuos del modelo base que solo incluye la edad del pavimento como variable explicativa (Ecuación 1) en función de cada factor climático.

Como resultado, las variables más influyentes fueron las relacionadas con la precipitación y la temperatura. En cuanto a las variables de precipitación, la Altura media anual de nieve (AAS) tuvo un mayor impacto en el estado del pavimento que la Precipitación media anual (AAP), que resultó en una variable no significativa (valor P = 0,8980). Específicamente, dada una cierta antigüedad del pavimento, el PCI disminuye una unidad por cada 100 mm de nieve (ver Ecuación 4 y Figura 15a).

$$PCI = \text{Max}(0; \text{Min}(122,43 - 5,79 \cdot p_a - 0,0108 \cdot AAS; 100)) \quad R_{test}^2 = 0,54 \quad (4)$$

Entre las variables de temperatura analizadas, la Temperatura Media Anual (AAT) fue la que presentó una relación más fuerte con el fenómeno estudiado. Esta relación se modeló a través

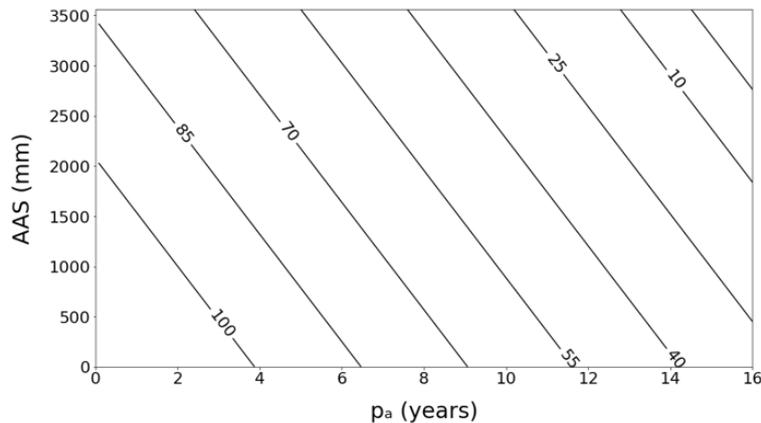
de la Ecuación 5 y se representó en la Figura 15b. De esta forma, se encontró una relación parabólica entre el deterioro del pavimento y *AAT*, de manera que los pavimentos expuestos a temperaturas medias anuales entre 5 y 15 °C experimentaron un proceso de deterioro más brusco. Además, los pavimentos ubicados en regiones cálidas (*AAT* = 20-30 °C) mostraron un retraso sustancial en el inicio del proceso de deterioro.

Por otro lado, aquellas variables que representan la variación de temperatura, *AART* y *SDT*, describieron la misma tendencia (ver Ecuación 8 y Figura 15c). Como se esperaba, el inicio del proceso de deterioro del pavimento se retrasó significativamente al disminuir la variación de temperatura durante el año.

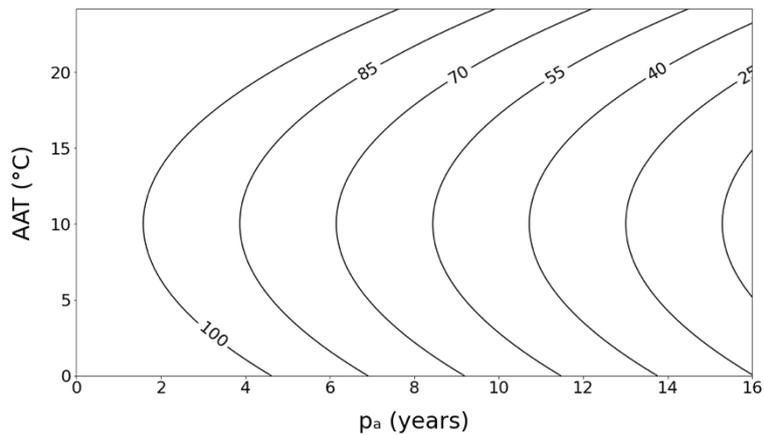
Por lo tanto, la inclusión de factores climáticos en la evaluación del estado del pavimento condujo a una estimación más precisa del PCI y a una mejor comprensión del fenómeno. Específicamente, el impacto de las condiciones climáticas en el proceso de deterioro del pavimento resultó en un aumento de la variabilidad explicada entre el 7% y 8%.

$$PCI = \text{Max}(0; \text{Min}(130.36 - 6.56 \cdot p_a - 3.98 \cdot AAT + 0.1988 \cdot AAT^2; 100)) \quad R_{est}^2 = 0.55 \quad (5)$$

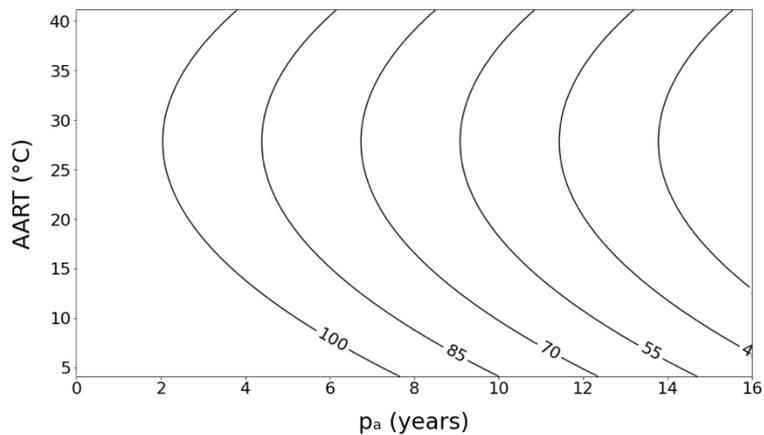
$$PCI = \text{Max}(0; \text{Min}(162.33 - 6.34 \cdot p_a - 3.54 \cdot AART + 0.0636 \cdot AART^2; 100)) \quad R_{est}^2 = 0.56 \quad (6)$$



(a) Altura media de nieve.



(b) Temperatura media anual



(c) Rango de temperatura medio anual

Fig. 15. Influencia de las condiciones climáticas en el deterioro del pavimento.

### 6.5 Influencia global

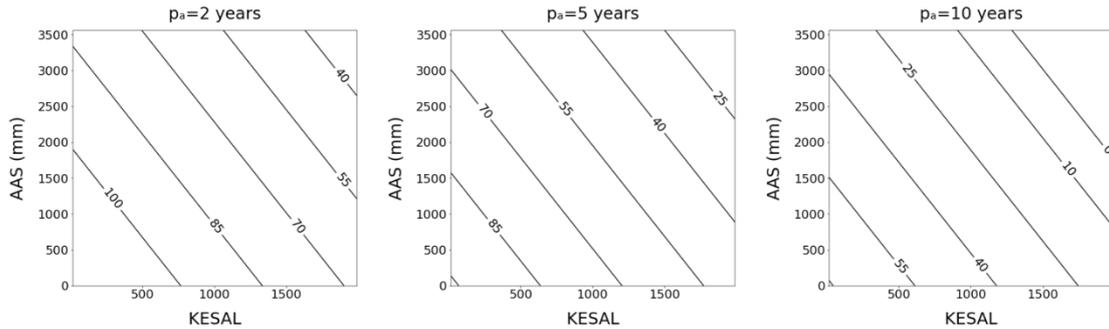
Una vez que se estudiaron individualmente la estructura del pavimento, la demanda del tráfico y las condiciones climáticas, se desarrolló un análisis global para determinar la influencia combinada del tráfico y el clima en el estado del pavimento. Para ello, se calibraron diferentes modelos de regresión combinando las variables de tráfico propuestas (*IMD*, *IMD<sub>p</sub>* y *KESAL*) con los factores climáticos más influyentes (*AAS*, *AAT* y *AART*), sin considerar *SN* por su bajo impacto en el proceso de deterioro del pavimento (Ecuaciones 7, 8 y 9). Aunque estos modelos proporcionaron un ligero aumento en la precisión de la predicción en comparación con los modelos individuales, se obtuvieron interesantes conclusiones globales que respaldaron los hallazgos descritos anteriormente. Estos modelos muestran que la condición del pavimento disminuye más de seis unidades por año y alrededor de dos unidades por cada cien mil cargas equivalentes de eje único. Asimismo, para una determinada edad del pavimento y condiciones de tráfico, cuanto mayor es la precipitación anual de nieve, menor es la condición del pavimento (ver Figura 16a). En cuanto a las variables de temperatura, un deterioro repentino del pavimento se relacionó con temperaturas frías (5-15 °C) y altas variaciones anuales de temperatura (20-30 °C) (ver Figura 16b y 16c). Adicionalmente, se encontró un retraso importante en el proceso de

deterioro en aquellos tramos de pavimento ubicados en climas cálidos con bajas variaciones de temperatura, que a su vez se caracterizaron generalmente por escasas precipitaciones.

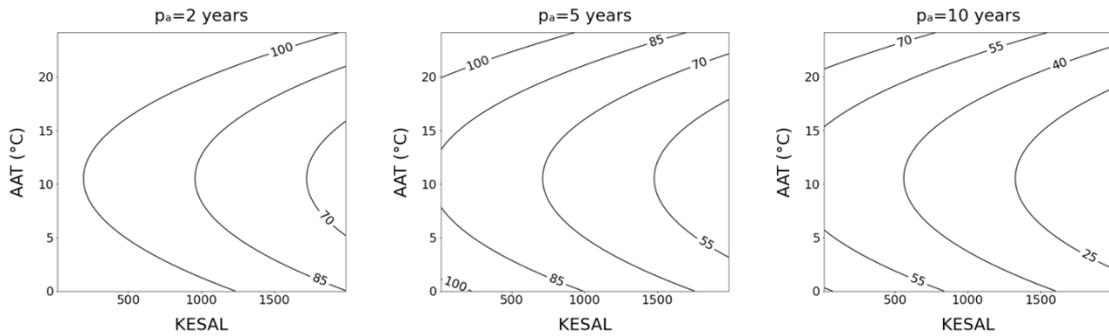
$$PCI = \text{Max}(0; \text{Min}(132.57 - 6.14 \cdot p_a - 0.0265 \cdot KESAL - 0.0104 \cdot AAS; 100)) \quad R_{test}^2 = 0.59 \quad (7)$$

$$PCI = \text{Max}(0; \text{Min}(137.43 - 6.60 \cdot p_a - 0.0196 \cdot KESAL - 3.89 \cdot AAT + 0.1847 \cdot AAT^2; 100)) \quad R_{test}^2 = 0.59 \quad (8)$$

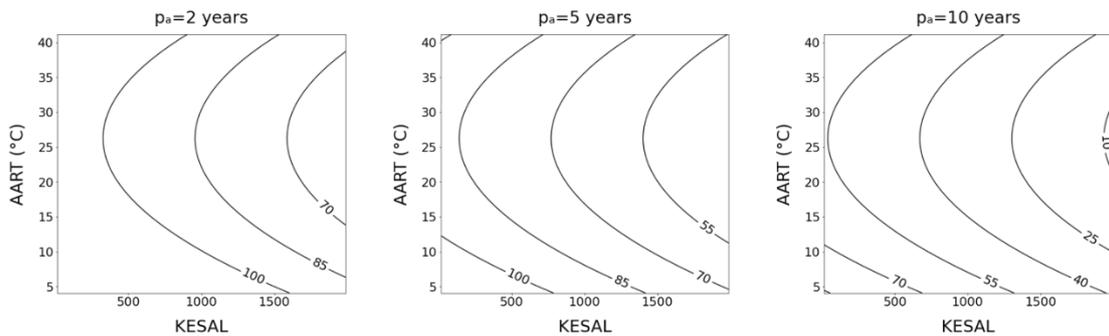
$$PCI = \text{Max}(0; \text{Min}(163.04 - 6.47 \cdot p_a - 0.0239 \cdot KESAL - 3.22 \cdot AART + 0.0615 \cdot AART^2; 100)) \quad R_{test}^2 = 0.58 \quad (9)$$



(a) Edad del pavimento, *KESAL* y AAS



(b) Edad del pavimento, *KESAL* y AAT



(c) Edad del pavimento, *KESAL* y AART

Fig. 16. Influencia global del tráfico y las condiciones climáticas en el deterioro del pavimento.

En resumen, la combinación de las variables de tráfico y climáticas junto con la edad del pavimento en la evaluación de la condición del pavimento permitió una mejor comprensión del proceso de deterioro del pavimento. Como se mencionó anteriormente, el factor más influyente en el deterioro del pavimento es la edad del mismo. Sin embargo, tanto la demanda del tráfico

como las condiciones climáticas, específicamente la precipitación y la temperatura, también resultaron en factores clave. En este sentido, el modelo que se ha decidido incluir en el desarrollo del software de este proyecto es el presentado en la Ecuación 8, principalmente, porque es uno de los que mayor precisión presenta y tiene mayor sentido en nuestro país, pues en muy pocas ciudades de España se espera una altura de nieve significativa.

## 7. Optimización multiobjetivo

Una vez conocido el estado de la red vial a partir de la inspección automática y su evolución a lo largo del tiempo, la siguiente etapa trata de evaluar cuál es el mejor plan de mantenimiento. Este plan de mantenimiento tiene una visión a largo plazo, por lo que se definen las actuaciones de mantenimiento que deberán llevarse a cabo durante un periodo de análisis con el fin de conseguir una óptima asignación de los recursos durante el ciclo de vida. Para ello, se propone desarrollar una optimización multiobjetivo basada en algoritmos heurísticos que permiten obtener las secciones de la red vial que deben ser tratadas cada año. Los objetivos y restricciones que se consideran en dicha optimización están encaminados a reducir el coste económico y el impacto social y medioambiental de las actividades de mantenimiento, al mismo tiempo que se mejora las características técnicas de la red. No obstante, serán los usuarios o administraciones de transporte quienes finalmente decidirán qué objetivos y restricciones desean considerar en su ciudad o región en base a los propuestos en esta metodología.

El proceso de optimización multiobjetivo utiliza algoritmos heurísticos para encontrar una matriz de intervención óptima que determina qué vías se deben intervenir cada año del periodo de análisis (Figura 17). Para la valoración económica, ambiental, social y técnica de cada intervención se proponen 5 funciones objetivo que se detallan en el epígrafe 7.1. Además, se comprueba que se cumplen las restricciones de condición mínima de la red (PCI mayor a 40) y el presupuesto disponible. Esta herramienta utiliza como datos de entrada aquellos aportados por el resto de los módulos del proyecto y explicados en los epígrafes previos. Los datos pueden ser dependientes de la red viaria, como la evaluación de los daños o las características geométricas y de tráfico, o independientes, como los modelos de deterioro o los datos de costes y emisiones unitarios de la base de datos.

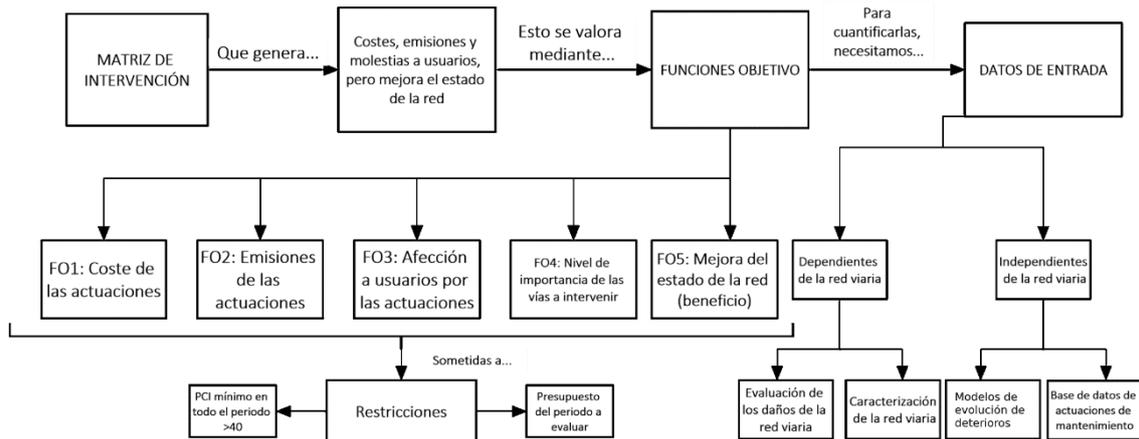


Fig. 17. Esquema general del proceso de optimización multiobjetivo

### 7.1 Base de datos de actuaciones de mantenimiento

Para el desarrollo de una herramienta de optimización multiobjetivo es necesario elaborar una base de datos completa que contenga toda la información necesaria para valorar las distintas actuaciones de mantenimiento en base al daño detectado y su severidad. En concreto, se estudia el coste económico, coste ambiental y tipo de corte de vía debido a la actuación de mantenimiento. Esta información se utiliza para valorar tanto los objetivos como las restricciones del problema de optimización. Para ello, se han utilizado dos fuentes de información: (1) información directa sobre las actuaciones de mantenimiento realizadas en la ciudad de Valencia en base al daño detectado, y (2) base de datos económica y ambiental de productos de la construcción (BEDEC) del Instituto de Tecnología de la Construcción de Cataluña (ITeC). En la Tabla 3 se muestra el coste unitario y las emisiones de CO<sub>2</sub> resultantes.

<b>Daños y severidades</b>	<b>Coste (€/u)</b>	<b>Emisiones de CO<sub>2</sub> (kg/u)</b>
<b>Grietas longitudinales y transversales (€/m)</b>		
Severidad Baja	6.63	15.01
Sellado de juntas con betún		
Severidad Intermedia	11.02	29.76
Sellado de juntas con betún		
Severidad Alta	17.30	32.61
Fresado de cajón 50 cm y reposición manual de aglomerado		
<b>Grietas en forma de piel de cocodrilo (€/m<sup>2</sup>)</b>		
Severidad Intermedia	23.51	77.33
Refuerzo de firme mediante recrecido, capa base y rodadura		
Severidad Alta	56.78	91.06
Refuerzo del firme mediante demolición, excavación y restitución de las capas		

<b>Bache (€/m<sup>2</sup>)</b>		
Severidad Intermedia	48.25	39.18
Parcheo con una capa		
Severidad Alta	81.66	77.23
Parcheo con varias capas		
Severidad Muy alta	90.92	79.89
Saneamiento y restitución puntual del firme		
<b>Meteorización y desprendimiento (€/m<sup>2</sup>)</b>		
Severidad Intermedia	23.51	77.33
Refuerzo de firme mediante recrecido, capa base y rodadura		
Severidad Alta	56.78	93.00
Refuerzo del firme mediante demolición, excavación y restitución de las capas		
<b>Parcheo (€/m<sup>2</sup>)</b>		
Severidad Intermedia	10.89	34.12
Reposición de capa de rodadura		
Severidad Alta	10.89	34.12
Reposición de capa de rodadura		

Tabla 3. Costes y emisiones unitarios de las actuaciones de mantenimiento

Para la evaluación de la afección a los usuarios debido al corte de vía se han valorado dos parámetros: tipo de corte de vía y horario (Tabla 4). El tipo de corte de vía distingue si el corte de la vía se realiza en todos los carriles (total) o solo en los afectados (parcial). El horario hace referencia a si la actuación se realiza en horario diurno o nocturno. Principalmente, esta clasificación es fruto de la experiencia de las empresas que conforman el consorcio que ha desarrollado el presente proyecto.

Deterioro asociado	Severidad	Tipo de corte vía	Horario
Grietas Longitudinales	Baja	Parcial	Nocturno
	Intermedia	Parcial	Nocturno
	Alta	Parcial	Diurno
Grietas Transversales	Baja	Total	Nocturno
	Intermedia	Total	Nocturno
	Alta	Total	Diurno
Grietas en forma de piel de cocodrilo	Intermedia	Total	Diurno
	Alta	Total	Diurno
Bache	Intermedia	Parcial	Diurno
	Alta	Parcial	Diurno

	Muy alta	Parcial	Diurno
Meteorización y desprendimiento	Alta	Total	Diurno
Parcheo	Intermedia	Total	Nocturno

Tabla 4. Cortes de vía necesarios para llevar a cabo las actuaciones de mantenimiento

## 7.2 Definición de criterios y funciones objetivo

Los criterios y objetivos seleccionados para la optimización multiobjetivo están encaminados a reducir el coste económico y el impacto social y medioambiental de las actividades de mantenimiento, al mismo tiempo que se mejora las características técnicas de la red. Tras un proceso de búsqueda de criterios en la literatura y filtrado de los más relevantes en ámbitos urbanos, se han seleccionado 5 criterios que serán incluidos como función objetivo en el proceso de optimización:

1. Coste económico de las actuaciones de mantenimiento
2. Emisiones de las actuaciones de mantenimiento
3. Afección a los usuarios de la red viaria
4. Nivel de importancia de las vías
5. Mejora del estado de las actuaciones o efectividad

### 7.2.1 Función Objetivo 1: Coste económico

Una gestión eficiente del mantenimiento implica una menor utilización de recursos económicos, por lo que el empleo del coste económico como criterio de decisión resulta imprescindible. La medición cuantitativa de dicho criterio es euros de ejecución material (€).

La evaluación de los costes se realiza en función del estado del pavimento en el momento en el que se lleva a cabo la actuación. Dado que se ha detectado que el daño debido a meteorización y desprendimiento tiene una repercusión económica y ambiental muy superior al resto de daños, se ha establecido un árbol de decisión inicial. En la Figura 18 se aprecia que el coste de reparación depende de la superficie afectada por meteorización o desprendimiento. Si esta es menor al 50% de la sección, el coste se obtiene como agregación de los costes de todos los daños; mientras que, en caso contrario, el coste será exclusivamente el de reparación de este daño.

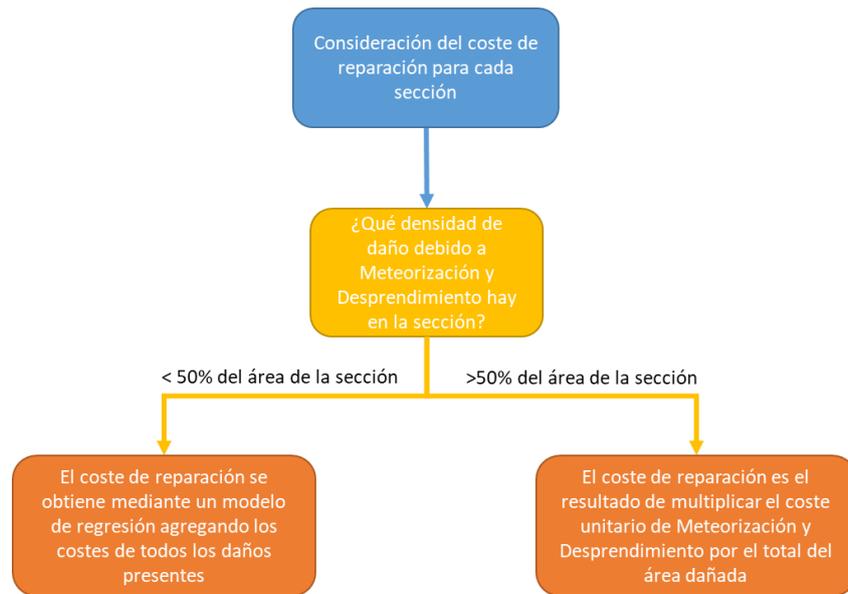


Fig. 18. Influencia de las condiciones climáticas en el deterioro del pavimento.

Una vez seleccionada la rama correspondiente, el coste de mantenimiento se obtiene de forma distinta si este se lleva a cabo en el año actual o en otro año del periodo de análisis. Los costes de las actuaciones en el año cero pueden ser calculados a partir de los daños presentes detectados mediante imágenes. Sin embargo, los costes futuros se obtienen mediante una ecuación racional que los relaciona con el PCI obtenido mediante el modelo predictivo (Ecuación 8). En la Tabla 5 se muestran las ecuaciones utilizadas en cada caso.

$A_{WR}$	t=0	t
$> 0.5 \cdot A_T$	$c_{it} = \frac{c_{wr}}{(1+dr)^t} = c_{wr} \quad (1)$	$c_{it} = (c_{max+} \cdot \frac{0.05 \cdot PCI_{it+1}}{(0.05 \cdot PCI_{it+1})^2} - \frac{c_{max+}}{6}) \cdot (\frac{1}{(1+dr)^t}) \quad (2)$
$< 0.5 \cdot A_T$	$c_{it} = V_{cu} \times A_i \cdot (\frac{1}{(1+dr)^t}) = V_{cu} \times A_i \quad (3)$	$c_{it} = (c_{max+} \cdot \frac{0.05 \cdot PCI_{it+1}}{(0.05 \cdot PCI_{it+1})^2} - \frac{c_{max+}}{6}) \cdot (\frac{1}{(1+dr)^t}) \quad (4)$

Tabla 5. Ecuaciones para la obtención del coste (Función Objetivo 1)

donde:

$A_T$  = Área total de la sección

$A_{WR}$  = Área de Meteorización y Desprendimiento en la sección

$dr$  = Tasa de descuento

$A_i$  = Áreas de cada daño para cada sección  $i$ .

$C_{wr}$  = Coste unitario de reparación de meteorización y desprendimiento (Tabla 3)

$C_{max+}$  = Constante del modelo  $PCI$ -coste que indica el valor superior del coste

$V_{cu}$  = Costes unitarios de las actuaciones de mantenimiento

$c_{it}$  = Coste total de la sección de referencia  $i$  en el año  $t$

### 7.2.2 Función Objetivo 2: Emisiones

Una gestión de mantenimiento sostenible ha de considerar la reducción del coste ambiental. Para la medición cuantitativa de dicho criterio, se emplean los kilogramos de CO<sub>2</sub> asociados a las actuaciones de mantenimiento (kg<sub>CO2</sub>). Esta Función Objetivo se obtiene siguiendo el mismo esquema que la Función Objetivo 1 (Tabla 6).

$A_{WR}$	t=0	t
$> 0.5 \cdot A_T$	$e_{it} = e_{wr} \text{ (5)}$	$e_{it} = e_{max+} \cdot \frac{0.05 \cdot PCI_{it+1}}{(0.05 \cdot PCI_{it+1})^2} - \frac{e_{max+}}{6} \text{ (6)}$
$< 0.5 \cdot A_T$	$e_{it} = V_{eu} \cdot A_i \text{ (7)}$	$(32) e_{it} = e_{max+} \cdot \frac{0.05 \cdot PCI_{it+1}}{(0.05 \cdot PCI_{it+1})^2} - \frac{e_{max+}}{6} \text{ (8)}$

Tabla 6. Ecuaciones para la obtención de las emisiones (Función Objetivo 2)

donde

$A_T$  = Área total de la sección

$A_{WR}$  = Área de Meteorización y Desprendimiento en la sección

$A_i$  = Áreas de cada daño para cada sección  $i$

$e_{wr}$  = Emisiones unitarias asociadas a la reparación de meteorización y desprendimiento (Tabla 3)

$e_{max+}$  = Constante del modelo *PCI-coste* que indica el valor superior de las emisiones

$V_{eu}$  = Emisiones unitarias de las actuaciones de mantenimiento

$e_{it}$  = Emisiones totales de la sección de referencia  $i$  en el año  $t$

### 7.2.3 Función Objetivo 3: Afección a los usuarios de la red viaria

La evaluación del impacto ambiental no puede entenderse sin la evaluación del impacto social de una actuación. Para llevar a cabo las actuaciones de mantenimiento urbano es necesario realizar cortes viarios, parciales o totales, que generan una afección directa a los distintos usuarios de la red viaria, desde peatones a vehículos motorizados. Para este proyecto, la afección a usuarios vendrá condicionada por el tipo de corte de la vía (parcial o total) y el momento en el que se realiza cada intervención (nocturno o diurno). Además, se tendrá en cuenta la IMD de la vía para evaluar la magnitud del impacto sobre los usuarios. Este criterio es evaluado mediante funciones de utilidad a partir de las variables mencionadas, adoptando un valor numérico entre 0 y 1, siendo 1 el valor óptimo y 0 el valor pésimo. En el epígrafe 8. Técnicas de decisión se detallan estas funciones de valor.

### 7.2.4 Función Objetivo 4: Nivel de importancia de las vías

Dentro de una red urbana, existen vías cuyo estado es prioritario para el decisor. Para este proyecto, este criterio se evalúa en función de la importancia de la vía por discurrir cerca de puntos de interés económico o social o por ser una vía prioritaria dadas sus características. Este criterio es también evaluado mediante funciones de utilidad, adoptando un valor numérico entre

0 y 1, siendo 1 en valor óptimo y 0 el valor pésimo. Estas funciones de valor se presentan en el siguiente epígrafe 8. Técnicas de decisión.

### 7.2.5 Función Objetivo 5: Mejora del estado de las actuaciones o efectividad

Este criterio mide la mejora del estado de la vía gracias a las actuaciones de mantenimiento. Por ello, se evalúa el estado de la red a lo largo de los años mediante los modelos de predicción empleados, definiéndose así una función cuya variable dependiente es el *PCI* y la variable independiente el tiempo. La medición cuantitativa de este criterio será la diferencia entre el valor de la integral definida dentro del periodo de evaluación de dicha función (*PCI*-*t*, con *t* medido en años) después de llevar a cabo una actuación de mantenimiento y el *PCI* mínimo impuesto en las restricciones (Ecuación 9).

$$b_i = \int_{t=0}^{t=m} (F(PCI_i) - PCI_{min}) \quad (9)$$

donde:

$F(PCI_i)$  = Función definida por los valores del *PCI* a lo largo del periodo a evaluar considerando la mejora por las actuaciones de mantenimiento

$PCI_{min}$  = Valor mínimo del *PCI* permitido como restricción del problema

$m$  = Número de años a evaluar en el problema

## 8. Técnicas de decisión

En último lugar, las técnicas de decisión facilitan la asignación de los pesos a cada uno de los objetivos o criterios definidos anteriormente y permiten la normalización de los mismos con el fin de priorizar las diferentes alternativas cuando se consideran varios de estos objetivos al mismo tiempo. Estas técnicas pueden ser integradas dentro de la propia optimización multiobjetivo para guiar la búsqueda de la mejor solución o, alternativamente, pueden aplicarse después de obtener una frontera de Pareto para seleccionar una única alternativa. Para reducir los tiempos de computación, esta metodología propone desarrollar la primera de las opciones.

De acuerdo a Penadés-Pla et al. (2016), las técnicas de decisión se pueden clasificar en: (i) métodos de puntuación; (ii) métodos basados en la distancia; (iii) métodos de comparación por pares; (iv) métodos de superación; (v) métodos de utilidad o valor; y (vi) otros métodos. Entre todas ellas, la metodología propuesta incorpora el método de utilidad denominado *Multi-Attribute Utility Theory (MAUT)*. Este método emplea una función de utilidad para convertir cada valor objetivo a un valor de utilidad entre 0 y 1, lo que proporciona mayor flexibilidad a la hora de realizar la priorización de alternativas. En este sentido, cada objetivo o criterio puede tener su propia curva de utilidad con el fin de priorizar cierto rango de valores de cada uno de ellos.

Las Funciones Objetivo 1, 2 y 5 proporcionan un valor cuantitativo que será normalizado utilizando funciones de valor lineales, siendo 1 el correspondiente al valor óptimo y 0 el correspondiente al valor pésimo.

$$FV_i = \frac{1}{1 - e^{-\gamma}} \left( 1 - e^{-\gamma \cdot \frac{(V_{opt} - V_i)}{(V_{opt} - V_{pes})}} \right) \quad (10)$$

donde:

$V_{opt}$  = valor óptimo de la función objetivo

$V_{pes}$  = valor pésimo de la función objetivo

$V_{pes}$  = valor de la función objetivo

$\gamma$  = factor que determina la forma de la curva de valor. En el caso de las Funciones Objetivo 1, 2 y 5 es igual a 0.

En cambio, las Funciones Objetivo 3 y 4 son evaluadas a partir de valoraciones cualitativas que serán transformadas en valores cuantitativos y normalizados utilizando las funciones de utilidad. La Funciones Objetivo 3 depende de la afección a los usuarios y la IMD de la vía. Para poder valorar el grado de afección en función del estado de las vías en cualquier año del periodo de análisis, se ha analizado el tipo de daño y severidad que cuenta con un peso mayor en cada escalón de PCI y se han cruzado estos resultados con los mostrados en la Tabla 4. Como resultado, se han obtenido tres funciones de utilidad (baja, media y alta) en función del rango de PCI (Tabla 7) y la magnitud del daño de meteorización y desprendimiento.

		Tipo de afección	Escala de afección		
		Tipo de intervención	Si AWR<50%		Si AWR>50%
PCI	Escala				
85-100	Good	Parcial/Nocturno	P/N	Baja	Alta
70-85	Satisfactory	Parcial/Nocturno			
55-70	Fair	Total/Nocturno	T/N o P/D	Media	
40-55	Poor	Parcial/Diurno			
25-40	Very Poor	Total/Diurno	T/D	Alta	
10-25	Serious	Total/Diurno			
0-10	Failed	Total/Diurno			

Tabla 7. Criterio de selección de las funciones de utilidad para la Función Objetivo 3.

Cada una de las funciones de utilidad (baja, media y alta) tomará como variable de entrada el percentil de IMD de dicha vía respecto al de la red viaria. Por tanto, las vías que tengan una IMD mayor, tendrán mayor afección a los usuarios por cortes de la vía y, por tanto, una utilidad menor. Del mismo modo, las vías con afecciones “bajas”, es decir, tratamientos que supongan cortes parciales y nocturnos, tendrán una utilidad mayor que las vías con afecciones “media” o “alta”, para el mismo valor de la IMD (ver Figura 19). La función de utilidad es:

$$FV_3 = \frac{1}{1 - e^{-\gamma}} \left( 1 - e^{-\gamma \cdot \frac{(100 - P_{IMD_i})}{100}} \right) \quad (11)$$

donde

$P_{IMD_i}$  = Percentil de la distribución de IMDs del conjunto de la red asociado al valor de la IMD de la sección.

$\gamma$  = Factor de que determina la forma de la curva, siendo  $\gamma_{baja}=0.5$ ,  $\gamma_{media}=-1.7$  y  $\gamma_{alta}=-4.75$

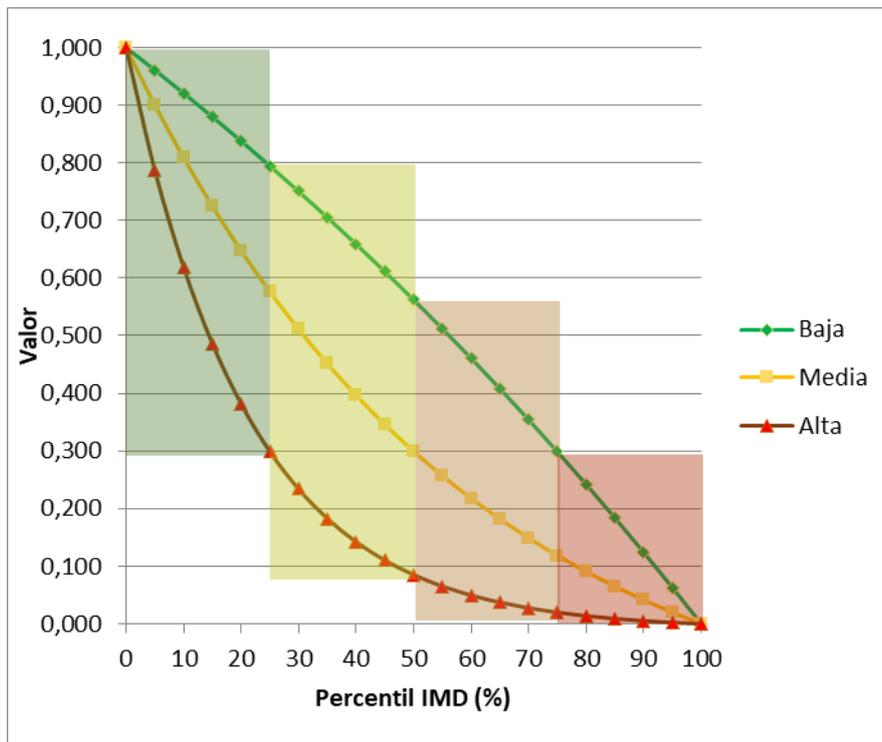


Fig. 19. Funciones de utilidad de la Función Objetivo 3.

Para la obtención de la Función Objetivo 4 se evalúa la importancia por zona y el tipo de vía. En este sentido, se considera que una sección de vía está en zona prioritaria cuando parte de su trazado queda dentro de un radio definido por el usuario a partir de un punto de interés. En cuanto al tipo de vía, se considera que la vía es prioritaria cuando es una vía arterial o el usuario la ha considerado como tal. A partir de estas clasificaciones, se obtienen cuatro funciones de utilidad (Tabla 8).

Zona prioritaria	Vía prioritaria	Función de utilidad
SI	SI	Función 1
NO	SI	Función 2
SI	NO	Función 3
NO	NO	Función 4

Tabla 8. Criterio de selección de las funciones de utilidad para la Función Objetivo 4.

En este caso, la utilidad depende del PCI mínimo de una sección a lo largo del periodo de evaluación y la función de utilidad seleccionada (Figura 20). El PCI mínimo se obtiene como el menor valor de PCI que alcanza la sección de vía durante el periodo de análisis considerado. De esta forma, las vías con importancia alta obtienen un valor de utilidad menor que las vías con importancia menor, para un mismo valor de PCI mínimo. Por tanto, al optimizar esta función objetivo, las vías con importancia alta no podrán tener un valor de PCI mínimo bajo.

(12)

$$FV_4 = \frac{1}{1 - e^{-\gamma}} \left( 1 - e^{-\gamma \cdot \frac{PCI_{min}}{100}} \right)$$

Donde

$PCI_{min}$  = valor mínimo del *PCI* a lo largo del periodo de evaluación para cada sección *i*

$\gamma$  = Factor de que determina la forma de la curva, siendo  $\gamma_1=-4.55$ ,  $\gamma_2=-1.8$ ,  $\gamma_3=-0.40$ ,  $\gamma_4=0.83$

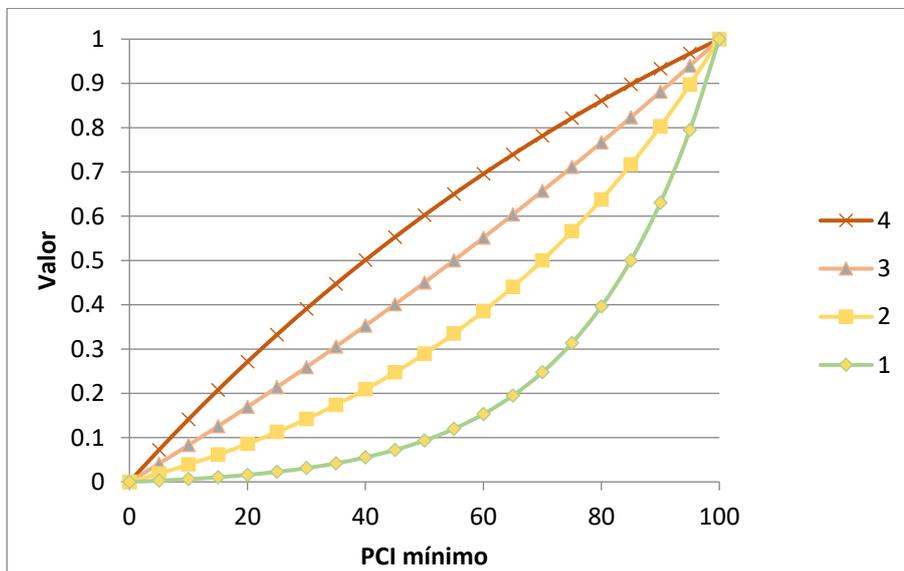


Fig. 20. Funciones de utilidad de la Función Objetivo 4

La función objetivo total se obtiene como sumatorio de los valores obtenidos de las funciones de utilidad multiplicados por los pesos de cada función objetivo (Ecuación 13). Los usuarios o administraciones de transporte podrán decidir qué objetivos desean considerar y los pesos de estos.

$$FO_T = w_1 \cdot FV_1 + w_2 \cdot FV_2 + w_3 \cdot FV_3 + w_4 \cdot FV_4 + w_5 \cdot FV_{54} \quad (13)$$

Cabe destacar que todas las etapas presentadas anteriormente están programadas en un único software donde, finalmente, será el usuario del mismo quien decida o seleccione sus prioridades antes de llevar a cabo la optimización. Así, en base a los criterios que la administración decida aplicar, el software le ofrecerá, a través de un visor GIS, el plan de mantenimiento para los próximos años.

## 9. Desarrollo del software

La etapa final del proyecto se centra en el desarrollo de un software para la gestión y planificación del mantenimiento del pavimento en entornos urbanos que incorpora todos y cada uno de los modelos que han sido desarrollados en las etapas anteriores con el fin de facilitar lo máximo posible la aplicación de estas herramientas al usuario, administración o ingeniero, encargado del mantenimiento de una red vial urbana. Las principales funciones del software son (ver Figura 21):

- Representación de la red vial urbana a través de un Sistema de Información Geográfica (SIG).
- Detección automática de daños.
- Evaluación automática del estado de la condición del pavimento.
- Predicción del deterioro.
- Optimización de la planificación de las actuaciones de mantenimiento.

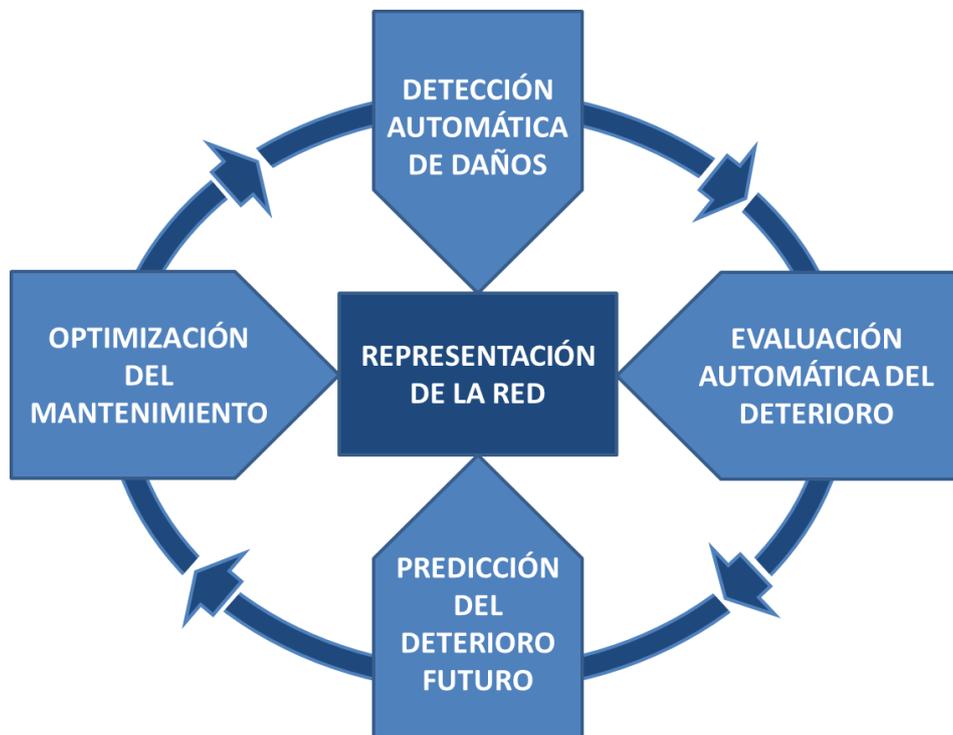


Fig. 21. Principales funciones del software.

### 9.1 Representación de la red a través de un SIG

La representación de la red vial urbana a través de un Sistema de Información Geográfica tiene como objetivo recopilar, gestionar y analizar el estado de cada una de las vías. Cada segmento de la red se caracteriza en base a:

- Características de la vía: Nombre, área, tipo de vía, IMD, nº de carriles, etc.
- Localización: Distrito, barrio, geometría, nivel de importancia, etc.
- Histórico de intervenciones: fecha y tipo de intervención, coste, emisiones, etc.

Como se puede observar en la Figura 22, todas las características de un determinado segmento se pueden consultar con un solo click.

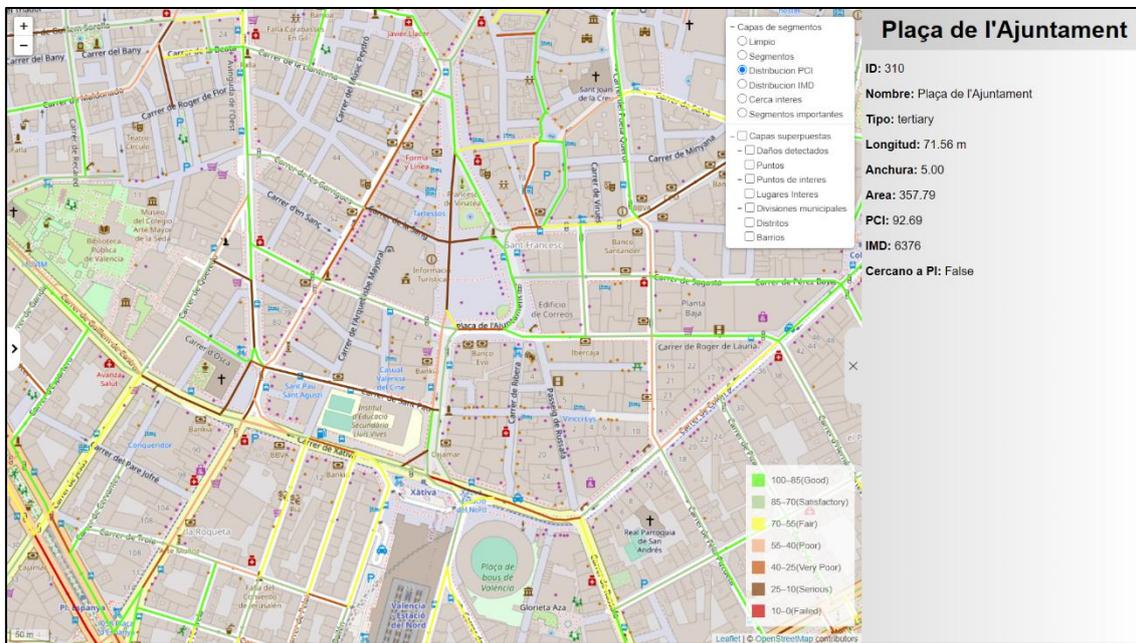


Fig. 22. Representación de la red vial.

### 9.2 Identificación de daños y evaluación de la condición del pavimento

El proceso de detección de daños existentes en las vías es automático. A través de un video registrado por el sistema de adquisición de imágenes, el software de manera automática y autónoma extrae las imágenes de cada segmento de la red, identifica los daños existentes, así como el área y nivel de severidad de dichos daños, y asocia a cada segmento la siguiente información: posición georreferenciada de cada daño, tipo de daño, severidad, área afectada, etc. Para ello, el programa emplea las redes neuronales convolucionales calibradas.

Seguidamente, el software es capaz de estimar automáticamente la condición del pavimento de un segmento de la red. A partir de los daños detectados, el área afectada y el nivel severidad de los mismos determina el valor del indicador de la condición del pavimento (PCI) de cada

segmento. Como se ha comentado anteriormente, toda esta información, una vez procesada, es incorporada como atributos a cada uno de los segmentos de la red (ver Figura 23).

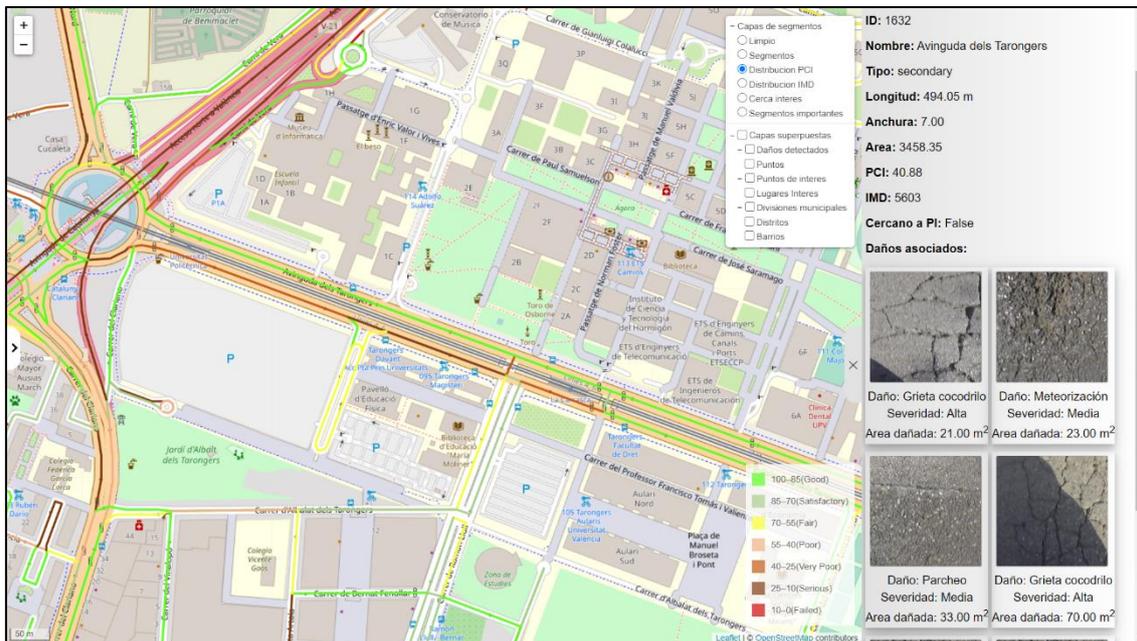


Fig. 23. Identificación de daños y estimación de la condición.

### 9.3 Predicción del deterioro

A partir de la evaluación del estado actual del deterioro de las vías, el software es capaz de predecir la evolución de dicho deterioro a lo largo del tiempo con el objeto de identificar las vías de mayor riesgo y con mayor capacidad de afección negativa sobre los usuarios. Para ello, el programa incorpora el modelo de predicción definido por la Ecuación 8 que se ha presentado en el epígrafe 6. Predicción de la condición del pavimento.

Una de las grandes ventajas del modelo seleccionado es que permite su aplicación, generalmente, en cualquier entorno urbano debido a que este es capaz de adaptarse a las condiciones climáticas de cada área o región específica. No obstante, el software está preparado para introducirle un modelo externo calibrado para un área específica y, además, incorpora un reajuste automático del modelo a medida que se incluyen los datos históricos de una determinada red vial urbana.

La Figura 24 muestra la predicción de la condición del pavimento en el distrito de En Corts de la ciudad de Valencia. Particularmente, en este ejemplo el software ofrece la opción de visualizar el estado del pavimento para los próximos cinco años, siendo este periodo de tiempo introducido por el usuario en base al análisis que se desee realizar. Asimismo, pueden ser visualizados cuáles serían los segmentos en los que intervenir cada uno de los años estudiados.



Fig. 24. Predicción de la condición del pavimento: distrito de En Corts (Valencia).

#### 9.4 Optimización de la planificación de las actuaciones de mantenimiento

Finalmente, en base al estado actual y el deterioro futuro de la red, el software es capaz de gestionar y planificar el mantenimiento de la red mediante la optimización y priorización de actuaciones de mantenimiento que garanticen, bajo determinadas restricciones presupuestarias establecidas por el cliente, la reducción de los costes de mantenimiento, las molestias a usuarios directos e indirectos de la red, la contaminación ambiental y los niveles de seguridad en la red.

Para ello, el usuario podrá fijar el año horizonte e incluso modificar algunos de los parámetros que se establecen por defecto como, por ejemplo, los puntos de interés, el porcentaje de vehículos pesados o la prioridad de actuación en un barrio o zona concreta de la ciudad.

La Figura 25 muestra un ejemplo de la salida de datos del software en cuanto a la planificación de las actuaciones de mantenimiento para un periodo de cinco años. Principalmente, la salida de datos está conectada a la matriz de intervención que proporciona la optimización multiobjetivo desarrollada en el proyecto y las distintas técnicas de decisión propuestas. De esta manera, el software nos indica para cada una de las calles o segmentos de la red vial en qué año intervenir.

	A	B	C	D	E	F	G	H
13	1354	Avinguda del Doctor Waksman	no	intervention	no	no	no	
14	1355	Avinguda del Doctor Waksman	intervention	no	no	no	no	
15	1356	Avinguda de la Plata	intervention	no	no	no	no	
16	1357	Avinguda de la Plata	no	no	no	intervention	no	
17	1359	Avinguda de la Plata	intervention	no	no	no	no	
18	1361	Avinguda de la Plata	intervention	no	no	no	intervention	
19	1363	Avinguda de la Plata	no	intervention	no	no	no	
20	1366	Avinguda de la Plata	intervention	no	no	intervention	no	
21	1368	Avinguda de la Plata	no	no	no	intervention	no	
22	1369	Avinguda de la Plata	no	no	intervention	no	no	
23	1370	Avinguda de la Plata	no	intervention	no	no	intervention	
24	1372	Avinguda de la Plata	intervention	no	no	no	no	
25	1373	Intersecció'n o VÃ-a sin nombre	no	no	intervention	no	no	
26	1378	Avinguda d'AusiÃ s March	no	no	intervention	no	no	
27	1379	Avinguda d'AusiÃ s March	intervention	no	no	no	no	
28	1380	Avinguda d'AusiÃ s March	intervention	no	no	no	no	
29	1382	Avinguda d'AusiÃ s March	no	intervention	no	no	no	
30	1383	Avinguda d'AusiÃ s March	no	intervention	no	intervention	intervention	
31	1384	Avinguda d'AusiÃ s March	no	intervention	intervention	intervention	intervention	
32	1390	Avinguda de la Plata	no	no	intervention	no	no	
33	1391	Carrera de la Fonteta de Sant LluÃ s	no	intervention	no	no	no	
34	1392	Avinguda de la Plata	no	intervention	no	no	no	
35	1393	Carrer de l'Actriu Pepita Serrador	intervention	no	no	no	no	
36	1583	Carrer de BÃ rnia	intervention	no	no	no	no	
37	1604	Avinguda d'AusiÃ s March	no	intervention	no	no	no	
38	1605	Avinguda d'AusiÃ s March	intervention	no	no	no	no	
39	1606	Carrer de Ribelles ComÃ n	intervention	no	no	no	no	
40		intervention matrix name						

Fig. 25. Planificaci3n de las actuaciones de mantenimiento.

## 10. Conclusiones

La red vial, como uno de los mayores bienes patrimoniales de un pa3s y base fundamental para su desarrollo econ3mico y social, debe mantenerse en buen estado para reducir costes de transporte de personas y bienes, as3 como para no incurrir en sobrecostes por mantenimientos tard3os. En este sentido, la gesti3n actual del pavimento urbano se caracteriza, principalmente, por: (i) inexistencia de m3todos eficientes para la detecci3n de da3os; (ii) carencia de mantenimiento predictivo; y (iii) ausencia de factores relacionados con la sostenibilidad social y medioambiental en la toma de decisiones.

Para hacer frente a estas deficiencias, las herramientas desarrolladas en este proyecto permitir3n: (i) la automatizaci3n de las tareas de auscultaci3n a trav3s de la obtenci3n de im3genes con c3maras convencionales y procesamiento posterior de las mismas mediante t3cnicas de aprendizaje profundo, evitando la subjetividad derivada de la inspecci3n visual y reduciendo tiempos y costes de la evaluaci3n del pavimento; (ii) la homogeneizaci3n de la predicci3n del estado del firme al incorporar, adem3s de variables t3cnicas, variables relacionadas con el volumen de tr3fico, la precipitaci3n y la temperatura, favoreciendo la aplicaci3n del software desarrollado a otras regiones geogr3ficas; y (iii) la incorporaci3n de un modelo de optimizaci3n y toma de decisiones que incluye criterios como las emisiones de CO<sub>2</sub> o la proximidad a infraestructuras de desarrollo social y econ3mico con el fin de reducir los costes tambi3n desde una perspectiva social y medioambiental.

El software desarrollado es capaz de integrar las distintas herramientas desarrolladas con el fin de facilitar su uso a los usuarios, ya sea la propia administración o una empresa especializada en el mantenimiento de una red vial. Este software, además, ha sido diseñado con el fin de ofrecer al usuario una interfaz y una visualización gráfica sencilla de los resultados que se van obteniendo a lo largo de las diferentes etapas que se deben llevar a cabo para obtener una planificación óptima de las actuaciones de mantenimiento. En este sentido, el software muestra, en primer lugar, cuál es el estado actual de la red tomando como input la grabación en vídeo del pavimento de un determinado tramo de la red o de la totalidad de la misma. Para ello, emplea principalmente las redes neuronales convolucionales entrenadas y estima el valor del PCI para cada sección de vía del área de estudio. A partir de la condición actual del pavimento, el software es capaz de predecir el estado futuro de la red vial en base a los modelos de predicción que incorpora. Finalmente, el software permite determinar cuál es la planificación óptima de las actuaciones de mantenimiento y rehabilitación en base a una optimización multiobjetivo que considera, entre otros criterios, la afección a los ciudadanos, las emisiones de CO<sub>2</sub> relacionadas con la actuación y la proximidad a puntos de interés. Estos criterios, junto a los habituales criterios económicos y técnicos, proporcionarán una planificación eficiente y proactiva para mantener la red vial en el mejor estado posible minimizando los costes y las afecciones a los ciudadanos y usuarios de la red, al mismo tiempo que se consigue un mantenimiento más sostenible.

Resumiendo, el desarrollo del proyecto SIMEPU ha permitido el desarrollo de una aplicación sencilla basada principalmente en una interfaz visual muy amigable para el usuario que permite:

- la identificación y cuantificación de deterioros en el pavimento de manera automática;
- conocer cuál será el estado de la red en un futuro; y
- establecer una programación eficiente y proactiva de las actuaciones de mantenimiento y rehabilitación del pavimento urbano a medio-largo plazo.

## Referencias bibliográficas

- AASHTO (2011). *Transportation Asset Management Guide: A Focus on Implementation*. American Association of State Highway and Transportation Officials, Washington, DC.
- AASHTO (1993). *Guide for Design of Pavement Structures*. American Association of State Highway and Transportation Officials, Washington, DC.
- AEC (2020). *Guía para la Rehabilitación y la Gestión de los Firms de las Carreteras dependientes de las Administraciones Locales*. Asociación Española de la Carretera, Madrid.
- AMHAZ, R., CHAMBON, S., IDIER, J., & BALTAZART, V. (2016). Automatic crack detection on two-dimensional pavement images: An algorithm based on minimal path selection. *IEEE Transactions on Intelligent Transportation Systems*, 17(10), pp. 2718-2729.
- ARAMBULA, E., GEORGE, R., XIONG, W., & HALL G. (2011). Development and validation of pavement performance models for the state of Maryland. *Transportation Research Record: Journal of the Transportation Research Board*, 2225(1), pp. 25-31.
- ASTM, 2018. *Standard practice for roads and parking lots pavement condition index surveys* (No. ASTM D6433-18). American Society for Testing and Materials, West Conshohocken.
- BULL, A. (2003). *Traffic Congestion: The Problem and how to Deal with it* (No. 87). United Nations Publications.
- CARR, T. A., JENKINS, M. D., IGLESIAS, M. I., BUGGY, T., & MORISON, G. (2018). Road crack detection using a single stage detector based deep neural network. *IEEE Workshop on Environmental, Energy, and Structural Monitoring Systems (EESMS), 2018*, pp. 1-5. IEEE.
- CHA, Y. J., CHOI, W., & BÜYÜKÖZTÜRK, O. (2017). Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5), pp. 361-378.
- CHAMBON, S., & MOLIARD, J. M. (2011). Automatic road pavement assessment with image processing: review and comparison. *International Journal of Geophysics*, 2011, doi:10.1155/2011/989354.
- DONG, Q., HUANG, B., & RICHARDS S.H. (2014). Calibration and application of treatment performance models in a pavement management system in Tennessee. *Journal of Transportation Engineering*, 141(2), 04014076.
- ESPINOZA-VALAREZO, P.A., GARCÍA-SEGURA, T., MONTALBÁN-DOMINGO, L., & PELLICER, E. (2019). *Development of a Decision Making Tool for the Pavement Maintenance Management under Sustainability Criteria: Application to Valencia (Spain)*. Interdependence between Structural Engineering and Construction Management. The Tenth International Structural Engineering and Construction Conference. Chicago, Illinois, United States.
- FHWA (1999). *Asset Management Primer*. Washington, DC, USA.
- FWA, T. F., CHAN, W. T., & HOQUE, K. Z. (2000). Multiobjective optimization for pavement maintenance programming. *Journal of Transportation Engineering*, 126(5), pp. 367-374.
- GEORGE, K. P., RAJAGOPAL, A. S., & LIM, L. K. (1989). Models for predicting pavement deterioration. *Transportation Research Record*, (1215), pp. 25-32.

- HAIJ, E. Y., LORIA, L., & SEBAALY, P. E. (2010). Performance evaluation of asphalt pavement preservation activities. *Transportation Research Record*, 2150(1), pp. 36-46.
- HASSAN, R., LIN, O., & THANANJEYAN, A. (2015). A comparison between three approaches for modelling deterioration of five pavement surfaces. *International Journal of Pavement Engineering*, 18(1), pp. 26-35.
- JENKINS, M. D., CARR, T. A., IGLESIAS, M. I., BUGGY, T., & MORISON, G. (2018). A deep convolutional neural network for semantic pixel-wise segmentation of road and pavement surface cracks. *26th European Signal Processing Conference (EUSIPCO), 2018*, pp. 2120-2124. IEEE.
- KINGMA, D. P., & BA. J. (2015). Adam: A method for stochastic optimization. *3rd International Conference for Learning Representations*, San Diego, arXiv:1412.6980.
- KRAEMER, C., PARDILLO, J. M., ROCCI, S., ROMANA, M., SÁNCHEZ, V., & DEL VAL, M.A. (2004). *Ingeniería de Carreteras, Vol. II*. Editorial McGraw Hill, Madrid.
- MAEDA, H., SEKIMOTO, Y., SETO, T., KASHIYAMA, T., & OMATA, H. (2018). Road damage detection using deep neural networks with images captured through a smartphone. *arXiv preprint arXiv:1801.09454*.
- MENESES, S., & FERREIRA, A. (2015). Flexible pavement maintenance programming considering the minimisation of maintenance and rehabilitation costs and the maximisation of the residual value of pavements. *International Journal of Pavement Engineering*, 16(7), pp. 571-586.
- MOHD HASAN, M. R., HILLER, J.E., & YOU, Z. (2016). Effects of mean annual temperature and mean annual precipitation on the performance of flexible pavement using ME design. *International Journal of Pavement Engineering*, 17(7), pp. 647-658.
- MOREIRA, A.V., TINOCO, J., OLIVEIRA, J.R., & SANTOS, A. (2018). An application of Markov chains to predict the evolution of performance indicators based on pavement historical data. *International Journal of Pavement Engineering*, 19(10), pp. 937-948.
- OLIVEIRA, H., & CORREIA, P. L. (2013). Automatic road crack detection and characterization. *IEEE Transactions on Intelligent Transportation Systems*, 14(1), pp. 155-168.
- OSORIO-LIRD, A., CHAMORRO, A., VIDELA, C., TIGHE, S., & TORRES-MACHI, C. (2018). Application of Markov chains and Monte Carlo simulations for developing pavement performance models for urban network management. *Structure and Infrastructure Engineering*, 14(9), pp. 1169-1181.
- PARK, S., BANG, S., KIM, H., & KIM, H. (2019). Patch-based crack detection in black box images using convolutional neural networks. *Journal of Computing in Civil Engineering*, 33(3), 04019017.
- PENADÉS-PLÀ, V., GARCÍA-SEGURA, T., MARTÍ, J., & YEPES, V. (2016). *A review of multi-criteria decision-making methods applied to the sustainable bridge design*. *Sustainability*, 8(12), 1295.
- QIAO, Y., FLINTSCH, G.W., DAWSON, A.R., & PARRY, T. (2013). Examining effects of climatic factors on flexible pavement performance and service life. *Transportation Research Record: Journal of the Transportation Research Board*, 2349(1), pp. 100-107.
- RAGNOLI, A., DE BLASII, M., & DI BENEDETTO, A. (2018). Pavement distress detection methods: A review. *Infrastructures*, 3(4), 58.

- REGGIN, A., SHALABY, A., EMANUELS, R., & MICHEL, G. (2008). Urban considerations for using road roughness to manage road networks. *7th International Conference on Managing Pavement Assets*.
- SANTERO, N. J., & HORVATH, A. (2009). Global warming potential of pavements. *Environmental Research Letters*, 4(3), 034011.
- SHI, Y., CUI, L., QI, Z., MENG, F., & CHEN, Z. (2016). Automatic road crack detection using random structured forests. *IEEE Transactions on Intelligent Transportation Systems*, 17(12), pp. 3434-3445.
- TORRES-MACHI, C., PELLICER, E., YEPES, V., & CHAMORRO, A. (2017). Towards a sustainable optimization of pavement maintenance programs under budgetary restrictions. *Journal of Cleaner Production*, 148, pp. 90-102.
- WANG, H., CHEN, Z., & SUN, L. (2013). Pavement roughness evaluation for urban road management. In *ICTE 2013: Safety, Speediness, Intelligence, Low-Carbon, Innovation*, pp. 2709-2713.
- WANG, X., & HU, Z. (2017). Grid-based pavement crack analysis using deep learning. *4th International Conference on Transportation Information and Safety (ICTIS), 2017*, pp. 917-924. IEEE.
- WU, Z., & FLINTSCH, G. W. (2009). Pavement preservation optimization considering multiple objectives and budget variability. *Journal of Transportation Engineering*, 135(5), pp. 305-31.
- ZHANG, L., YANG, F., ZHANG, Y. D., & ZHU, Y. J. (2016). Road crack detection using deep convolutional neural network. *IEEE International Conference on Image Processing (ICIP), 2016*, pp. 3708-3712. IEEE.
- ZOU, Q., CAO, Y., LI, Q., MAO, Q., & WANG, S. (2012). CrackTree: Automatic crack detection from pavement images. *Pattern Recognition Letters*, 33(3), pp. 227-238.