

(02-017) - Neural Network-Based Models for Predicting Pavement Performance for Spain context using LTPP database

Molinero-Pérez, Noelia ¹; Sanz-Benlloch, Amalia ¹; García-Segura, Tatiana ¹;
Montalbán-Domingo, Laura ¹; Pellicer, Eugenio ¹

¹ Universitat Politècnica de València

Understanding the evolution of pavement deterioration is a complex but essential challenge for the effective planning of conservation operations. Several studies have demonstrated the significant influence of factors such as the current state, traffic intensity, and climatic conditions on pavement deterioration. This study aims to develop a prediction model based on neural networks to forecast the evolution of pavement condition. To achieve this, diverse combinations of input data are explored, encompassing elapsed time, pavement damage, current pavement condition, weather variables (temperature and precipitation), and traffic intensity (especially heavy traffic). The findings underscore that the most precise model incorporates elapsed time, current condition, and traffic and weather conditions as input variables. The inclusion of pavement damage in the models introduces some predictive errors due to the variable evolution of different damage types over time. Furthermore, this model exhibits a deterioration evolution curve similar to the theoretical curve of pavement deterioration, reinforcing its validity and utility in the strategic planning of conservation interventions.

Keywords: Pavement deterioration; Deterioration prediction; Neural Networks; Weather; Traffic

Modelos basados en redes neuronales para predecir el comportamiento de los firmes en España utilizando la base de datos LTPP

Conocer la evolución del deterioro del pavimento es un desafío complejo pero esencial para una planificación efectiva de las operaciones de conservación. Diversas investigaciones han demostrado la influencia significativa de factores como el estado actual, la intensidad del tráfico y las condiciones climáticas, en el deterioro del pavimento. El objetivo de este estudio es desarrollar un modelo de predicción basado en redes neuronales para anticipar la evolución de la condición del pavimento. Para ello se analizan diversas combinaciones de datos de entrada, entre los que se encuentran: el tiempo transcurrido, los daños del pavimento, el estado actual del firme, las condiciones climáticas (temperatura y precipitación) y la intensidad de tráfico (especialmente tráfico pesado). Los resultados revelan que el modelo más preciso considera como datos de entrada el tiempo transcurrido, el estado actual y las condiciones de tráfico y climáticas. Incluir los daños en los modelos conlleva ciertos errores de predicción debido a la evolución variable de los distintos tipos de daños con el tiempo. Además, este modelo exhibe una curva de evolución del deterioro similar a la curva teórica de evolución del deterioro del pavimento, respaldando su validez y utilidad para la planificación de intervenciones de conservación.

Palabras clave: Deterioro de pavimentos; Predicción del deterioro; Redes Neuronales; Clima; Tráfico

Correspondencia: Noelia Molinero Pérez noemope@cam.upv.es , Amalia Sanz Benlloch asanz@upv.es , Laura Montalbán Domingo laumondo@upv.es , Tatiana García Segura tagarse@upv.es; Eugenio Pellicer pellicer@upv.es



©2024 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/>).

Agradecimientos: La publicación es parte del proyecto PID2022-141875OA-I00, financiado por MCIN/AEI/10.13039/501100011033 y por FEDER Una manera de hacer Europa.

1. Introducción

El correcto mantenimiento de la red viaria es esencial para garantizar y aumentar los beneficios socioeconómicos (Bull, 2003; Hajj et al., 2010). Por consiguiente, las administraciones responsables en la toma de decisiones deben asignar una financiación y gestión apropiadas para el mantenimiento de las carreteras, con el fin de garantizar un estado óptimo de la red vial. Un mantenimiento inadecuado o deficiente podría resultar en un deterioro significativo del firme, lo que supone un aumento en el coste de actuación y repercusiones significativas para la sociedad, incluyendo un aumento de los costes de operación de los vehículos, una mayor accidentalidad o un incremento significativo de la contaminación atmosférica (AEC, 2020; García-Segura et al., 2023).

Por este motivo, diversas agencias de carreteras han desarrollado Sistemas de Gestión de Pavimentos (SGP) para evaluar el estado de los firmes y definir estrategias óptimas para las actividades de mantenimiento con el propósito de mejorar el rendimiento de la red vial y minimizar los fondos necesarios (Chen & Zheng, 2021; Peraka & Biligiri, 2020). Un SGP eficiente debe integrar un modelo de predicción del deterioro del pavimento para planificar las actuaciones a largo plazo de forma adecuada (Donev & Hoffmann, 2020; Dong et al., 2015; Hassan et al., 2017).

En este sentido, se han desarrollado numerosos estudios para identificar qué factores afectan al deterioro de las carreteras a lo largo del tiempo (Ragnoli et al., 2018). Estudios previos demuestran que el deterioro del pavimento se ve afectado por distintos factores, como son el clima, el tráfico y la capacidad estructural del pavimento (Llopis-Castelló et al., 2020). Además, algunos autores han valorado diferentes propuestas para las variables de entrada de los modelos de predicción, como la edad del pavimento, los daños presentes en la carretera, el histórico de mantenimientos realizados, así como la utilización de otros índices de condición del pavimento (Guo et al., 2021) como por ejemplo el Índice Internacional de Rugosidad (IRI).

La mayoría de los modelos de deterioro de pavimentos utilizan el IRI. Sin embargo, el uso de indicadores globales de comportamiento ha demostrado ser más eficaz y fiable para la evaluación del estado de los pavimentos que un solo índice (ASTM International, 2020; Osorio et al., 2014). Entre todos ellos, el *Pavement Condition Index* (PCI) es el parámetro más comúnmente utilizado. De hecho, la Asociación Española de la Carretera (AEC) recomienda la evaluación del estado del pavimento mediante dicho indicador (AEC, 2020). Los modelos para predecir el deterioro del pavimento tratan de realizar estimaciones aceptables de las variaciones que experimentan estos índices de manera que el SGP pueda proponer las actividades de mantenimiento y rehabilitación adecuadas para conseguir un estado óptimo del pavimento, evitando niveles altos de deterioro.

Existen diversos tipos de modelos de predicción del deterioro de pavimentos, que varían en complejidad y enfoque. Las técnicas o métodos utilizados podrían clasificar los modelos de predicción en: (i) modelos determinísticos, (ii) modelos probabilísticos, (iii) redes neuronales artificiales.

Los modelos determinísticos se basan en relaciones matemáticas y físicas conocidas para predecir el deterioro del pavimento, estableciendo relaciones lineales o no lineales entre las variables explicativas y el indicador de la condición del deterioro empleado que se pretende predecir (Hassan et al., 2017). Si bien estos modelos han sido ampliamente utilizados porque permiten a los ingenieros de carreteras predecir fácilmente el estado del pavimento y comprender la influencia de los parámetros incluidos en el modelo, presentan desventajas en cuanto a la necesidad de gran cantidad de datos históricos para la calibración de los modelos, así como la insuficiente capacidad para representar adecuadamente el fenómeno estocástico del deterioro del pavimento a lo largo del tiempo (Arambula et al., 2011; Dong et al., 2015;

Llopis-Castelló et al., 2020; Meegoda & Gao, 2014; Pérez-Acebo et al., 2020). Otra desventaja es que no se pueden aplicar más allá de los confines de los datos experimentales y producen un valor único de la variable dependiente (Hassan et al., 2017). De ahí que se recomiende generalmente la calibración cuando se transfiere un modelo determinista de un sitio a otro (Pérez-Acebo et al., 2020).

Los modelos probabilísticos incorporan la incertidumbre y la variabilidad en las predicciones del deterioro del pavimento (Golroo & Tighe, 2009; Thomas & Sobanjo, 2013). Utilizan distribuciones de probabilidad y técnicas estadísticas para modelar la aleatoriedad de los procesos que afectan al deterioro del pavimento (Uddin, 2006; Abaza, 2016). Durante los últimos años, se han desarrollado diferentes formas de modelos basados en la probabilidad (Lethanh et al., 2015), pero no son tan empleados como los deterministas. Los modelos probabilísticos bayesianos y de Markov son los que más interés despiertan y los más empleados (Uddin, 2006). Entre ellos, las cadenas de Markov de tiempo discreto, son probablemente el modelo probabilístico más utilizado en la modelización del deterioro del pavimento, con muchos ejemplos en la literatura (Li et al., 1997; Thomas et al., 2013; Abaza, 2016; Abaza, 2018; Osorio-Lird et al., 2018; Soncim et al., 2018; Pérez-Acebo et al., 2018; Mohammadi et al., 2019; García-Segura et al., 2020).

Los modelos basados en redes neuronales artificiales (ANN por sus siglas en inglés) emplean cálculos paralelos para la representación del conocimiento y el procesamiento de la información (Tarawneh & Nazzal, 2014), permitiendo resolver ciertos tipos de problemas que resultan difíciles de abordar mediante métodos numéricos y estadísticos tradicionales. El enfoque de las ANN difiere de la ejecución de una serie de instrucciones fijas, tal como lo hace un programa de ordenador convencional o un análisis estadístico. En cambio, resuelven en paralelo las entradas presentadas durante el periodo de entrenamiento. Algunos autores las consideran una "caja negra", ya que los resultados se producen sin establecer relaciones causales entre la entrada y la salida (Abdelaziz et al., 2020; Sollazzo et al., 2017).

La modelización con ANN no exige una relación detallada entre las variables y puede emplearse cuando varias variables influyen en el resultado (Soncim et al., 2018). Tras un periodo de entrenamiento, se pueden introducir nuevos datos para su evaluación. Sin embargo, la modelización es compleja, requiere una gran cantidad de datos experimentales y la principal limitación es que dificulta la interpretación de resultados. A pesar de esto, estos modelos computacionales tienen la ventaja de adquirir conocimiento a partir de ejemplos y representar las relaciones existentes entre los datos de entrada y salida, ofreciendo una elevada precisión en la predicción (Shtayat et al., 2022), motivo por el cual en los últimos años han aumentado su popularidad.

2. Objetivo

El objetivo de este estudio es desarrollar un modelo de predicción de las carreteras españolas, a partir de la base de datos LTPP, basado en redes neuronales para anticipar la evolución de la condición del pavimento. La necesidad de tal modelo surge de la vital importancia del mantenimiento de pavimentos de la infraestructura vial, donde la anticipación y la intervención en momentos óptimos son fundamentales para garantizar la seguridad y la eficiencia del transporte. Al prever la degradación del pavimento, se posibilita la programación de acciones preventivas en el momento adecuado, lo que permite mejorar su estado y, por ende, reducir potencialmente los riesgos para los conductores, así como los costos asociados a reparaciones mayores.

3. Metodología

La metodología de investigación incluye cuatro etapas: 1) obtención de datos, 2) preparación de los datos; 3) desarrollo del modelo y 4) validación del modelo. La Figura 1 muestra de forma esquemática el proceso seguido en la investigación.

Figura 1. Esquema de la metodología empleada



3.1 Obtención de datos

Los datos fueron recogidos de la base de datos americana *Long-Term Pavement Performance* (LTPP) debido a la falta de datos a nivel nacional. Esta base de datos contiene información relativa a la estructura del firme, los daños del pavimento, las condiciones climáticas y el tráfico, de una gran cantidad de carreteras en Estados Unidos y Canadá. Además, contiene información sobre indicadores del estado del pavimento como deflexiones, IRI (*International Roughness Index*) y el skid number similar al Coeficiente de Rozamiento Transversal (CRT).

Toda esta información se descargó para carreteras interurbanas con superficie asfáltica de zonas de EE.UU. con climatología similar a España. La Tabla 1 recoge los datos descargados de LTPP. De este modo, se tiene para distintas secciones de carretera, la información del estado del pavimento en diferentes años.

Tabla 1. Datos descargados de LTPP.

Categoría	Variable	Unidades
Daños	Piel de cocodrilo*	ft ²
	Agrietamiento en bloque*	ft ²
	Grieta de borde*	ft
	Grieta longitudinal en banda de rodadura*	ft
	Grieta longitudinal no en banda de rodadura*	ft
	Grieta longitudinal sellada en banda de rodadura	ft
	Grieta longitudinal sellada no en banda de rodadura	ft
	Grieta transversal*	ft
	Grieta transversal sellada	ft
	Parcheo*	ft ²
	Bache o hueco*	n ^o
	Hinchamiento	ft ²
	Exudación	ft ²
	Pulimento de agregados	ft ²
Desprendimiento de agregados	ft ²	
Indicadores	PCI	adim.
	IRI	m/km
	Deflexión	

Categoría	Variable	Unidades
	<i>Skid number</i> (similar a CRT)	
Características	Edad del pavimento	años
	Número estructural	-
	CN	-
Tráfico	AADT	Nº veh.
	AADTT	Nº veh. pesados
	KESAL	1000*ESAL
Clima	Precipitación de lluvia	mm
	Precipitación de nieve	mm
	Temperatura media	°C

* Se distinguen tres tipos de severidad: baja, media y alta.

Nota: AADT = Promedio anual de la intensidad media diaria de tráfico. AADTT = Promedio anual de la intensidad media diaria de tráfico pesado. KESAL = Estimación anual de la carga equivalente sobre un eje (en miles). CN = *Construction Number*, indica el número de actuaciones que se han realizado.

3.2 Preparación de los datos

A partir de los datos de los daños del pavimento descargados de la base de datos LTPP, se calculó el PCI siguiendo la metodología detallada en la norma para estudios de índices de condición del pavimento de carreteras y estacionamientos *Standard Practice For Roads And Parking Lots Pavement Condition Index Surveys* (ASTM International, 2020) y se eliminaron los datos anómalos. Se consideraron datos anómalos aquellos que, en una misma sección y sin realizar actuaciones de mantenimiento, el PCI aumentaba en el tiempo (mejoraba el estado de la carretera).

Con el fin de relacionar conjuntos de datos pasados y futuros (inferencia causal entre los datos de entrada y salida del modelo) se implementó una tabla de tuplas. Para la construcción de dicha tabla de tuplas se analiza cada segmento de vía de forma independiente, distinguiendo los datos tomados bajo una misma actuación, es decir, con mismo CN (*Construction number*) ya que este indicador refleja el número de actuaciones que se han realizado. De esta forma, cada entrada de la tabla de tuplas contendrá los valores previos y consecuentes con una desviación temporal Δt . Además, este período entre muestras podrá, a su vez, servir de valor de entrada a la red neuronal con el objetivo de implementar una función de edad sobre los datos.

La Figura 2 recoge un ejemplo de la construcción de la tabla de tuplas a partir de los datos descargados. En este ejemplo, se tienen dos segmentos de vía distintos (Segmento 1 y Segmento 2). Del Segmento 1 se tienen datos en seis años distintos (1999-2004), sin embargo, atendiendo al CN se observa que, antes de la toma de datos del año 2001, se ha realizado una actuación (cambio del CN). Por lo tanto, para la creación de la tabla de tuplas del Segmento 1 se tiene, por una parte, las fechas con CN=1 y por otra, las fechas con CN=2. En total se obtuvieron 6400 tuplas de datos a partir de una tabla original de 4128 filas de datos. Sin embargo, según las variables de entrada seleccionadas esta muestra se verá reducida, ya que las redes neuronales no admiten entradas nulas y no todas las tuplas tienen datos de todas las variables.

Figura 2. Ejemplo de construcción de la tabla de tuplas a partir de los datos descargados.

Datos descargados			Tabla de tuplas							
Segmento 1	CN 1	1999	→	Segmento 1	CN 1	1999	Δt	Segmento 1	CN 1	2000
Segmento 1	CN 1	2000		Segmento 1	CN 2	2001	Δt	Segmento 1	CN 2	2002
Segmento 1	CN 2	2001		Segmento 1	CN 2	2001	Δt	Segmento 1	CN 2	2003
Segmento 1	CN 2	2002		Segmento 1	CN 2	2001	Δt	Segmento 1	CN 2	2004
Segmento 1	CN 2	2003		Segmento 1	CN 2	2002	Δt	Segmento 1	CN 2	2003
Segmento 1	CN 2	2004		Segmento 1	CN 2	2002	Δt	Segmento 1	CN 2	2004
Segmento 2	CN 1	1995		Segmento 1	CN 2	2003	Δt	Segmento 1	CN 2	2004
Segmento 2	CN 1	1997		Segmento 2	CN 1	1995	Δt	Segmento 2	CN 1	1997

La muestra se segmentó de modo que el 70% de los datos se seleccionaron aleatoriamente para desarrollar el modelo y el otro 30% se utilizó para la validación del modelo.

3.3 Desarrollo del modelo

Para determinar el modelo de predicción se estudiaron las redes neuronales prealimentadas (FNN). El desarrollo de las redes se llevó a cabo en Python mediante la librería Keras (con núcleo de TensorFlow).

En cuanto al diseño de estas redes, se analizaron redes con una y dos capas intermedias, y se contemplaron diferentes tipos de funciones de activación para las capas: sigmoide, tangente hiperbólica (TanH), lineal o RELU (*Rectified Linear Unit*). Por otro lado, se contemplaron distintas propuestas de variables de entrada y salida.

Para seleccionar los modelos más adecuados se utilizaron los siguientes criterios: el coeficiente de determinación (R^2), el *error absoluto medio* (MAE por sus siglas en inglés) y el error cuadrático medio (MSE por sus siglas en inglés).

Coeficiente de determinación (R^2)

El coeficiente de determinación R^2 es una medida estadística que indica la proporción de la varianza en la variable dependiente que es predecible a partir de la o las variables independientes en un modelo de regresión. Un R^2 cercano a 1 indica que el modelo explica una gran parte de la variabilidad de la variable dependiente, mientras que un R^2 cercano a 0 indica que el modelo no proporciona una explicación significativa para la variabilidad de la variable dependiente.

Error Absoluto Medio (MAE)

El error absoluto medio (MAE) es una medida de la diferencia absoluta entre los valores *Mean Absolute Error* predichos por el modelo y los valores reales. Se calcula como la media de las diferencias absolutas entre las predicciones y los valores reales.

Error cuadrático medio (MSE)

El error cuadrático medio (MSE por sus siglas en inglés) es una métrica empleada para evaluar la precisión de un modelo. Se calcula como la media de los cuadrados de las diferencias entre las predicciones y los valores reales. El MSE penaliza los errores más grandes de manera más significativa que el MAE debido al cuadrado en la fórmula. Esto significa que los errores más grandes tendrán un impacto mucho mayor en el valor del MSE en comparación con el MAE.

3.4 Validación

Finalmente, para escoger el modelo de predicción, se realizó una validación de los modelos que presentaban mejores resultados en la fase de entrenamiento. Para ello, se tuvo en cuenta el coeficiente de determinación (R^2), pero principalmente se buscaba el modelo que presentase menor porcentaje de error en la predicción, considerando como error de predicción un PCI fuera de los límites de este indicador.

4. Desarrollo del modelo de predicción

El modelo de predicción desarrollado en este estudio se basa en una estructura de red neuronal.

Por lo general, las ANN se componen de tres capas: la capa de entrada, la capa de salida y una serie de capas ocultas intermedias, donde tienen lugar las complejas operaciones no lineales. Cada una de las capas mencionadas contiene varias neuronas, que están conectadas mediante conexiones neuronales. Estas últimas tienen pesos que cambian al iterar para alcanzar la solución óptima.

Para diseñar una red neuronal es imprescindible definir: (i) las variables de entrada, (ii) las variables de salida, y (iii) la estructura de la red.

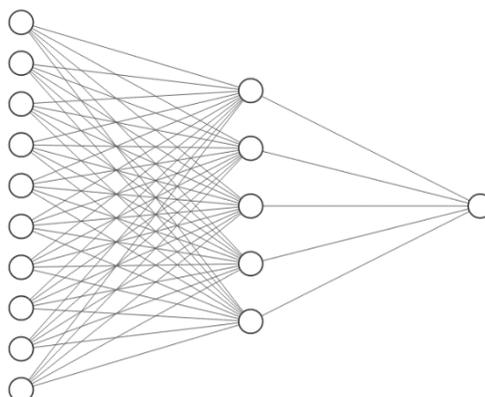
En este caso, se consideraron como variables de entrada:

- Los daños del pavimento. Obtenidos de LTPP.
- El PCI. Calculado a partir de los daños del pavimento siguiendo la normativa del PCI (ASTM International, 2020).
- Las condiciones climáticas: precipitación acumulada por lluvia y nieve; y la temperatura media. Calculadas para los periodos correspondientes de la tabla de tuplas a partir de los datos de LTPP.
- El volumen de tráfico: el promedio anual de la intensidad media diaria de tráfico (AADT), el promedio anual de la intensidad media diaria de tráfico pesado (AADTT) y la estimación anual de la carga equivalente sobre un eje -en miles- (KESAL). Calculados para los periodos correspondientes de la tabla de tuplas a partir de los datos obtenidos de LTPP.
- Otros índices de la condición del pavimento: IRI, deflexiones y *skid number* (similar al CRT), obtenidos de LTPP.

En cuanto a las variables de salida, se consideraron el PCI y los daños del pavimento.

La estructura constaba de 3 o 4 capas: una capa de entrada, otra de salida y, 1 o 2 capas intermedias; con i nodos de entrada, k nodos de salida y $h = ((i-k)/2)$ nodos intermedios (Figura 3). Se escogió esta estructura tras comprobar que la inclusión de más de 1 ó 2 capas intermedias, no incrementaba la precisión de la red al predecir la condición del pavimento e incrementaba el tiempo de computación y el consumo de recursos del equipo base. Además, se contemplaron distintas funciones de activación para las diferentes capas: sigmoide, tangente hiperbólica (TanH), lineal o RELU (*Rectified Linear Unit*).

Figura 3. Red neuronal FNN implementada para valorar las entradas y salidas. Ejemplo con $i = 10$, y $k = 1$.



Se desarrollaron tantos modelos como posibles combinaciones diferentes de las variables de entrada y salida, el modelo de red neuronal, las funciones de activación de las capas y el número de capas intermedias. Es importante destacar que, según las variables de entrada seleccionadas esta muestra se verá reducida, ya que las redes neuronales no admiten entradas nulas y no todas las tuplas contenían datos de todas las variables.

Tras valorar los dos tipos de modelos (FNN y RNN) bajo diferentes escenarios, se detectó que los modelos FNN lograban un resultado adecuado en un tiempo de procesamiento considerablemente más bajo que las RNN.

De entre los modelos FNN, los modelos de predicción con mejores resultados (Tabla 2) contemplaban como variables de entrada el PCI, los daños, el tráfico y las condiciones climáticas. Además, se observó que tenían como función de activación de las capas intermedias la función tangente hiperbólica, y como salida la función lineal. Sin embargo, en cuanto al número de capas intermedias, según el modelo y las variables de entrada contempladas, los mejores resultados se obtenían con 1 o 2 capas, según el caso.

En cuanto a las variables de salida, se descartó la predicción de los daños por la dificultad en la clasificación futura según la severidad. Además, la predicción de los daños presenta otra dificultad mayor aún, debido a la evolución en el tiempo del daño en otro tipo de daño. Por lo tanto, se contempló como única variable de salida el PCI.

Tabla 2. Resultados de los mejores modelos de predicción.

Variables de entrada	N.º capas intermedias	MAE	MSE	R ²
Δt , PCI, daños	1	12,097	256,083	0,660
Δt, PCI, daños	2	11,867	246,058	0,671
Δt , PCI, daños, AADTT, Precip., Nieve, Temp.	1	10,944	212,317	0,711
Δt , PCI, daños, AADTT, Precip., Nieve, Temp.	2	11,008	219,858	0,699
Δt, PCI, daños, KESAL, Precip., Nieve, Temp.	1	10,588	196,041	0,747
Δt , PCI, daños, KESAL, Precip., Nieve, Temp.	2	10,757	205,408	0,723
Δt , PCI, AADTT, Precip., Nieve, Temp.	1	12,052	243,165	0,654
Δt , PCI, AADTT, Precip., Nieve, Temp.	2	11,900	238,252	0,658
Δt, PCI, KESAL, Precip., Nieve, Temp.	1	12,085	243,103	0,670

Variables de entrada	N.º capas intermedias	MAE	MSE	R ²
Δt , PCI, KESAL, Precip., Nieve, Temp.	2	12,072	245,657	0,662

Nota: Todos los modelos son FNN, con función de las capas intermedias la tangente hiperbólica, función de salida lineal y con una única variable de salida (PCI). MAE = Error Absoluto Medio, MSE = Error Cuadrático Medio, R² = coeficiente de determinación.

Finalmente se seleccionaron los siguientes modelos para su posterior validación:

- Modelo 1: FNN con dos capas intermedias con función de activación TanH y función lineal para la capa de salida. Variables de entrada: el tiempo transcurrido, el PCI y los daños del pavimento. Variable de salida: el PCI
- Modelo 2: FNN con una capa intermedia con función de activación TanH y función lineal para la capa de salida. Variables de entrada: el tiempo transcurrido, el PCI, los daños del pavimento, el tráfico (KESAL) y las condiciones climáticas (precipitación de lluvia y nieve y temperatura). Variable de salida: el PCI
- Modelo 3: FNN con una capa intermedia con función de activación TanH y función lineal para la capa de salida. Variables de entrada: el tiempo transcurrido, el PCI, el tráfico (KESAL) y las condiciones climáticas (precipitación de lluvia y nieve y temperatura). Variable de salida: el PCI

5. Validación

Tras seleccionar los mejores modelos, se realizó una validación de los diferentes modelos evaluando, además de los períodos naturales generados a partir de las combinaciones de las tuplas, la respuesta de los modelos frente a períodos interpolados de entre 1 y 5 años. Aunque el ajuste de los datos (R²) es muy importante, el principal criterio de selección del modelo fue la obtención del menor error posible en la predicción.

La Tabla 3 resume los criterios de validación empleados: el error de predicción y el ajuste de los datos (R²). Aunque el modelo 2 es el que obtiene un mayor R², la red presenta un número mayor de errores por valores resultantes inferiores al 0, alcanzando un 5,12 % de la muestra (de los cuales un 1,79 % es inferior a -1). Los errores generados por la red del modelo 1, se encuentran en su mayoría en valores de PCI cercanos al 0 ($25 < \text{PCI} \leq 0$) cuando el descenso se presenta demasiado brusco, resultando en total un 0,55 % de los valores de la muestra estudiada (de los que un 0,33 % del PCI final es inferior a -1). La tasa de error del modelo 3 es la más baja, con un 0,49 % de valores de PCI de salida inferiores al 0 y tan sólo un 0,16 % de PCI inferior a -1.

Tabla 3. Ajuste R² y error en la predicción.

Modelo	Variables de entrada	R ²	Error de predicción (%)	
			PCI<0	PCI<-1
1	Δt , PCI, daños	0,67	0,55	0,33
2	Δt , PCI, daños, KESAL, Precip., Nieve, Temp.	0,75	5,12	1,79
3	Δt , PCI, KESAL, Precip., Nieve, Temp.	0,67	0,49	0,16

El modelo 1 contempla, como datos de entrada, los daños presentes en el pavimento, el PCI calculado, y la diferencia de tiempo o Δt que se desea con respecto del PCI futuro (valor de salida). Este modelo respeta la aceleración del deterioro expuesta en la normativa del cálculo del PCI, que predice que, en determinados tramos de estado del PCI, el impacto del daño es mayor en el tiempo. Concretamente, en tramos de PCI entre 85 y 25 se observan pérdidas en

torno a 10 puntos de PCI, mientras que en los extremos ($PCI < 25$ y $PCI > 85$) son de 5 puntos, para una diferencia de 1 año (Δt); en diferencias de 5 años esta respuesta se suaviza, con valores de diferencia de entre 4 y 1 unidades (Tabla 4).

Tabla 4. Variación de PCI del modelo 1 de predicción.

Δt	ΔPCI	$100 \leq PCI \leq 85$	$85 < PCI \leq 70$	$70 < PCI \leq 55$	$55 < PCI \leq 40$	$40 < PCI \leq 25$	$25 < PCI \leq 0$
1 año	Promedio	6	11	13	12	10	5
	Máximo	21	36	43	35	29	18
	Mínimo	-2	-4	-3	-11	-4	-11
	Negativo	1	2	7	7	9	24
5 años	Promedio	4	4	3	2	1	1
	Máximo	6	6	6	4	3	2
	Mínimo	0	0	0	0	0	0
	Negativo	0	0	0	0	0	1

El modelo 2 incorpora datos de entrada, el KESAL, la precipitación por lluvia y nieve, y la temperatura promedio. Al igual que en el modelo anterior, la respuesta respeta la aceleración del deterioro de la curva de evolución del PCI, manteniéndola tanto para diferencias de 1 como de 5 años en torno a 12 puntos en tramos de PCI entre 25 y 70, y cerca de 8 puntos en los extremos ($PCI < 25$ y $PCI > 85$) (Tabla 5).

Tabla 5. Variación de PCI del modelo 2 de predicción.

Δt	ΔPCI	$100 \leq PCI \leq 85$	$85 < PCI \leq 70$	$70 < PCI \leq 55$	$55 < PCI \leq 40$	$40 < PCI \leq 25$	$25 < PCI \leq 0$
1 año	Promedio	8	9	13	12	10	6
	Máximo	19	49	39	40	25	19
	Mínimo	-2	-4	-8	-9	-7	-7
	Negativo	18	4	14	7	4	20
5 años	Promedio	8	9	13	12	10	6
	Máximo	19	49	39	40	25	19
	Mínimo	-2	-4	-8	-9	-7	-7
	Negativo	18	4	14	7	4	20

El modelo 3 descarta el uso de daños individuales como datos de entrada a la red. El comportamiento en intervalos de 1 y 5 años presenta aceleraciones de en torno a 11 puntos en los rangos de PCI entre 40 y 85, y 6 puntos o menos para los extremos ($PCI < 25$ y $PCI > 85$) (Tabla 6).

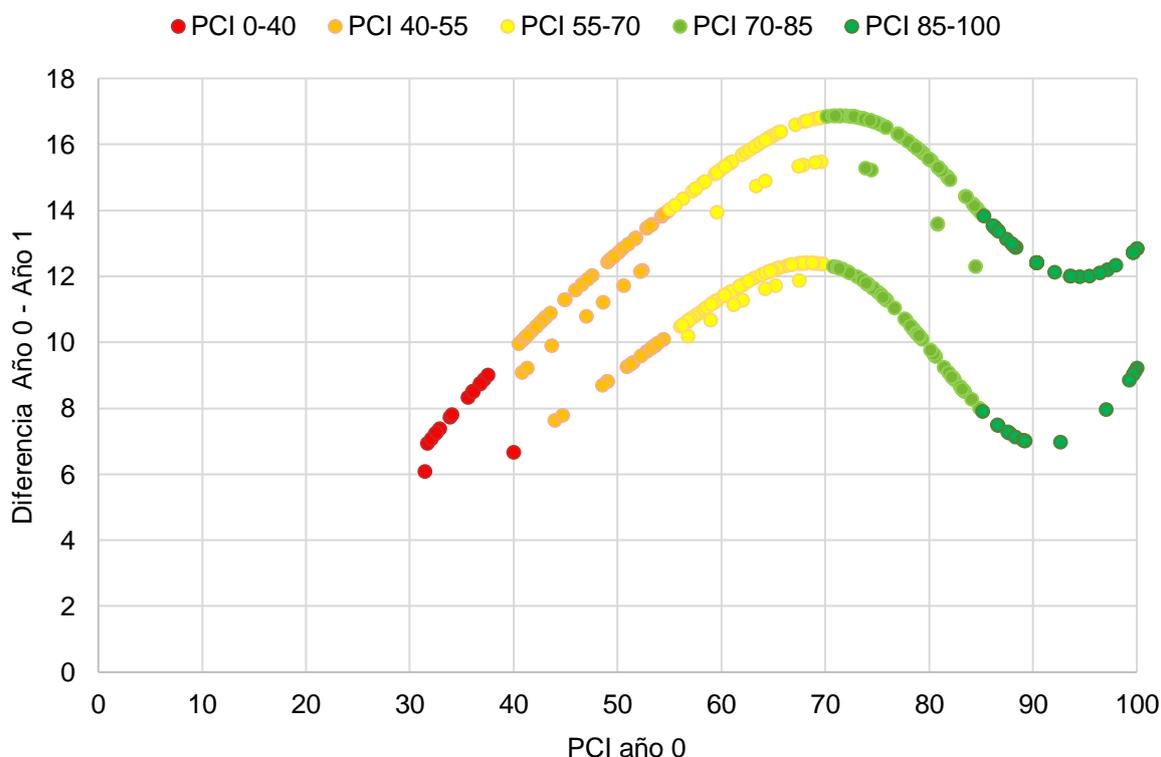
Tabla 6. Variación de PCI del modelo 3 de predicción.

Δt	ΔPCI	$100 \leq PCI \leq 85$	$85 < PCI \leq 70$	$70 < PCI \leq 55$	$55 < PCI \leq 40$	$40 < PCI \leq 25$	$25 < PCI \leq 0$
1 año	Promedio	7	12	12	9	7	4
	Máximo	15	17	17	12	10	7
	Mínimo	0	0	0	0	0	-5

Δt	ΔPCI	$100 \leq PCI \leq 85$	$85 < PCI \leq 70$	$70 < PCI \leq 55$	$55 < PCI \leq 40$	$40 < PCI \leq 25$	$25 < PCI \leq 0$
5 años	Negativo	0	0	0	0	0	11
	Promedio	4	3	3	2	2	1
	Máximo	7	6	6	4	3	3
	Mínimo	0	0	0	0	0	-2
	Negativo	0	0	0	4	1	7

Finalmente, el modelo seleccionado es el modelo 3, que no considera daños y sí condiciones de tráfico (KESAL) y clima (precipitación y temperatura). A pesar de no tener el mejor ajuste ($R^2=0,67$, frente al 0,75 del modelo 2), es el modelo que presenta una menor tasa de error a la salida, valores de PCI por debajo de 0. Además, este modelo presenta la ventaja de no depender de los daños, que resultan difícilmente escalables en el tiempo, debido a que presentan diversos grados de severidad y no evolucionan de forma lineal. Por otra parte, la Figura 4 representa el descenso de PCI en el primer año para cada tramo, donde cada curva representa un escenario de tráfico diferente. El modelo refleja claramente, que cuanto mayor es el nivel de tráfico, mayor es el deterioro. Además, la aceleración del deterioro del PCI se corresponde con la curva teórica de evolución del deterioro del pavimento, la cual refleja una pendiente muy suave cuando la condición del pavimento es muy buena, una mayor inclinación cuando la condición del pavimento es aceptable, y nuevamente una pendiente muy distendida cuando la condición del pavimento es pobre o muy mala.

Figura 4. Aceleración en el deterioro (disminución del valor de PCI) entre los años 0 y 1, según el nivel de PCI en el que se encuentre el pavimento en el año 0. Cada curva representa un escenario de tráfico diferente.



6. Conclusiones

En el presente trabajo se investigó el desarrollo de un nuevo modelo de predicción del estado del firme para pavimentos flexibles mediante redes neuronales artificiales, a partir de la base de datos LTPP. Se utilizaron un total de 4128 entradas de datos para este propósito.

Se evaluaron modelos de redes neuronales prealimentadas. Se exploraron diversas configuraciones para las redes, considerando variaciones en el número de capas intermedias y en las funciones de activación empleadas en las distintas capas. La estructura de red que arrojó mejores resultados consistía en una o dos capas intermedias con una función de activación tangente hiperbólica, y una función lineal para la capa de salida.

Se estudiaron diversas propuestas para las variables de entrada, incluyendo el tiempo transcurrido, los daños del pavimento, el estado actual del firme, las condiciones climáticas (temperatura y precipitación) y la intensidad de tráfico (particularmente el tráfico pesado). Los resultados revelan que el modelo más preciso considera como datos de entrada el tiempo transcurrido, el estado actual, las condiciones climáticas y las condiciones de tráfico. La inclusión de los daños en los modelos conlleva ciertos errores de predicción debido a la evolución variable de los distintos tipos de daños con el tiempo.

Para la predicción del estado del pavimento se contemplaron tanto los daños como el PCI. Finalmente, se optó por excluir los daños como variables a predecir debido a la variabilidad en la evolución temporal de los diferentes tipos de daños. Por lo tanto, la red neuronal contaba únicamente con el PCI como variable de salida.

Además, se observó que el modelo de predicción exhibe una curva de evolución del deterioro similar a la curva teórica de evolución del deterioro del pavimento, respaldando su validez y utilidad para la planificación de intervenciones de conservación. En este sentido, el modelo no solo contribuye a mejorar la seguridad y eficiencia del transporte, sino que también promueve una gestión más eficaz y sostenible de la infraestructura vial a largo plazo, reduciendo costes y minimizando interrupciones en el servicio.

7. Referencias

- Abaza, K. A. (2016). Back-calculation of transition probabilities for Markovian-based pavement performance prediction models. *International Journal of Pavement Engineering*, 17(3), 253–264. <https://doi.org/10.1080/10298436.2014.993185>
- Abdelaziz, N., Abd El-Hakim, R. T., El-Badawy, S. M., & Afify, H. A. (2020). International Roughness Index prediction model for flexible pavements. *International Journal of Pavement Engineering*, 21(1), 88–99. <https://doi.org/10.1080/10298436.2018.1441414>
- AEC. (2020). *Guía para la rehabilitación y la gestión de los firmes de las carreteras dependientes de las administraciones locales*.
- Arambula, E., George, R., Xiong, W., & Hall, G. (2011). Development and validation of pavement performance models for the state of Maryland. *Transportation Research Record*, 2225, 25–31. <https://doi.org/10.3141/2225-04>
- ASTM International. (2020). Standard practice for roads and parking lots pavement condition index surveys. *ASTM International*. <https://doi.org/10.1520/D6433-20.2>
- Bull, A. (2003). *Traffic congestion: the problem and how to deal with it*. United Nations, Economic Commission for Latin America and the Caribbean.
- Chen, W., & Zheng, M. (2021). Multi-objective optimization for pavement maintenance and rehabilitation decision-making: A critical review and future directions. *Automation in Construction*, 130, 23. <https://doi.org/10.1016/j.autcon.2021.103840>

- Donev, V., & Hoffmann, M. (2020). Optimisation of pavement maintenance and rehabilitation activities, timing and work zones for short survey sections and multiple distress types. *International Journal of Pavement Engineering*, 21(5), 583–607. <https://doi.org/10.1080/10298436.2018.1502433>
- 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), 1–9. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000738](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000738)
- García-Segura, T., Montalbán-Domingo, L., Llopis-Castelló, D., Sanz-Benlloch, A., & Pellicer, E. (2023). *Integration of deep learning techniques and sustainability-based concepts into an urban pavement management system*. 231(June). <https://doi.org/10.1016/j.eswa.2023.120851>
- Golroo, A., & Tighe, S. (2009). Use of soft computing applications to model pervious concrete pavement condition in cold climates. *Journal of Transportation Engineering*, 135(11), 791–800. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000052](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000052)
- Guo, F., Zhao, X., Gregory, J., & Kirchain, R. (2021). A weighted multi-output neural network model for the prediction of rigid pavement deterioration. *International Journal of Pavement Engineering*, 0(0), 1–13. <https://doi.org/10.1080/10298436.2020.1867854>
- 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). A comparison between three approaches for modelling deterioration of five pavement surfaces. *International Journal of Pavement Engineering*, 18(1), 26–35. <https://doi.org/10.1080/10298436.2015.1030744>
- Lethanh, N., Kaito, K., & Kobayashi, K. (2015). Infrastructure Deterioration Prediction with a Poisson Hidden Markov Model on Time Series Data. *Journal of Infrastructure Systems*, 21(3). [https://doi.org/10.1061/\(asce\)is.1943-555x.0000242](https://doi.org/10.1061/(asce)is.1943-555x.0000242)
- 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 (Switzerland)*, 12(22), 1–20. <https://doi.org/10.3390/su12229717>
- Meegoda, J. N., & Gao, S. (2014). Roughness progression model for asphalt pavements using long-term pavement performance data. *Journal of Transportation Engineering*, 140(8), 1–7. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000682](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000682)
- 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(June), 103336. <https://doi.org/10.1016/j.autcon.2020.103336>
- Pérez-Acebo, H., Linares-Unamunzaga, A., Rojí, E., & Gonzalo-Orden, H. (2020). IRI performance models for flexible pavements in two-lane roads until first maintenance and/or rehabilitation work. *Coatings*, 10(2). <https://doi.org/10.3390/coatings10020097>
- Ragnoli, A., De Blasiis, M. R., & Di Benedetto, A. (2018). Pavement distress detection methods: A review. *Infrastructures*, 3(4), 1–19.

<https://doi.org/10.3390/infrastructures3040058>

- Shtayat, A., Moridpour, S., Best, B., & Rumi, S. (2022). An Overview of Pavement Degradation Prediction Models. *Journal of Advanced Transportation*, 2022, 1–15. <https://doi.org/https://doi.org/10.1155/2022/7783588>
- Sollazzo, G., Fwa, T. F., & Bosurgi, G. (2017). An ANN model to correlate roughness and structural performance in asphalt pavements. *Construction and Building Materials*, 134, 684–693. <https://doi.org/10.1016/j.conbuildmat.2016.12.186>
- Soncim, S. P., de Oliveira, I. C. S., Santos, F. B., & Oliveira, C. A. de S. (2018). Development of probabilistic models for predicting roughness in asphalt pavement. *Road Materials and Pavement Design*, 19(6), 1448–1457. <https://doi.org/10.1080/14680629.2017.1304233>
- Tarawneh, B., & Nazzal, M. D. (2014). Optimization of resilient modulus prediction from FWD results using artificial neural network. *Periodica Polytechnica Civil Engineering*, 58(2), 143–154. <https://doi.org/10.3311/PPci.2201>
- Thomas, O., & Sobanjo, J. (2013). Comparison of Markov Chain and Semi-Markov Models for Crack Deterioration on Flexible Pavements. *Journal of Infrastructure Systems*, 19(2), 186–195. [https://doi.org/10.1061/\(asce\)is.1943-555x.0000112](https://doi.org/10.1061/(asce)is.1943-555x.0000112)
- Uddin, W. (2006). Pavement management systems. In Taylor & Francis Group (Ed.), *The Handbook of Highway Engineering*.

**Comunicación alineada con los
Objetivos de Desarrollo Sostenible**

