

02-018

INTEGRATED MANAGEMENT SYSTEM FOR THE PREDICTIVE MAINTENANCE OF INTERURBAN ROADS USING ARTIFICIAL INTELLIGENCE TECHNIQUES

González-Marco, Carlos ⁽¹⁾; García-Segura, Tatiana ⁽¹⁾; López-Marco, José Ramón ⁽²⁾; Mansanet, Jordi ⁽³⁾; Sánchez-Robles, Juan ⁽⁴⁾

⁽¹⁾ Universitat Politècnica de València, ⁽²⁾ Pavasal Empresa Constructora, ⁽³⁾ Solver Machine Learning, ⁽⁴⁾ CPS Infraestructuras Movilidad y Medio Ambiente

Maintenance management systems are essential for road administrations to know the condition of the road network and to analyze the best maintenance solutions based on the available budget. To achieve this goal, Neurovias project has developed a system for identifying and quantifying road damage by processing 3D images obtained from a camera system installed on a conventional vehicle. The damage identification is used to determine pavement condition index of each road section, predict the evolution of the condition over the years and obtain the most sustainable maintenance plan. All these processes are performed automatically using neural networks and heuristic optimization algorithms. As a result, an efficient plan of maintenance and rehabilitation activities is obtained that improves the condition of the network, reduces the risk of accidents, and reduces costs and CO2 emissions in the short and long term.

Keywords: Integrated management; maintenance; pavement; artificial intelligence

SISTEMA DE GESTIÓN INTEGRAL PARA EL MANTENIMIENTO PREDICTIVO DE VÍAS INTERURBANAS MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL

Los sistemas de gestión del mantenimiento son fundamentales para que las administraciones competentes en materia de carreteras conozcan el estado de la red de carreteras y analicen las mejores soluciones de mantenimiento en base al presupuesto disponible. Con este objetivo, el proyecto Neurovias ha desarrollado un sistema de identificación y cuantificación de los daños presentes en las carreteras a partir del procesamiento de imágenes 3D obtenidas mediante un sistema de cámaras instalado en un vehículo convencional. La identificación de los daños es utilizada para determinar la condición del pavimento de cada tramo de carretera, predecir la evolución de la condición a lo largo de los años y obtener el plan de mantenimiento más sostenible. Todos estos procesos se realizan de forma automática utilizando redes neuronales y algoritmos heurísticos. Como resultado, se obtiene un plan eficiente de actividades de mantenimiento y rehabilitación que mejora la condición de la red, reduce el riesgo de accidentes, y disminuye los costes y las emisiones de CO2 a corto y largo plazo.

Palabras clave: gestión integral; mantenimiento; pavimentos; inteligencia artificial

Agradecimientos: Esta investigación ha sido financiada por la Agencia Valenciana de la Innovación (AVI) y cofinanciada por la Unión Europea a través del Programa Operativo del Fondo Europeo de Desarrollo Regional (FEDER) de la Comunitat Valenciana 2014-2020 (INNEST/2021/6



© 2023 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. Introducción

1.1. Importancia de la conservación de la red viaria

La red de carreteras interurbana supone uno de los pilares fundamentales para el desarrollo económico y social de una región o país. En este sentido, cabe destacar el importante papel que han jugado durante la pandemia ocasionada por el COVID-19, y cuyos efectos continuamos viviendo hoy en día. Según la Asociación Mundial de la Carretera, las infraestructuras viales han sido vitales para: (1) garantizar la conectividad; (2) mantener en movimiento las mercancías, trabajadores y servicios; (3) mantener la integridad de las cadenas de suministro; (4) velar por que los y las profesionales de la salud pública, las fuerzas y cuerpos de seguridad del estado y otros grupos de respuesta ante emergencias puedan realizar su trabajo con eficacia (PIARC, 2020).

Para que las vías interurbanas continúen estando al servicio de la sociedad, garantizando un óptimo nivel de confort, operabilidad y seguridad, es imprescindible que se lleve a cabo un adecuado mantenimiento de su infraestructura mediante la predicción del deterioro y la optimización del plan de mantenimiento (Bull, 2003; Hajj, Loria & Sebaaly, 2010). En caso contrario, el coste asociado al transporte de mercancías y de personas se incrementaría, pues un mal estado de la vía está asociado a un mayor consumo de combustible y, consecuentemente, a un aumento también de las emisiones de gases de efecto invernadero. Asimismo, un pavimento en mal estado constituye un gran peligro para los conductores, produce un mayor desgaste de los neumáticos, y puede llegar a ocasionar daños en los vehículos, además de incrementar el consumo de combustible por encima del 10 % (AEC, 2022).

De acuerdo con la auditoría sobre el estado de conservación de la red de carreteras, realizada por la Asociación Española de la Carretera (AEC) en 2021, de los 101.700 km de tramos autonómicos y nacionales analizados se estima que un 12,78 % —13.000 km— presenta deterioros superficiales graves, siendo las roderas, grietas bajo rodadas, agrietamientos gruesos, disgregaciones, deformaciones y grietas erráticas los daños más frecuentes, y que pueden llegar a afectar a la propia estructura del firme.

Particularmente, la Comunitat Valenciana presentaba en 2021 el mayor déficit acumulado en inversiones de conservación con respecto a la red viaria de todo el país, alcanzando un total de 115.740 €/km, siendo, sin embargo, el tercero por la cola en referencia al estado del firme. Por tanto, resulta imprescindible elaborar un nuevo plan de inversión en infraestructura vial, con el fin de mejorar el estado de la red de carreteras en España, y facilitar su transición hacia una movilidad más segura, ecológica y sostenible (AEC, 2022).

1.2. Estrategias de gestión en la actualidad

Para llevar a cabo una gestión eficiente del estado de conservación de las vías es necesario disponer de datos del estado del pavimento (Hassan, Lin & Thananjeyan, 2017). En la actualidad, existen diversos procedimientos basados en modelizaciones algorítmicas que permiten identificar los factores que presentan mayor impacto en la evolución del estado del pavimento (Ragnoli, De Blasiis & Di Benedetto, 2018).

Para la evaluación de la condición del pavimento en el entorno interurbano, diferentes métodos de auscultación tratan de determinar, principalmente, la regularidad de la superficie, las características de la interacción entre el neumático y la carretera, y el estado estructural. Sin embargo, estos métodos no permiten identificar la tipología de los daños que presenta la carretera para determinar el tratamiento posterior, por lo que adicionalmente se exige una inspección visual. Asimismo, la inspección visual es el método más común para la detección

de daños en redes urbanas (Loprencipe, Pantuso & Di Mascio, 2017), a pesar de que este procedimiento adolece de una escasa objetividad y efectividad, ya que depende de la experiencia técnica del observador, además de suponer un gran coste temporal para obtener la información de toda la red en urbes de gran tamaño (Coenen & Golroo, 2017).

Aunque muchos de los modelos calibrados hasta la fecha se han centrado en el Índice de Regularidad Internacional (IRI), los pocos que han empleado un indicador global como el Índice de Condición del Pavimento (PCI) —basado en un total de 19 tipos de daño para pavimentos asfálticos— han concluido que el empleo de indicadores globales conduce a resultados más precisos que el uso de indicadores simples (Osorio et al., 2014; ASTM, 2023). Recientemente, la AEC, en su *Guía para la rehabilitación y la gestión de los firmes de las carreteras dependientes de las administraciones locales* (AEC, 2020), ha instado a la evaluación del estado del firme mediante este indicador.

1.3. Propuesta proyectual: NEUROVÍAS

Como se ha expuesto anteriormente, no sólo es importante disponer de datos para llevar a cabo una buena gestión del mantenimiento viario, sino que esta información debe estar acompañada de herramientas adecuadas para la predicción del deterioro, y de un sistema de optimización del plan de mantenimiento para poder proyectar de manera eficiente la conservación a corto y largo plazo (Peraka & Biligiri, 2020).

En este contexto, el proyecto NEUROVÍAS pretende dar respuesta a la más que necesaria gestión y planificación de las inversiones de conservación en materia de pavimentos de vías interurbanas. Como resultado de este proyecto, y apoyándose en estudios previos sobre los indicadores mencionados, que consideran la calibración de modelos matemáticos para predecir la condición del pavimento en función de diversos factores estructurales y ambientales (Dong, Huang & Richards, 2015; Hassan, Lin & Thananjeyan, 2017), se obtendrá una herramienta que permitirá priorizar las actuaciones de mantenimiento y conservación de la red, basándose principalmente en la identificación y cuantificación de los deterioros presentes en las carreteras a partir del procesamiento de imágenes 3D, obtenidas de la grabación de la superficie de las vías mediante un sistema de cámaras instalado en un vehículo convencional, utilizando técnicas de inteligencia artificial basadas en aprendizaje automático profundo (*deep learning*), así como características relacionados con la edad del pavimento, el volumen de tráfico, la climatología y las características estructurales del paquete de firmes.

2. Objetivos

El objetivo principal del proyecto es el desarrollo y aplicación de una solución innovadora capaz de llevar a cabo, por una parte, la monitorización, evaluación y predicción de la condición del pavimento de vías interurbanas (que comprenden carreteras convencionales y multicarril, autovías y autopistas) y, por otra parte, la optimización del plan de gestión del mantenimiento del pavimento de las mismas.

Para la monitorización del pavimento, se propone un sistema económico y de fácil instalación en un vehículo convencional, compuesto por dos cámaras que permitan caracterizar los daños existentes en la superficie del pavimento. La determinación y cuantificación de estas patologías se obtendrá mediante técnicas de procesamiento automático de imágenes basadas en el concepto de *deep learning*, concretamente redes neuronales convolucionales que habiliten el análisis estereoscópico, para dotar de mayor precisión y capacidad al sistema a la vez que se reducen los tiempos de computación frente a otras técnicas. Así, y mediante la evaluación objetiva y automática de las imágenes, se podrá determinar la condición del pavimento sin requerir de inspecciones visuales adicionales ni el uso de técnicas invasivas.

Por otra parte, la utilización de un modelo predictivo de aprendizaje automático permitirá pronosticar el estado futuro de la red a partir de los datos aportados, y así realizar estimaciones precisas de la variación de la condición del pavimento, permitiendo que el sistema proponga los tratamientos preventivos más eficientes (eso es, aquellos que reportan mayor economía y mejoran la condición global de la red viaria) y que impiden alcanzar una fase de degradación acelerada que ponga en riesgo la seguridad de los usuarios. La prospección de daños, además, permitirá la generación de una base de datos que complete los registros actuales con información actualizada y detallada.

A partir de los resultados de la evaluación de la condición actual y predicha del pavimento, se llevará a cabo una optimización multiobjetivo y una toma de decisiones que permita priorizar las actuaciones a corto, medio y largo plazo que minimicen el impacto económico, ambiental y social, mientras maximizan la seguridad y el confort de los usuarios de la red. Finalmente, como resultado se obtendrá un plan eficiente de actividades de mantenimiento y rehabilitación, que conducirá a la disminución del coste y las emisiones de CO₂, mejorando asimismo la condición de la red y reduciendo el riesgo de accidentes. Además, se propone el uso del aprendizaje por refuerzo (*reinforcement learning*) para simular diferentes escenarios futuros y determinar cómo deberá modificarse el plan de mantenimiento óptimo.

Todos los componentes del sistema, integrados en una aplicación web junto con un sistema de información geográfica (GIS), permitirán el almacenamiento, análisis y visualización de toda la información, así como la extracción de los datos en formatos aptos para su manejo en programas de modelado de información de la infraestructura (BIM).

3. Metodología

3.1. Sistema de monitorización

La inspección visual del estado de los pavimentos en vías interurbanas requiere el análisis de capturas fotográficas tomadas a las velocidades propias del tramo vial, hasta 120 km/h. En la actualidad, las técnicas existentes de captura de imágenes del pavimento a altas velocidades requieren el uso de técnicas LiDAR (detección y medición de impulsos láser) para obtener modelos de análisis tridimensionales de alta precisión (Ramos & Sánchez, 2019), suponiendo un alto coste en desarrollo de esos sistemas.

NEUROVÍAS, en cambio, propone la utilización de dos cámaras convencionales integradas en un software de captura sincronizada, cuyas imágenes permiten la detección de profundidad tras su introducción en una red neuronal dedicada. De esta forma, aplicando un escalado de profundidad 3D, se habilita la detección y clasificación de la severidad de aquellos defectos que dependan de su elevación (como la profundidad de los huecos).

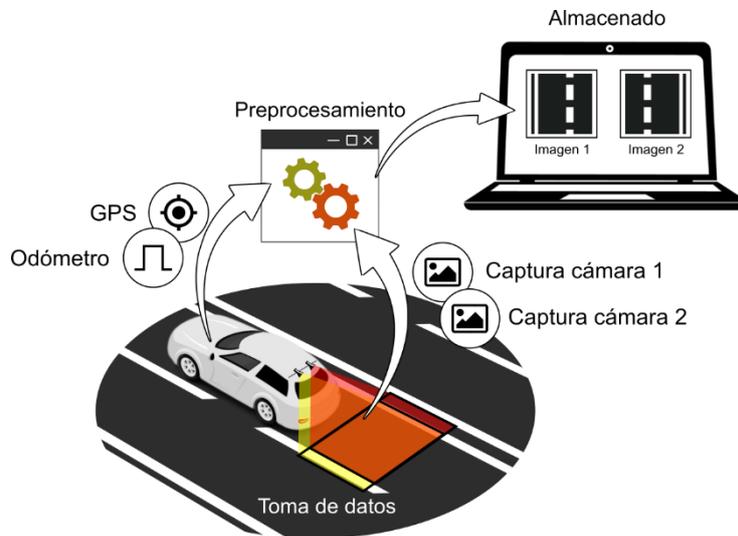
Estas cámaras, dispuestas transversalmente —izquierda y derecha— e instaladas en el portaequipajes de un vehículo, realizan una captura regular de imágenes cada 1,6 m a lo largo de toda la superficie del carril. Las capturas son almacenadas en un repositorio, donde se incorporan metadatos referidos a las marcas temporales de obtención, georreferencia, numeración del ítem, e indicación de la cámara fuente (Figura 1).

Tras su captura, las imágenes serán introducidas al sistema mediante una interfaz web (véase el punto 3.5) para su procesamiento, que incluirá:

1. La corrección de las aberraciones ópticas, como la distorsión en barril u ojo de pez.
2. La fijación de condiciones lumínicas, como la luminancia o el contraste.
3. La adecuación del tamaño de la imagen.
4. La obtención de los solapes transversales (entre capturas de carriles adyacentes) y longitudinales (a lo largo del mismo carril) de las imágenes, mediante técnicas de fotogrametría, para no replicar los mismos daños.

El conjunto corregido de imágenes permitirá el análisis posterior para la identificación y clasificación de los daños presentes mediante redes convolucionales.

Figura 1: Esquema del proceso de captura de imágenes de NEUROVÍAS.



3.2. Identificación y clasificación de los desperfectos

En las vías interurbanas, debido al impacto que los daños del pavimento generan en su usabilidad, y las dificultades técnicas y económicas que implican los estudios in situ, es importante definir un sistema y un procedimiento que permitan detectar y discriminar las afecciones propias de este tipo de infraestructuras, así como cuantificar su área y profundidad para evaluar la severidad de cada daño. En NEUROVÍAS, el proceso de identificación y clasificación se lleva a cabo mediante el empleo de técnicas de *deep learning*, partiendo de una calibración inicial de una red neuronal convolucional que supone el entrenamiento de los algoritmos mediante imágenes preclasificadas manualmente para, posteriormente, convertir al sistema en autónomo y dotarle de capacidad para reconocer y clasificar los daños de forma automática, a partir de nuevas capturas del firme.

La utilización de redes convolucionales, como parte de la inteligencia artificial basada en el *deep learning*, responde a su orientación hacia los trabajos de manipulación de imágenes, siendo los métodos más recurridos en la actualidad debido a su versatilidad, ya que no sólo brindan buenos resultados en tareas de clasificación, sino que permite la identificación de múltiples objetos dentro de una misma imagen, segmentando el área que estos cubren. Dentro de las redes convolucionales, existen diferentes topologías destinadas a la resolución de unas tareas particulares, de las que se debe considerar también el impacto sobre el equipo en el que desarrollan su labor (consumo de recursos como las gráficas dedicadas o GPU, el coste temporal de aprendizaje, etc.).

Las redes escogidas para la detección y clasificación de los desperfectos se basan en el modelo de red convolucional, debido a la capacidad de estas redes de tomar como entrada los datos de píxeles sin requerir procesamiento previo, y deducir cómo extraer las características que, en última instancia, permiten dirimir qué objeto constituyen. Además, debido a que pueden coexistir varios desperfectos en una misma imagen, las redes serán de tipo multietiqueta.

Con respecto a la medición de la severidad, el sistema se apoya en las redes convolucionales de tipo U-Net, donde una arquitectura, basada en la segmentación semántica, recorre una ruta de contracción y expansión donde se suceden operaciones de convolución, funciones de rectificación y *pooling* (generalización de parámetros extraídos por la convolución). Otra de

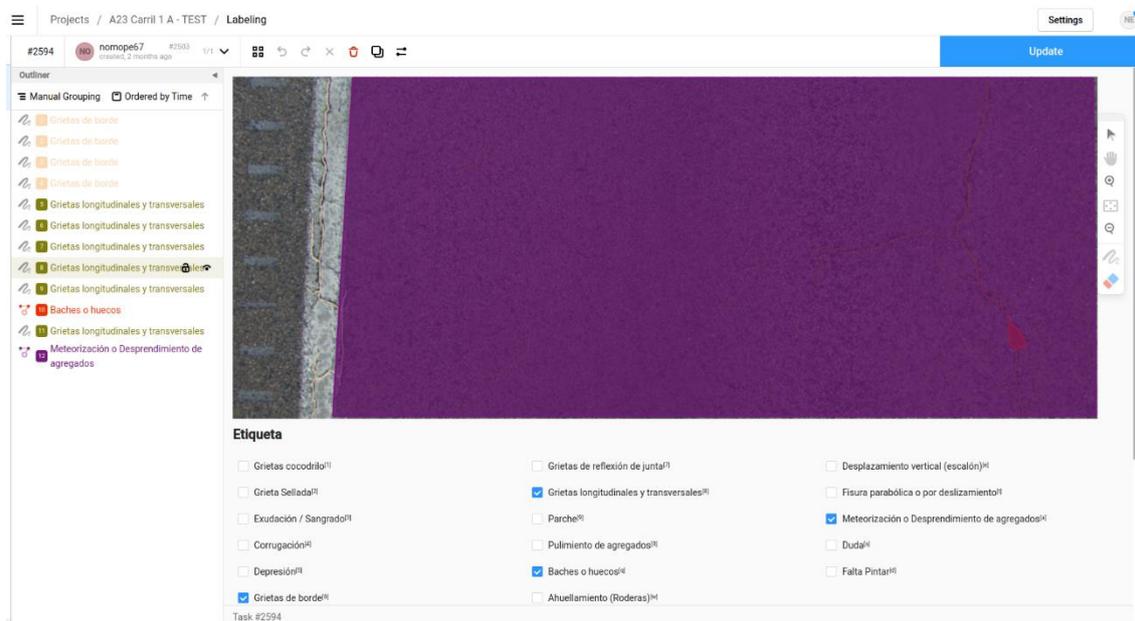
las características de estas redes es su capacidad para enmarcar objetos dentro de una imagen con celeridad y precisión, permitiendo realizar mediciones sobre su área en píxeles (Ronneberger, Fischer & Brox, 2015). Otra funcionalidad de esta red en el sistema es la detección de la profundidad de ciertos daños, mediante la segmentación de sus relieves, para así clasificar su severidad mediante imágenes simultáneas —capturas de ambas cámaras durante la toma de datos—, siendo necesario el entrenamiento mediante imágenes con la profundidad previamente etiquetada de forma manual.

Para el correcto entrenamiento de las redes mencionadas, y a fin de que éstas ofrezcan los resultados deseados, previamente es necesario efectuar una minuciosa tarea manual de etiquetado en un conjunto seleccionado de imágenes del pavimento. Estimando una selección mínima de 500 imágenes por cada uno de los defectos y severidades que se pretenden introducir en el posterior cálculo del estado de la carretera (en el caso de NEUROVÍAS, el PCI), el aumento de la precisión dependerá del incremento de este conjunto de datos de entrada.

Primeramente, el equipo de NEUROVÍAS, en una labor elongada durante varios meses de trabajo, seleccionó y estimó un conjunto de imágenes que asciende a 132.982 en el momento actual, correspondientes a diversos tramos interurbanos comprendidos en la Comunitat Valenciana, y cuyo trabajo continuará desarrollándose para incrementar la precisión y fiabilidad de las redes.

Seguidamente, y para facilitar el etiquetado manual, se desarrolló una aplicación basada en el proyecto Label Studio, que vincula una interfaz de usuario con diferentes herramientas de marcado (véase la Figura 2, donde se aprecia una captura con daños por grietas, baches y meteorización etiquetados) con un repositorio o base de datos de imágenes, permitiendo también un seguimiento de la evolución del etiquetado.

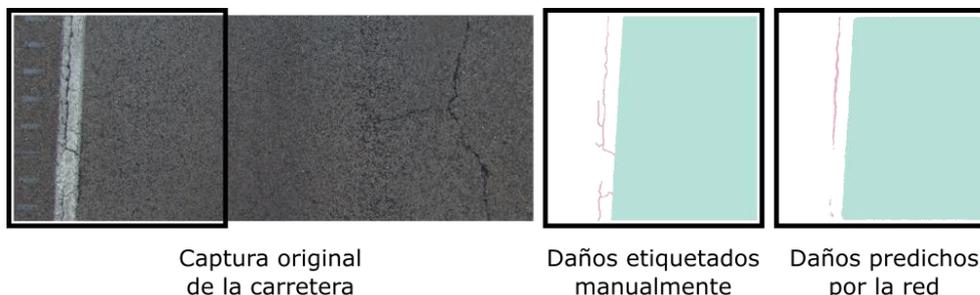
Figura 2: Captura de la herramienta de etiquetado desarrollada.



Este conjunto de imágenes y etiquetas nutren el entrenamiento de las redes convolucionales anteriormente descritas, a las que se entrega otro conjunto de imágenes independiente para validar la precisión de sus resultados, mediante el empleo de las máscaras obtenidas a partir de su análisis (véase la Figura 3, donde se aprecia la comparación entre la captura de la Figura 2, su etiquetado y los daños predichos por la red: grietas coloreadas en tonos rosados, y meteorización en azul celeste). En la actualidad, el nivel de fiabilidad de los modelos está

por encima del 90% en los desperfectos analizados, siendo el área bajo la curva ROC la métrica utilizada como objetivo de maximización de los modelos.

Figura 3: De izquierda a derecha: captura real, daños y máscara de daños predicha por la red (vista en detalle). En rosa, agrietamientos; en azul celeste, meteorización.



3.3. Evaluación de la condición del pavimento

Debido a que no es posible determinar el estado general del pavimento a partir de un daño en particular y, por tanto, estimar cuál debe ser la actividad de mantenimiento o rehabilitación más adecuada, es necesario recurrir a un indicador que represente con exactitud la situación, y que resulte adecuado para la agrupación y segmentación por tramos uniformes de la superficie de análisis, estableciendo un criterio objetivo sobre su estado.

Entre los índices evaluables encontramos el anteriormente mencionado Índice de Regularidad Internacional (IRI), las deflexiones (que reflejan el estado estructural del firme, obtenidas mediante un deflectómetro de impacto) y el coeficiente de rozamiento transversal o CRT (indicador de la capacidad de adherencia durante la circulación según el método SRIM), entre otros, como posibles candidatos que reflejan la caracterización de la vida de un pavimento. Sin embargo, la implementación del Índice de Condición del Pavimento (PCI) ofrece una visión amplia que integra la diversidad de daños y severidad identificables, a la par que ofrece una metodología de fácil implementación y sin la necesidad de recurrir a herramientas especializadas.

NEUROVÍAS, siguiendo las recomendaciones de la AEC y los planteamientos de los estudios más recientes, recurre al PCI como principal indicador de la condición del pavimento. El PCI valora el estado del firme en un rango de cero a cien —representando el 0 su destrucción, y el 100 su perfecto estado— contemplando hasta 19 categorías de daños para pavimentos asfálticos (los más representativos de la red viaria española), si bien se han tomado en consideración para su detección por las redes convolucionales aquellos más presentes en las carreteras de nuestra geografía, incluyendo:

1. Agrietamientos: grietas de cocodrilo, de reflexión de junta, de borde, fisuras, y grietas longitudinales y transversales.
2. Desniveles: ahuellamientos, escalones, depresiones, baches y huecos.
3. Condiciones del firme: exudación, corrugación, y pulimento, meteorización y desprendimiento de agregados.

Este conjunto de desperfectos ha sido fruto de un estudio de correlación, donde se han identificado las posibles causas de su aparición, y asociándose una tipología de intervención de mantenimiento, permitiendo así que, en posteriores etapas, se agrupe y retransmita la superficie y se asignen costes y parámetros homogéneos para el proceso de optimización. Adicionalmente, el sistema prevé la incorporación de los indicadores de estado del pavimento comentados anteriormente: IRI, CRT y deflexiones, así como la textura superficial.

Por otra parte, y debido a que el objetivo de NEUROVÍAS es ofrecer una planificación optimizada de las actuaciones de mantenimiento de la red a estudiar, este análisis no sólo se

encuentra limitado al momento presente (período de auscultación de las carreteras), sino que deberá considerar la evolución futura del estado de la infraestructura, y ser capaz de integrar dicha predicción en una optimización a largo plazo. Para cumplir esa meta, es necesario desarrollar un algoritmo de predicción que permita incorporar esos parámetros en el análisis multicriterio.

La solución propuesta para NEUROVÍAS consiste en el empleo de técnicas de *deep learning*, particularmente redes neuronales, para estimar la evolución de la condición del pavimento (PCI) a partir de la monitorización y evaluación del estado conocido. Estos procedimientos pueden simular las complejas relaciones entre los datos de entrada y salida, y, motivado por estudios previos desarrollados por los autores del proyecto, se plantean diferentes escenarios donde, más allá de los daños presentes, existen factores externos que influyen en el estado de la vía, como: las condiciones climáticas, la capacidad estructural del pavimento, y el volumen de tráfico. Por ello, las redes desarrolladas contemplarán estos factores como datos de entrada en los modelos desarrollados, con el fin de aumentar la certeza de las predicciones (Llopis-Castelló et al., 2020). Se han obtenido modelos con ajustes de R^2 superiores al 70 %.

La implementación de este tipo de técnica en el software le dotará de una herramienta de predicción de la condición del pavimento precisa y con la ventaja adicional de retroalimentar la salida del sistema, mediante el aprendizaje y mejora de la precisión conforme se obtengan datos de monitorización de las redes viarias. Debido a la escasez inicial de datos, para el entrenamiento inicial de la red se ha utilizado la base de datos del Long Term Pavement Performance (LTPP) elaborada por la Federal Highway Administration (FHWA) de EE. UU.; este repositorio contiene información de todas las posibles variantes de entrada (estructura, clima, tráfico, daños y otros índices del estado del pavimento) de un elevado número de vías interurbanas de Estados Unidos y Canadá. En este sentido, esta base de datos contiene, además de los daños del pavimento, información sobre otros indicadores (deflexiones, IRI y CRT o *skid number*), permitiendo la calibración de los modelos no sólo para indicadores globales, como el PCI, sino también para esos indicadores de estado individuales.

3.4. Gestión del mantenimiento: optimización multiobjetivo y toma de decisiones

Tras conocer el estado de la red viaria a partir de la inspección automática y su evolución a lo largo del tiempo, el siguiente paso es evaluar cuál es el plan de mantenimiento más adecuado. Con una visión a largo plazo, se definen las actuaciones que deberán llevarse a cabo durante el periodo de análisis determinado, con el fin de conseguir una óptima asignación de los recursos durante el ciclo de vida del pavimento.

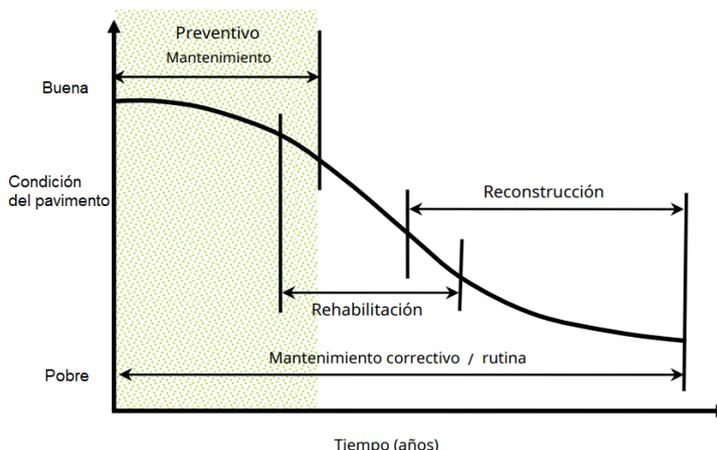
Siguiendo la política de la American Association of State Highway and Transportations Officials (AASHTO), que determina que la gestión de pavimentos debe ser una herramienta de ayuda para los decisores, dicha gestión tendrá como objetivo fundamental la definición de las estrategias óptimas para proporcionar, evaluar y mantener los pavimentos en un buen estado de servicio (AASHTO, 2012). Este hecho, ligado a concepto de rentabilidad de los activos (eficiencia en la sistematización del mantenimiento, actualización y operación de las carreteras) marcado por la Federal Highway Administration (FHWA), permiten definir cuáles son los objetivos principales del sistema de gestión de pavimentos (Zimmerman et al., 2011):

1. Determinar el estado actual del pavimento, así como su condición futura.
2. Estimar las necesidades y requerimientos de financiación para tratamientos futuros.
3. Proporcionar recomendaciones de mantenimiento y rehabilitación del pavimento.
4. Evaluar las estrategias de tratamiento, según los diferentes niveles de inversión.
5. Validar la necesidad de aumentar la financiación para mantenimiento y rehabilitación.
6. Evaluar los impactos a largo plazo.

De esta forma, se obtiene como resultado un plan de gestión que define qué secciones de una red vial debe ser intervenidas, y qué actuaciones de mantenimiento deben ejecutarse. Estos tratamientos de mantenimiento pueden ser clasificados en tres tipos (Figura 4):

1. Mantenimiento preventivo, al principio de la vida útil del pavimento.
2. Rehabilitación, como mantenimiento correctivo o rutinario.
3. Reconstrucción, al finalizar la vida útil del pavimento.

Figura 4: Ciclo de vida típico de un pavimento y categorías de tratamientos (APTech, 2013).



Se puede lograr una mayor eficiencia en la elaboración del plan de mantenimiento mediante la implementación de una optimización multiobjetivo fundada en algoritmos heurísticos (eso es, basados en búsquedas locales que recorren un espacio de soluciones concreto) que permitan identificar las secciones de la red que deben ser tratadas cada año del período de estudio. De esta forma, y para demostrar la eficiencia de la optimización, ésta debe responder ante un conjunto de objetivos y restricciones, formulados en base a las necesidades técnicas, económicas, ambientales y sociales. Sin embargo, deberán ser las personas usuarias del sistema (entidades y corporaciones administradoras de las redes de transporte) quienes finalmente decidan qué objetivos y restricciones sean considerables o preponderantes en su entorno en base a los criterios propuestos en esta metodología.

Para la implementación de la herramienta de optimización multiobjetivo (Figura 5) es necesario elaborar una base de datos completa, contenedora de toda la información requerida para valorar las distintas actuaciones de mantenimiento en base a los daños detectados y su severidad. Así, la planificación tratará de encontrar aquellas actuaciones de mantenimiento que consigan optimizar las funciones objetivo, mientras se cumplan las restricciones implicadas en el problema de optimización.

El sistema de NEUROVÍAS propone cinco criterios —funciones objetivo— para el proceso de optimización multiobjetivo:

1. Coste económico de las actuaciones (C): implica la menor utilización de recursos en el desarrollo de las tareas de mantenimiento. La medición cuantitativa será la de euros de ejecución material (€).
2. Coste ambiental de las actuaciones (E): supone la reducción del impacto ambiental de las actuaciones de mantenimiento. Medible cuantitativamente en kilogramos de dióxido de carbono asociados a las actuaciones (kg CO₂).
3. Coste de los usuarios (CU): incluye el coste de operación del vehículo (VOC), y el coste temporal o retraso de viaje adicional debido a los trabajos sobre la vía. Medido cuantitativamente en euros (€).

- Seguridad vial (A): factor de modificación de accidentes (CMF) relacionado con las molestias a los usuarios, y vinculado al estado del pavimento (IRI) y el tráfico (IMD).
- Mejora del estado de la red a lo largo del período de evaluación (B): implica obtener el mejor estado viario posible con el menor coste e impacto. Para ello, se evalúa el estado de la red a lo largo de los años mediante modelos de predicción, valorando la evolución del PCI en el tiempo. La medición cuantitativa será el valor de la integral definida en el período de evaluación de la curva del PCI.

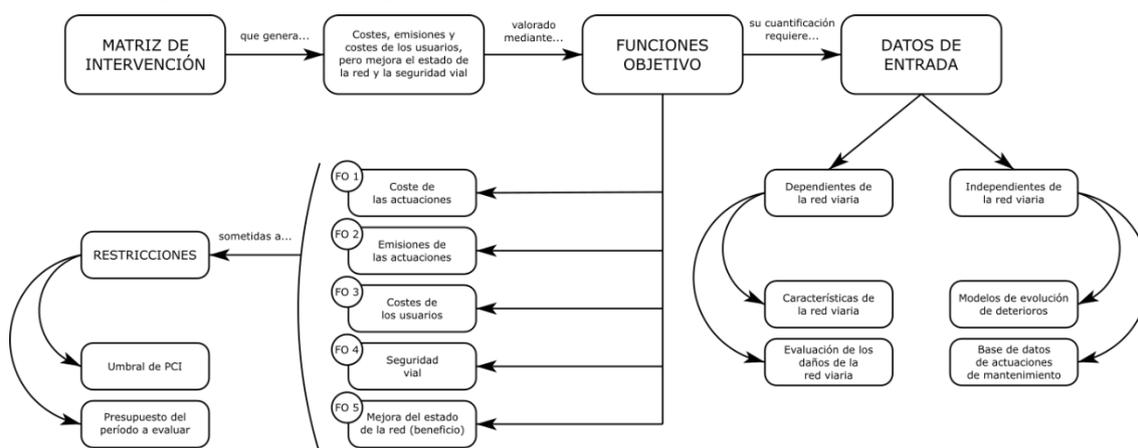
La función objetivo total será el resultado de sumar los valores normalizados de las anteriores funciones objetivo, multiplicando cada una por su peso relativo. Su formulación se muestra en la ecuación (1), donde C_{norm} , E_{norm} , CU_{norm} , A_{norm} , B_{norm} representan las funciones objetivo normalizadas de coste económico, emisiones asociadas, costes de los usuarios, seguridad vial, y mejora del estado de la red, respectivamente, y w_i el peso asociado a una función objetivo i .

$$FO_T = w_C \cdot C_{norm} + w_E \cdot E_{norm} + w_{CU} \cdot CU_{norm} + w_A \cdot A_{norm} + w_B \cdot B_{norm} \quad (1)$$

Con respecto a las restricciones, NEUROVÍAS plantea la utilización de dos parámetros que limitarán la actuación de la optimización:

- Estado mínimo admisible del pavimento (valor mínimo del PCI).
- Presupuesto máximo admisible por parte del decisor en ejecución material (€).

Figura 5: Esquema general del proceso de optimización multiobjetivo.



3.5. Integración y despliegue: aplicación web

El conjunto de herramientas indicadas en los puntos anteriores, integrados en un programa de interfaz multiplataforma y apoyados en un Sistema de Información Geográfica (GIS), conforman el sistema de NEUROVÍAS.

Bajo el planteamiento de un desarrollo de aplicación web, que permite su acceso desde cualquier punto y bajo requisitos tecnológicos mínimos, la consecución de acciones anteriormente descritas seguiría la siguiente sucesión dentro del sistema:

- Importación de la geometría de las carreteras de interés, en un formato común (ESRI Shapefile, SHP) y con tramificación en función de las características homogéneas.
- Importación de las imágenes tomadas y georreferenciadas del pavimento.
- Filtrado y cálculo del solape de las imágenes.
- Análisis mediante la red convolucional: detección/clasificación de los daños presentes.
- Procesamiento de imágenes estereoscópicas para la estimación de la severidad de los daños incorporando la profundidad.

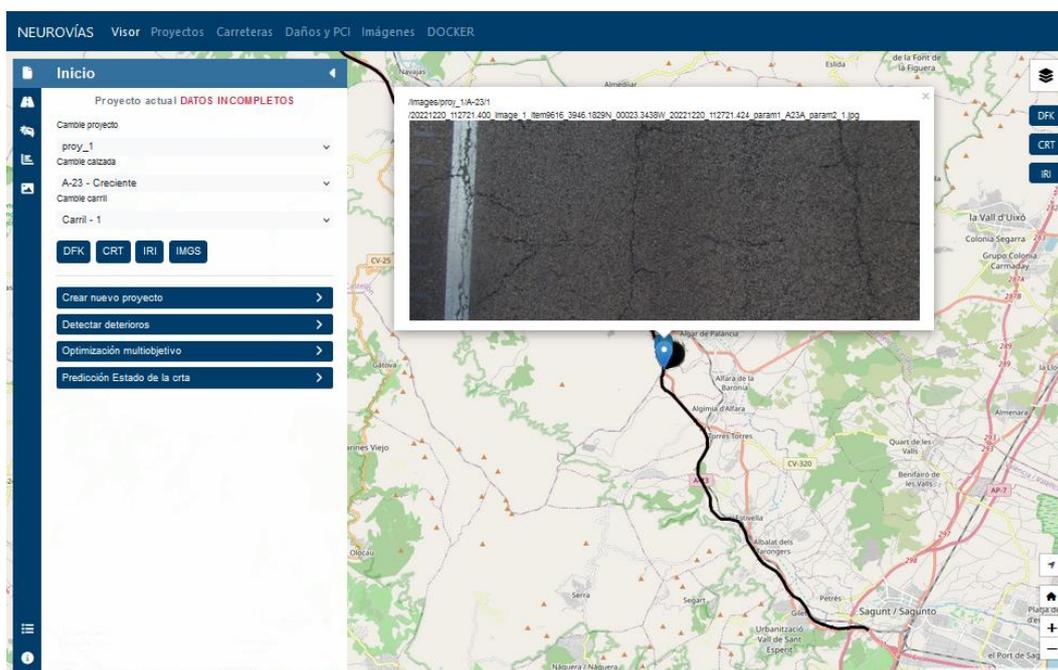
6. Establecimiento de la segmentación de los tramos del firme y evaluación de la condición del pavimento (PCI) de cada sección.
7. Predicción del deterioro, optimización del plan de mantenimiento y toma de decisiones.

La interfaz gráfica, desarrollada con la tecnología Django de Python, permitirá que el usuario de la aplicación introduzca sus preferencias mediante un panel de toma de decisiones, en el que se puedan escoger parámetros como, por ejemplo, el período de análisis, la prevalencia de unas u otras funciones objetivo, las restricciones presupuestarias, o los valores de condición del pavimento mínimos admisibles. Una versión preliminar de la interfaz gráfica de la utilidad puede apreciarse en la Figura 6.

La información de las carreteras de interés importadas, incluyendo características como la intensidad de tráfico, la velocidad máxima de circulación, la tipología viaria y sus características, etc., quedará introducida en una base de datos de gestión geográfica basada en la tecnología PostgreSQL, que permita su procesamiento y su integración en el visor GIS —mapa de carreteras caracterizado— para su visualización por parte del usuario.

El software será capaz de interpretar las imágenes subidas por el usuario, referenciándolas a las tramificaciones presentes en la base de datos, y procesándolas automáticamente para permitir la visualización del estado de la red, habilitando la consulta del estado presente y futuro del pavimento en base a las estimaciones de los modelos predictivos. Asimismo, se podrán visualizar las actuaciones óptimas en cada punto, en base a los resultados de la optimización, y apreciar todas las salidas sobre el visor GIS de la interfaz, como las afecciones al tráfico, el impacto medioambiental y el coste económico de dichas actuaciones.

Figura 6: Versión preliminar de la interfaz para la aplicación web de NEUROVIAS.



Por último, el sistema de NEUROVIAS permitirá la obtención de un informe que recopile toda la información de la red bajo estudio y los resultados de la valoración de la condición del pavimento, la predicción del deterioro y el plan de gestión óptimo.

Adicionalmente, la captura y análisis de los datos producidos por el sistema permitirá la generación de una base de datos georreferenciada de los deterioros presentes en la red viaria interurbana, que podrá obtenerse en un formato estandarizado para permitir la incorporación de datos del estado de la red, pudiendo integrarse tanto en modelos BIM de carreteras, como

en mapas de alta definición que puedan ser incorporados en los futuros vehículo autónomos y conectados. De esta forma, el acceso a la información actualizada también será de gran utilidad para los usuarios de la red, permitiendo programar rutas más económicas con un menor impacto medioambiental.

4. Conclusiones

El sistema NEUROVÍAS propone una solución para llevar a cabo una gestión integral del mantenimiento de los pavimentos en vías interurbanas, a través de la integración de diferentes utilidades. Por una parte, un sistema automático y georreferenciado permite la monitorización del pavimento mediante un complejo de captura de imágenes sincronizadas, habilitando la evaluación y cuantificación de los desperfectos del firme. Este análisis se realiza mediante redes neuronales convolucionales, de forma que se obtiene una evaluación objetiva y automatizada de la condición del pavimento sin recurrir a inspecciones visuales ni técnicas invasivas.

Por otra parte, el software cuenta con un módulo de predicción del estado futuro de la vía, aplicando técnicas de *deep learning* gracias a los datos recogidos en la monitorización, que permitirán retroalimentar y mejorar el propio sistema, además de ofrecer mayor dimensión a la herramienta de planificación y ayuda a la toma de decisiones que, optimizando mediante algoritmos heurísticos y multicriterio, plantea una solución apoyándose en aspectos sociales, económicos y ambientales.

El conjunto de herramientas, combinado con un sistema de información geográfica (GIS) para el almacenamiento, análisis y visualización de la información, y desarrollado en el seno de una aplicación multiplataforma, permitirá, asimismo, la elaboración de informes y la utilización de los datos en formatos adecuados para programas de modelado de información de la infraestructura (BIM), además de permitir la generación de una base de datos histórica.

De esta forma, NEUROVÍAS es capaz de abarcar la monitorización y gestión de los planes de conservación de toda la red de carreteras, implicando un menor esfuerzo del que actualmente se requiere y, además, ofreciendo distintas herramientas que participan en la ayuda a la planificación y la ejecución de los trabajos de intervención anticipada, lo que implica una reducción en los sobrecostos del trabajo en todas las áreas, la reducción de riesgos de accidentalidad por parte de los usuarios de la vía, y la disminución del impacto ambiental, gracias a la optimización de los recursos disponibles.

5. Referencias

- AASHTO (2012). *Pavement Management Guide*. American Association of State Highway and Transportation. Washington D.C., USA: AASHTO.
- AEC (2020). *Guía para la rehabilitación y la gestión de los firmes de las carreteras dependientes de las administraciones locales*. Asociación Española de la Carretera, Madrid.
- AEC (2022). *Examen al estado de la red viaria. Las carreteras españolas, a “años luz” de convertirse en infraestructuras verdes y conectadas*. Madrid: Asociación Española de la Carretera.
- APTech (2013). *An Independent Assessment of the Washington County, Oregon Pavement Preservation and Maintenance Program. Final Report*. Urbana, USA: APTech.
- ASTM (2023) *Standard Practice for Roads and Parking Lots Pavement Condition Index Surveys*. ASTM Standards 04.03 (D6433-23). West Conshohocken, USA: ASTM.
- Bull, A. (2003). *Traffic congestion: the problem and how to deal with it*. Santiago, Chile: United Nations, Economic Commission for Latin America and the Caribbean.

- Coenen, T. B. J., & Golroo, A. (2017). A review on automated pavement distress detection methods. *Cogent Engineering*, 4 (1), 1374822. <https://doi.org/10.1080/23311916.2017.1374822>
- Dong, Q., Huang, B., & Richards, S. H. (2015). Calibration and application of treatment performance models in a pavement management system in Tennessee. *Journal of Transportation Engineering*, 141 (2), 4014076. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000738](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000738)
- Hajj, E. Y., Loria, L., & Sebaaly, P. E. (2010). Performance Evaluation of Asphalt Pavement Preservation Activities. *Transportation Research Record: Journal of the Transportation Research Board*, 2150 (1), 36-46. <https://doi.org/10.3141/2150-05>
- Hassan, R., Lin, O., & Thananjeyan, A. (2017). Probabilistic modelling of flexible pavement distresses for network management. *International Journal of Pavement Engineering*, 18(3), 216–227. <https://doi.org/10.1080/10298436.2015.1065989>
- Llopis-Castelló, D., García-Segura, T., Montalbán-Domingo, L., Sanz-Benlloch, A., & Pellicer, E. (2020). Influence of pavement structure, traffic, and weather on urban flexible pavement deterioration. *Sustainability* 12(22), 1–20. <https://doi.org/10.3390/su12229717>
- Loprencipe, G., Pantuso, A., & Di Mascio, P. (2017). Sustainable pavement management system in urban areas considering the vehicle operating costs. *Sustainability* 9 (3). <https://doi.org/10.3390/su9030453>
- Osorio, A., Chamorro, A., Tighe, S., & Videla, C. (2014). Calibration and validation of condition indicator for managing urban pavement networks. *Transportation Research Record: Journal of the Transportation Research Board*, 2455 (1), 28–36. <https://doi.org/10.3141/2455-04>
- Peraka, N. S. P., & Biligiri, K. P. (2020). Pavement asset management systems and technologies: A review. *Automation in Construction*, 119. <https://doi.org/10.1016/j.autcon.2020.103336>
- PIARC (2020). *Covid-19: efectos y respuestas iniciales de los organismos de carreteras y transporte a la pandemia*. París, Francia: Asociación Mundial de la Carretera.
- Ragnoli, A., De Blasiis, M. R., & Di Benedetto, A. (2018). Pavement distress detection methods: A review. *Infrastructures*, 3 (4).
- Ramos García, J. A., & Sánchez Domínguez, F. (2019) Aplicación, en la gestión a nivel de red, de los datos de inspección de deterioros de los pavimentos con tecnología Láser 3D. *PIARC 26th World Road Congress*.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science* 9351, 234-241.
- Zimmerman, K. A., Peshkin, D. G., Wolters, A. S., & Smadi O. (2011). Update to AASHTO Pavement Management Guide. *Draft Report NCHRP Project 20-07, Task 277*. Washington, DC, USA: AASHTO.

Comunicación alineada con los Objetivos de Desarrollo Sostenible

