

TÉCNICAS DE APRENDIZAJE AUTOMÁTICO PARA LA PREDICCIÓN DE INTERVENCIONES DE MANTENIMIENTO EN INFRAESTRUCTURAS LINEALES DE CARRETERA

Francisco José Morales Sánchez

Ingeniería e infraestructura de los Transportes, Universidad de Sevilla, España.

Antonio Reyes Gutiérrez

Ingeniería e infraestructura de los Transportes, Universidad de Sevilla, España.

Noelia Caceres Sánchez

Ingeniería e infraestructura de los Transportes, Universidad de Sevilla, España.

Luis Miguel Romero Pérez

Ingeniería e infraestructura de los Transportes, Universidad de Sevilla, España.

Francisco García Benítez

Ingeniería e infraestructura de los Transportes, Universidad de Sevilla, España.

RESUMEN

Las técnicas de mantenimiento predictivo persiguen disminuir la aparición de fallos imprevistos, y la ejecución de las intervenciones correctivas necesarias que deben llevarse a cabo con anterioridad a la aparición de los fallos.

Esta comunicación presenta una metodología, que permite automatizar la predicción de alertas de mantenimiento en infraestructuras lineales de transporte, aplicada al caso de una red de carreteras. Combina información cuantitativa del estado del activo junto con datos de las intervenciones de mantenimiento operativos e históricos, haciendo uso de técnicas de analítica de datos y modelos de aprendizaje automático.

Una vez los modelos se encuentran entrenados, se infiere el estado del activo en el escenario futuro de interés, y las tareas de mantenimiento necesarias para evitar una degradación posterior o desajustes de las condiciones de seguridad y/o confortabilidad. La metodología genera una lista priorizada correspondiente a las alertas generadas por todos los activos de la infraestructura monitorizada.

La parte científica de esta comunicación presenta: i) el análisis de la información mínima necesaria para obtener predicciones de alertas, y de las intervenciones de mantenimiento más probables asociadas a ellas en redes de carreteras; ii) el diagrama de flujo esquemático del conjunto de herramientas desarrollado para predecir alertas de mantenimiento; iii) el procedimiento metodológico utilizado, para activar alertas y predecir las intervenciones más probables, necesario para resolver estas alertas; iv) la metodología para determinar la fiabilidad y el nivel de severidad de alertas frente a falsos positivos y negativos.

La parte empírica del artículo recoge la descripción y resultados de un caso piloto de red de carreteras.

Finalmente, se extraen conclusiones sobre el enfoque del procedimiento propuesto y la capacidad predictiva alcanzada.

1. INTRODUCCIÓN

El mantenimiento predictivo de las infraestructuras de transporte lineales ha despertado un interés considerable en las dos últimas décadas. La importancia de impulsar el desarrollo de herramientas de predicción fiables, a fin de maximizar la disponibilidad de las redes de carreteras y ferrocarriles, y optimizar los recursos dedicados a mantenerlas en servicio, es de suma importancia socioeconómica. Actualmente, desde la faceta gerencial, varios códigos profesionales de administración de activos lineales (e.g. Bentley Exor, Bentley Optram, HDM-4, INFOR EAM, PAVER, PMS Core) incluyen aplicaciones que brindan algún tipo de capacidades predictivas sobre alertas y operaciones de mantenimiento, que facilitan ciertos niveles de predicción; aunque se echa en falta mayores esfuerzos y avances hasta su completa automatización y universalización.

En el ámbito del desarrollo de las técnicas de predicción del estado de activos, se produjo un gran salto en los años 1940-60 con la introducción del concepto de fiabilidad y el uso de técnicas estadísticas y de optimización (Dekker, 1996), que dio lugar al cuerpo de conocimiento del *Mantenimiento Centrado en la Fiabilidad* (Moubray, 1998), una de las herramientas más utilizadas en la actualidad. Un segundo salto hacia delante aparece, en la década de los años 80, con la analítica de datos computacional, que permite inferir modelos de estimación de la evolución del estado de activos y componentes (e.g. inteligencia artificial, sistemas expertos). Esto da lugar a la estructuración en un novedoso corpus científico (e.g. aprendizaje automático: ML) entre los años 1980 y 2000 y su más reciente popularización (e.g. minería de datos) ha suscitado un gran interés por predecir el estado de las infraestructuras lineales de transporte con el fin de establecer programas de planificación de las intervenciones y tareas de mantenimiento, de acuerdo con los recursos disponibles y el mínimo impacto en el funcionamiento de la infraestructura.

La detección de alertas de mantenimiento se basa, por lo general, en la inspección del estado de los activos mediante la visualización/auscultación/medición de las características explicativas del activo involucrado. La evolución de estas características, estimadas de manera cuantitativa o cualitativa, utilizando técnicas de proyección (e.g. regresión) o cualitativas (e.g. experiencia), y la verificación cruzada con umbrales y límites (definidos por estándares técnicos prescritos por la administración/regulador de la infraestructura correspondiente), ha sido la principal herramienta para prever los posible fallos o deficiencias en el funcionamiento de los activos.

Estos umbrales se basan en el conocimiento acumulado adquirido durante un período prolongado de tiempo, en relación con la adecuación del estado de los activos analizados, y responden a una envolvente conservadora que garantiza la seguridad, integridad y correcto funcionamiento del activo como parte del sistema en el que se integra. Con el fin de mejorar la capacidad “predictiva” de este procedimiento, se han considerado nuevas y adicionales características explicativas, unitarias o combinadas, que se han ido progresivamente incorporando, durante el pasado, a la lista de índices a monitorizar y medir. Sin embargo, la gran diversidad de factores que afectan a un determinado activo, en relación con su estado, hace poco probable que se prevea el caso ideal en el que cualquier estado/condición pueda explicarse de manera integral utilizando un conjunto fijo de características medibles y, como consecuencia adicional, obtener una estimación fiable de la evolución de su integridad u operatividad. Esta falta de determinismo se solventa, parcialmente, con el conocimiento histórico recogido por el equipo de mantenimiento.

Durante décadas, la construcción de modelos deterministas o probabilísticos basados en características explicativas apriorísticas (i.e. modelos empíricos-mecanicistas) ha sido la tendencia más acusada (e.g. Lytton, 1987; NCHRP, 2004; AASHTO, 2008; Mubarak, 2010). En la actualidad, los desarrollos se han enfocado en sustituir esa forma de proceder por el modelado basado en datos, haciendo uso de técnicas de minería de datos y aprendizaje automático (e.g. Quinlan 1986; Schwartz 1993; TRB 1999; Dick et al.2003; Podofillini et al.2006; Iqbal 2010; Podder 2010; Witten et al.2011; Karlaftis et al.2015; Plati et al.2015), y apoyándose en la creciente disponibilidad de datos capturados de las actividades y campañas de auscultación/monitorizado. Estas técnicas inteligentes (i.e. automáticas y de minería) han promovido el concepto de aprender de los datos, facilitando la extracción de patrones y tendencias al “dejar que los datos hablen por sí mismos”. El uso de estas técnicas, complementadas con la información histórica contenida en el repositorio de órdenes de trabajo, permite una rápida mejora de las predicciones.

En el ámbito de las infraestructuras de carreteras, desde la década de los 90s, la tendencia se ha enfocado en la predicción de la evolución del estado de determinados componentes usando técnicas ML y analítica de datos; tal es el caso de la predicción de los índices asociados al pavimento, (Attoh-Okine, 1994; Bosurgi & Trifiro, 2005; Gong et al., 2018), o al estado global de éste (Eldin & Senouci, 1995; Salini et al., 2015; **Sollazzo et al.**, 2017). En relación con la estimación de las intervenciones de mantenimiento ha habido importantes avances (Hanna et al., 1993; Taha & Hanna, 1995; Alsugair & Al-Qudrah, 1998; Domitrovic et al., 2018; Roberts et al., 2021); referenciadas por diversas publicaciones sobre el estado del arte en esta temática (TRB, 1999; Flintsch & Chen, 2004; Ismail et al., 2009; Ceylan et al., 2014; Abambres & Ferreira; 2020; Karimzadeh & Shoghli, 2020).

Esta comunicación presenta un enfoque metodológico para la estimación y activación de alertas asociadas a activos de infraestructuras lineales de carreteras relativas a intervenciones de mantenimiento, sean correctivas o predictivas. Su objetivo final es disponer de un sistema de información basado en un sistema experto que respalda y automatiza la gestión de la infraestructura desde la auscultación hasta el mantenimiento utilizando un enfoque modular. Se basa en: i) un sistema de gestión de los datos asociados a las variables explicativas de los activos implicados; ii) un conjunto de herramientas de analítica de datos (i.e. cuantificación del estado de los activos, gestión de alertas) y un sistema de apoyo a la toma de decisiones que recibe los resultados de estas herramientas y optimiza las intervenciones de mantenimiento. Esta comunicación presenta avances en el marco metodológico y analítico, y se avala con resultados obtenidos en un caso piloto (Infralert, 2016, 2017; Morales et al, 2017, 2018, 2020; Reyes, 2018). Las alertas estimadas se evalúan, de acuerdo con la información que brinda el sistema de toma de decisiones, en base a la evolución del estado de los activos de interés, reflejado por sus variables explicativas (e.g. características físicas endógenas, variables exógenas), y la base de datos de intervenciones históricas. Los resultados inferidos proporcionan las alertas etiquetadas con un determinado nivel de severidad y una clasificación de todas las alertas en una lista jerárquica de intervenciones junto con sus probabilidades de incidencia. El objetivo final es facilitar la gestión de todas las intervenciones activas y previstas, optimizando las operaciones de mantenimiento.

2. INFORMACION RELEVANTE PARA EL PROCESO DE PREDICCIÓN

En el enfoque propuesto, las alertas se infieren correlacionando los valores estimados (proyectados) de las características explicativas (X_{i1}, \dots, X_{in}) del estado del activo (A_i), en un escenario futuro de interés para el mantenimiento, con la información almacenada en el repositorio histórico de mantenimiento (RHM). En este proceso están involucradas dos fuentes de datos principales diferentes: i) mediciones realizadas en la infraestructura en la que se incluyen los valores de las características relevantes; ii) datos de mantenimiento histórico que almacena, al menos: a) cada una de las intervenciones realizada (incluyendo información cronológica/tipológica); b) cuantificación/valoración de las variables de estado/explicativas previas a la intervención. Esto hace que la activación de alertas se base no solo en la comparativa de los valores estimados de las características explicativas con sus umbrales preestablecidos, sino también en el uso de la información no explícita oculta en estas fuentes de datos, lo que puede explicar la intervención necesaria realizada en casos pasados. Este repositorio también puede contener información registrada, con respecto a la evaluación subjetiva, del estado del activo inspeccionado por el equipo de mantenimiento previo a la intervención realizada (e.g. la evaluación subjetiva de cada característica explicativa individual del activo [SX_{i1}, \dots, SX_{in}], una característica explicativa combinada [CX_i] y/o una valoración global del estado del activo [G_i]).

Además, existen otras características (variables endógenas y exógenas) que afectan a la evolución del estado del activo. Éstas completan el conjunto de características explicativas a tener en cuenta en el enfoque de intervención predictiva (e.g. flujo de tráfico, categoría de la infraestructura).

3. PROCESO METODOLÓGICO

El marco general propuesto se esboza en la Figura 1 donde se muestran diferentes módulos (que incorporan técnicas, metodologías, algoritmos y modelos) y sus interacciones, entradas y salidas. El enfoque tiene como objetivo estimar y priorizar las alertas de mantenimiento y predecir las intervenciones necesarias. En particular, se consideran dos tipos de alertas en la metodología propuesta: i) las desencadenadas por la desviación de los indicadores asociados a la calidad/estado de un activo establecido por la normativa vigente (e.g. europea, administración/gestor de la infraestructura), y ii) los índices cuantitativos que se infieren al correlacionar la información registrada de intervenciones históricas.

El Módulo AM1 (*Pre-alerts base on limits*) se encarga de generar pre-alertas basadas en límites, desde el punto de vista de aquellas características que superan sus umbrales asociados, utilizando como datos de entrada los valores pronosticados de las características explicativas del activo. El objetivo de este módulo es comparar el valor de cada característica prevista con el umbral correspondiente (según los parámetros de diseño/calidad/seguridad) para cuantificar el estado del activo. Como resultados, se proporcionan las siguientes salidas: i) Pre-alertas (*Warnings*) que indican que una característica específica excede su umbral prescrito, y ii) niveles de severidad técnica (*Technical Severity Level TSL*) de las pre-alertas estimadas. El TSL es un valor objetivo que se utiliza para priorizar las pre-alertas (e.g. en función de un criterio de distancia entre el valor de las características y los umbrales). El módulo AM2 se encarga de predecir alertas basadas en órdenes de trabajo (WO), desde el punto de vista de requerir una acción de mantenimiento (Sí/No); también estima las operaciones de mantenimiento necesarias más probables. Para lograr esto, el módulo incorpora dos submódulos funcionales diferentes. El primero (AM21) está específicamente dedicado a activar alertas atendiendo a la necesidad de mantenimiento (Sí/No) y su correspondiente nivel de severidad técnica global (*Global Technical Severity Level GTSL*) cuantificada en términos de todas las características previstas consideradas en su conjunto. El GTSL se infiere en función de todos los TSL de las características explicativas correspondientes $X = \{X_1, X_2, \dots, X_n\}$, previamente normalizadas (referidas a la misma escala) y ponderadas por valores preestablecidos α_i a cada característica individual X_i (sujeto a restricciones de ponderación unitaria $\alpha_1 + \alpha_2 + \dots + \alpha_n = 1$). Aquí, las alertas son activadas por el estimador contenido en el primer bloque (*Alert Estimator*), que ha sido previamente entrenado con la información adecuada mediante un procesamiento de aprendizaje automático. El segundo submódulo (*Maintenance interventions AM22*) tiene como cometido la estimación de la tipología de intervenciones de mantenimiento más probables (ver Sección 3.2).

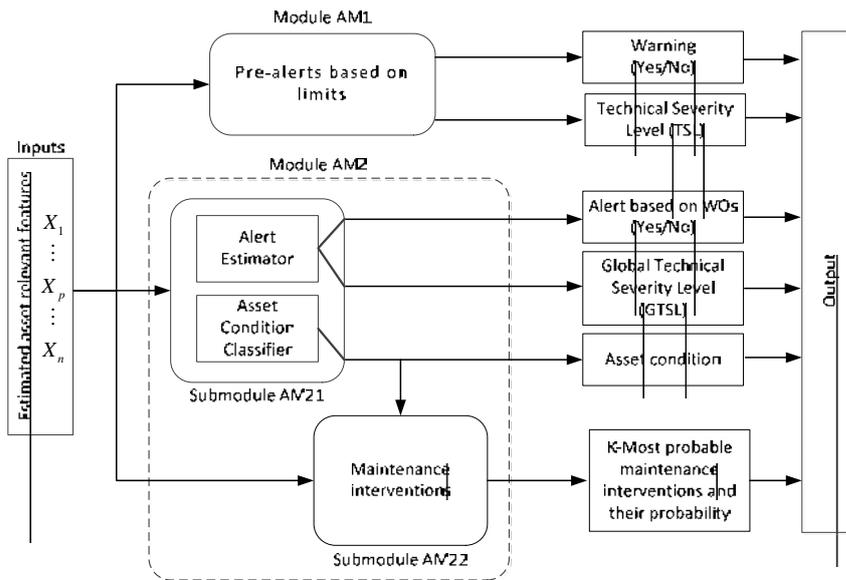


Figura 1. Marco metodológico

3.1 Proceso de aprendizaje y predicción de alertas

La metodología de aprendizaje, representado en la Figura 2, consiste en una clasificación automática basado en variables binarias (1-0: Sí/No). Se ha considerado un conjunto de cuatro modelos de clasificación binaria automática (i.e. árbol de decisión DT, red neuronal artificial ANN, vecinos más próximos KNN-K, máquina de vector soporte SVM).

De entre los cuatro modelos que se ensayan queda seleccionado el que proporciona las mejores capacidades predictivas. El submódulo AM21 también proporciona una salida opcional utilizando un segundo bloque (*Subjective asset condition* en la Figura 2), que "aprende" del conocimiento del RHM, con el propósito final de predecir una evaluación subjetiva del estado del activo (a partir del conjunto de características pronosticadas).

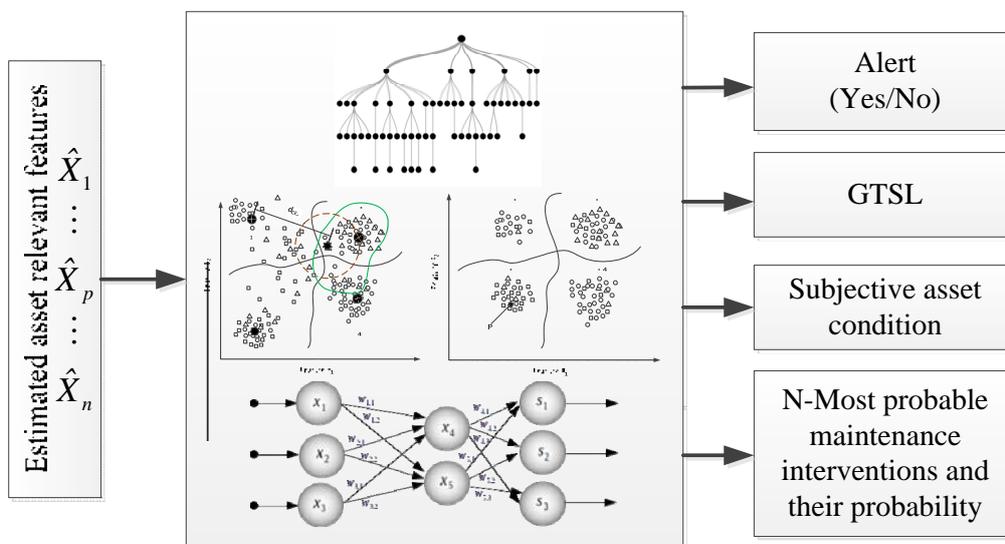


Figura 2. Esquema del proceso de aprendizaje y predicción

3.2 Proceso de predicción de tipo de intervenciones de mantenimiento

El segundo submódulo (AM22), Figura 1, tiene como objetivo determinar el conjunto de las k-intervenciones de mantenimiento más probables que deben realizarse, así como sus correspondientes probabilidades de incidencia, mediante un procedimiento de aprendizaje basado en datos de la base histórica de intervenciones. Para estimar el tipo de intervención más probable, en un activo específico, de acuerdo con el conocimiento contenido en la base histórica, se debe iniciar un proceso correlacionando los valores estimados de las características explicativas relevantes (\hat{X}) y el estado subjetivo pronosticado ($S\hat{X}, C\hat{X}, \hat{G}$) proporcionado por el submódulo AM21; este proceso hace uso de muestras de activos similares reportadas en el repositorio histórico; las predicciones del tipo de intervención se basan en un esquema de aprendizaje automático no supervisado que utiliza técnicas de agrupamiento y k-vecinos. Como resultado, el módulo AM2 proporciona: i) alertas activadas que identifican aquellos activos donde se requiere mantenimiento; ii) nivel de severidad técnica global (GTSL) de esos activos; iii) K-intervenciones previstas más probables asociadas a cada activo y alerta activada; y iv) probabilidades de incidencia de las intervenciones más probables.

4. REGLAS DE AUTOAPRENDIZAJE AUTOMÁTICO

Dado que el enfoque se basa en técnicas de aprendizaje automático, se encuentran definidas un conjunto de reglas de autoaprendizaje para mejorar las capacidades predictivas. Esta sección se centra en la metodología utilizada para discernir las predicciones de “falsos positivos” y “falsos negativos”, de acuerdo con las siguientes reglas:

- Un falso positivo surge cuando una estimación (derivada de los modelos) indica que se ha alcanzado un estado determinado, cuando no es así. Este caso se considera como una "falsa alarma", valorándose como caso positivo erróneo.
- Un falso negativo aparece cuando una estimación indica que no se ha detectado ninguna alerta (i.e. el estado previsto del activo es correcto), mientras que posteriormente tuvo que realizarse una intervención de mantenimiento correctivo; por lo que el pronóstico de fallos era erróneo.

La Figura 3 esboza una descripción del modo de proceder que debe seguir el equipo de mantenimiento cuando se comunica una alerta activada; incluyendo la información necesaria a registrar en la base de datos. Esto puede tener una causa "correctiva" o "predictiva". El caso de intervención preventiva no se tiene en cuenta en este documento, ya que sigue un plan predefinido y con reglas específicas. De acuerdo con esto, todos los datos registrados tienen asociado un campo de marca cronológica para identificar el instante en que se tomó cualquier decisión/acción (cuando la alerta se considera como “no atendida”, “atendida” o “intervenida”).

Los casos falsos pueden surgir cuando las estimaciones incorrectas se deben a: i) predicción incorrecta de una característica, ii) predicción incorrecta para solicitar mantenimiento (Sí/No), iii) predicción incorrecta del tipo de operación de mantenimiento requerido. En los siguientes párrafos se presenta una descripción gráfica de los casos.

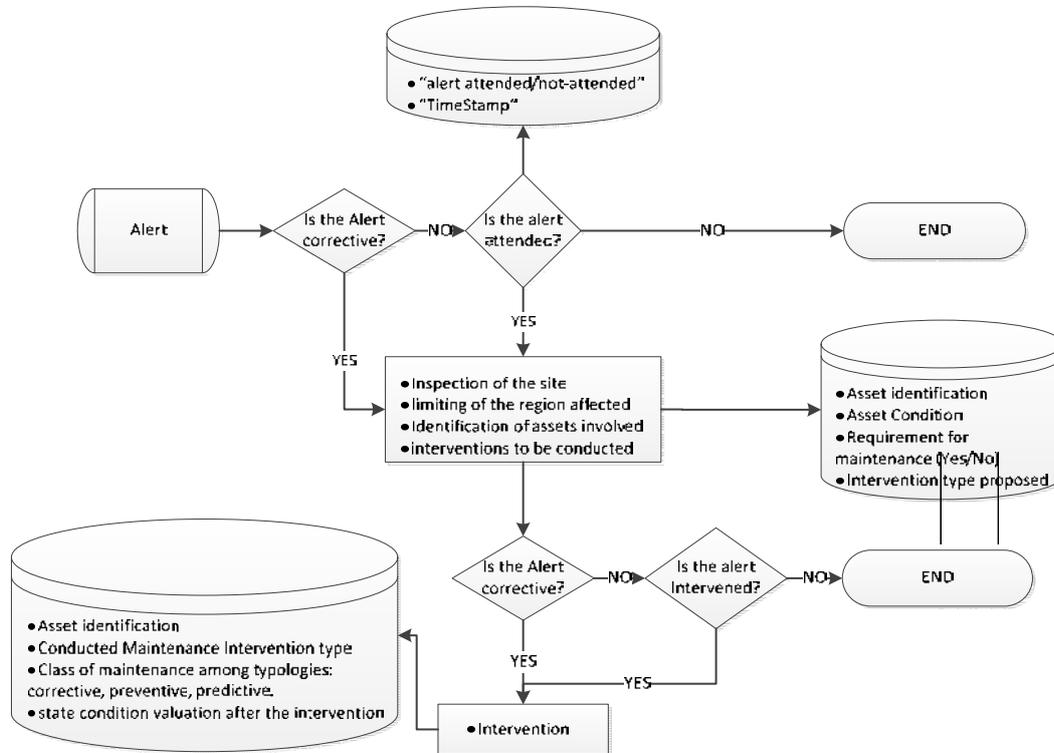


Figura 3. Diagrama de flujo del procedimiento de verificación y activación de alertas

4.1 Predicción incorrecta de una característica

Se analizan por separado dos posibles casos, falso positivo y falso negativo:

- i) Falso positivo. Tiene lugar cuando la alerta se activa por el valor esperado de una característica (individual, combinada, o multiplicidad de características), debido a la predicción incorrecta de los valores de las características. El procedimiento de alerta activada, puesto en marcha por el Equipo Gestor del Mantenimiento (EGM), finaliza con la evaluación de todos los activos implicados en la alerta y con el registro de información sobre el estado de dichos activos. La nueva información enriquecerá la base de datos (RHM) correspondiente al estado de los activos involucrados. El procedimiento de aprendizaje automático aprenderá de la información enriquecida de la base de datos, mejorando la tasa de éxito de acuerdo con la calidad de la información capturada en más ejecuciones de predicción.
- ii) Falso negativo. Surge cuando el valor esperado de las características (única, combinada o multiplicidad de características) está por debajo del valor que tendrán y también cae por debajo del umbral TSL. En este caso, el procedimiento de activación-de-alerta no se activa y no se predice ninguna alerta. Eventualmente, puede aparecer una advertencia correctiva y activarse el procedimiento de activación-de-alertas, que registrará la información identificada en la Figura 3.

4.2 Predicción incorrecta de incidencia de mantenimiento

Al igual que en el caso anterior, se analizan los casos de falso positivo y falso negativo:

- i) Falso positivo. Esto ocurre cuando el submódulo AM21 predice la necesidad de mantenimiento y se activa una alerta. Este caso sigue un patrón similar al caso (i) de la sección 4.1. El procedimiento de ML se mejorará de acuerdo con el enriquecimiento de la base de datos.
- ii) Falso negativo. Esto ocurre cuando el submódulo AM21 no detecta la necesidad de mantenimiento y no se activa ninguna alerta. Este caso sigue un patrón similar al caso (ii) de la sección 4.1.

4.3 Predicción incorrecta del tipo de mantenimiento

En este caso, se supone que la solicitud de mantenimiento se estima correctamente como positiva, de lo contrario el procedimiento vuelve a la sección 4.2. Solo es posible la predicción general de "tipo falso de mantenimiento ":

- Tipo falso. La alerta se ha activado debido a una solicitud de mantenimiento (submódulo AM21) y se proporciona un tipo de intervención de mantenimiento estimado. El EGM activa el procedimiento de *Alerta-activada* y el equipo de intervención de mantenimiento evalúa los activos implicados. El equipo detecta que el tipo de mantenimiento estimado no corresponde al tipo previsto, y que se ha realizado una predicción incorrecta del tipo de mantenimiento por parte del submódulo AM22. Se continúa el procedimiento de *Alerta-activada*, actuando de acuerdo con las acciones especificadas. La información capturada por este procedimiento (que refleja todos los presentados en la Figura 3) se registra en la base de datos RHM, lo que enriquece la información almacenada. Las estimaciones posteriores de los algoritmos ML se verán beneficiadas por la nueva base de datos enriquecida.

5. CASO PILOTO

Para el caso piloto se ha elegido una subred de carreteras de la zona centro de Portugal, con una extensión de 620 km, gestionada por *Infraestructuras de Portugal*. La información disponible consta de dos bases de datos: 1) la primera corresponde a los resultados de diferentes campañas de medición en las que se obtienen características representativas del estado de la vía; 2) la segunda recopila las intervenciones históricas de mantenimiento realizadas en la red en las últimas cuatro décadas. Al correlacionar ambas bases de datos se infieren las entradas y los objetivos para los modelos de aprendizaje automático. Sin embargo, los datos registrados se han filtrado previamente para extraer la información relevante que utiliza el sistema antes de activar toda la metodología predictiva de mantenimiento.

Con la información disponible para el caso piloto, los modelos se han implementado computacionalmente usando las técnicas de árboles de decisión (DT), k-vecinos más próximos (KNN), máquinas de vectores soporte (SVM) y redes neuronales artificiales

(ANN). Para comprobar la precisión de esos modelos, el conjunto de datos de los últimos años se ha dividido en tres subconjuntos: a) datos de entrenamiento y testeo, b) datos para predicción, c) datos de las operaciones de mantenimiento reales llevadas a cabo en los tramos usados para la predicción. El primer subconjunto se ha utilizado como base de datos para detectar la técnica de aprendizaje automática más adaptada a la naturaleza de los datos e información disponibles, manteniendo ésta fuera del conjunto de datos utilizados para predicción. El segundo subconjunto de información se ha focalizado en los datos existentes de las variables explicativas de los tramos (no incluidos en el conjunto de entrenamiento y testeo), para los que se conocía las operaciones de mantenimiento que se habían llevado a cabo (pero que no era información disponible utilizada para las predicciones) correspondiendo a un subconjunto de tramos de la red piloto. El tercer subconjunto corresponde a los datos de las operaciones de mantenimiento reales, entre los años 2012 a 2016, llevadas a cabo en los tramos del subconjunto anterior (b) con la finalidad de contrastación de la bondad/divergencia de las predicciones estimadas. La evaluación del rendimiento de los modelos se realizó mediante el uso de una matriz de confusión, basada en el recuento de los registros de prueba predichos correcta e incorrectamente. En esas matrices aparecen el tipo de mantenimiento real (M) y el predicho a tendiendo a los tipos de intervenciones, recogidos en la Tabla 1. La clase T0 está asociada a no-alerta, y el resto de las clases pertenecen a diferentes alertas de mantenimiento.

M	Alerta	Descripción
T0	No	No se requiere mantenimiento
T1	Si	No actuar
T2	Si	Microaglomerado, Recubrimiento-tratamiento de superficie
T3	Si	Capa fina mezcla caliente de asfalto (grosor ≤ 5 cm)
T3.1	Si	Fresado y extendido de capa fina de mezcla en caliente de asfalto (grosor ≥ 5 cm)
T4	Si	Capa gruesa de mezcla en caliente de asfalto (grosor > 5 cm) combinada con o sin fresado

Tabla 1- Descripción de los tipos de mantenimiento

Las curvas de aprendizaje de los modelos seleccionados se muestran en la Figura 4, donde se representan un total de cuatro gráficos; el eje horizontal (x) representa diferentes tamaños de conjuntos de entrenamiento, el eje vertical (y) el error obtenido. Las dos líneas gruesas representan el valor promedio de los conjuntos de entrenamiento y prueba; las líneas finas representan los percentiles 20 y 80 de los conjuntos de entrenamiento y prueba, proporcionando una cuantificación de la variación de las predicciones.

A medida que aumenta el tamaño del conjunto de entrenamiento, las líneas convergen hacia una asíntota que representa la cantidad de error irreducible en los datos. El error de la predicción del conjunto de entrenamiento en el modelo de k-vecinos más cercanos es siempre del 0%. Esto se debe al hecho de que la predicción de un registro se calcula a partir de una vecindad en la que se incluye el registro. El modelo DT presenta el error más bajo. Los modelos SVM, ANN y KNN arrojaron resultados similares; ninguno de ellos redujo el error promedio del conjunto de prueba por debajo del 5%. Solo el modelo DT alcanzó un error promedio por debajo del 5% utilizando un tamaño de conjunto de entrenamiento más elevado (375 registros).

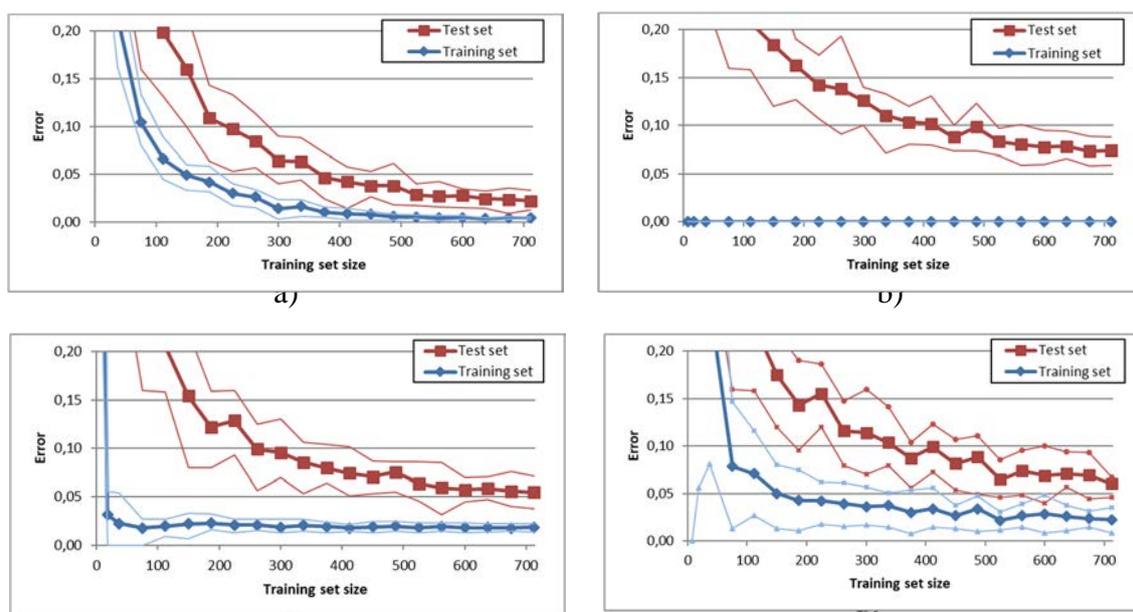


Figura 4. Curvas de aprendizaje: a) árbol de decisión, b) modelos de k-vecinos más cercanos, c) máquina de vectores soporte y d) modelos de redes neuronales artificiales.

Es importante subrayar que los resultados corresponden a un caso de datos numerosos. En la práctica real, la base de datos de mantenimiento histórico proporciona un conjunto de muestra válido limitado debido a múltiples causas: i) el número de intervenciones que se registran con descripción detallada no suele ser alto; ii) la información almacenada carece de coherencia cronológica (las intervenciones reales no se describen con el mismo rigor a lo largo del tiempo); iii) se cuantifican insuficientes características físicas explicativas. Por ello es importante que los modelos seleccionados logren un error de conjunto de prueba promedio bajo, con un número limitado de registros. En este caso, el modelo DT resulta ser la mejor opción.

La Figura 5 muestra la matriz de confusión para el modelo DT donde las columnas corresponden a la clase conocida (clase especificada por la orden de trabajo) y las filas a las predicciones inferidas por el modelo (clase de salida).

Los elementos diagonales muestran el número de clasificaciones correctas alcanzadas para cada clase; los elementos fuera de la diagonal muestran los errores cometidos por las predicciones del modelo. Cada celda contiene la misma información como porcentaje del tamaño total del conjunto de prueba. En la última fila y columna, estos gráficos presentan las medidas de rendimiento derivadas de la matriz de confusión: la precisión (ACC), recuperación o tasa de verdaderos positivos (TPR) y precisión o valor predictivo positivo (PPV), que se muestran en color verde; así como los respectivos índices complementarios: tasa de error (ERR), tasa de falsos negativos (FNR) y tasa de descubrimiento de falsos (FDR), mostrados en color rojo.

		Confusion matrix for: DT					PPV/FDR			
Output Class	T0 (no alert)	106 35.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%	0.0%	
	T1	0 0.0%	14 4.7%	3 1.0%	2 0.7%	0 0.0%	0 0.0%	73.7%	26.3%	
	T2	0 0.0%	0 0.0%	14 4.7%	0 0.0%	1 0.3%	0 0.0%	93.3%	6.7%	
	T3	0 0.0%	0 0.0%	0 0.0%	52 17.3%	5 1.7%	0 0.0%	91.2%	8.8%	
	T3.1	0 0.0%	0 0.0%	1 0.3%	1 0.3%	54 18.0%	1 0.3%	94.7%	5.3%	
	T4	0 0.0%	0 0.0%	0 0.0%	1 0.3%	5 1.7%	40 13.3%	87.0%	13.0%	
	TPR/FNR	100% 0.0%	100% 0.0%	77.8% 22.2%	92.9% 7.1%	83.1% 16.9%	97.6% 2.4%	93.3% 6.7%		
		T0 (no alert)	T1	T2	T3	T3.1	T4	ACC/ERR		
		Target Class								

Figura 5. Matriz de Confusión (modelo DT).

5.1 Resultados

En la Figura 6 se extrae una selección de los resultados obtenidos tras aplicar las metodologías presentadas al conjunto de tramos de carreteras no incluidas en el proceso de elección y aprendizaje del modelo de predicción. La predicción del estado general de cada tramo se cuantifica numéricamente a través de la variable explicativa global (GTSL) y cualitativamente por el color de la celda. El penúltimo conjunto de columnas (*Estimated alert per year*) identifica los tramos en los que se predice (aconseja) la necesidad de realizar intervenciones de mantenimiento. El último conjunto de columnas (*Intervention by year*) señala los tramos en los que realmente se llevaron a cabo labores de mantenimiento. Los tipos de intervenciones de mantenimiento más recomendados, propuesto por el algoritmo de predicción, se identifican por el color asignado al tramo de carretera en el mapa de la Figura 7.

Road id			Global Technical Severity Level (GTSL) by year					Estimated alert by year					Intervention by year			
idSection	netClass	Section	GTSL 2012	GTSL 2013	GTSL 2014	GTSL 2015	GTSL 2016	2012	2013	2014	2015	2016	2012	2013	2014	2015
218174	2521	0	0,358	0,353	0,285	0,307	0,398	--	--	--	--	--		Maintened		
218174	2521	0,5	0,367	0,645	0,287	0,32	0,342	--	--	--	--	--		Maintened		
218174	2521	1	0,596	0,688	0,318	0,436	0,429	--	Alert	--	--	--		Maintened		
218174	2521	1,5	0,737	0,653	0,448	0,656	0,601	Alert	Alert	--	--	--		Maintened		
218174	2521	2	0,477	0,475	0,279	0,37	0,445	--	--	--	--	--		Maintened		
218174	2521	2,5	1,144	1,052	0,187	0,212	0,227	Alert	Alert	--	--	--		Maintened		
218174	2521	3	1,078	1,247	0,204	0,228	0,231	Alert	Alert	--	--	--		Maintened		
218174	2521	3,5	0,801	1,051	0,268	0,346	0,407	Alert	Alert	--	--	--		Maintened		
218174	2521	4	0,563	0,757	0,194	0,21	0,231	Alert	Alert	--	--	--		Maintened		
218174	2521	4,5	0,338	0,585	0,157	0,174	0,187	--	Alert	--	--	--		Maintened		
218174	2521	5	0,498	0,532	0,195	0,219	0,293	--	--	--	--	--		Maintened		
218174	2521	5,5	0,969	0,56	0,169	0,188	0,2	Alert	--	--	--	--		Maintened		
218174	2521	6	0,505	0,328	0,219	0,233	0,332	--	--	--	--	--		Maintened		
218174	2521	6,5	0,377	0,288	0,208	0,224	0,232	--	--	--	--	--		Maintened		
218174	2521	7	0,779	0,642	0,248	0,263	0,277	Alert	Alert	--	--	--		Maintened		
218174	2521	7,5	0,481	0,925	0,718	1,044	1,056	--	Alert	Alert	Alert	Alert				
218174	2521	8	0,313	0,979	0,804	1,024	0,862	--	Alert	Alert	Alert	Alert				

Figura 6. Resultados de GTSL y Alertas del tramo 218174, segmentado en subsecciones de 500 metros, predicciones para el período de tiempo 2012-2016.

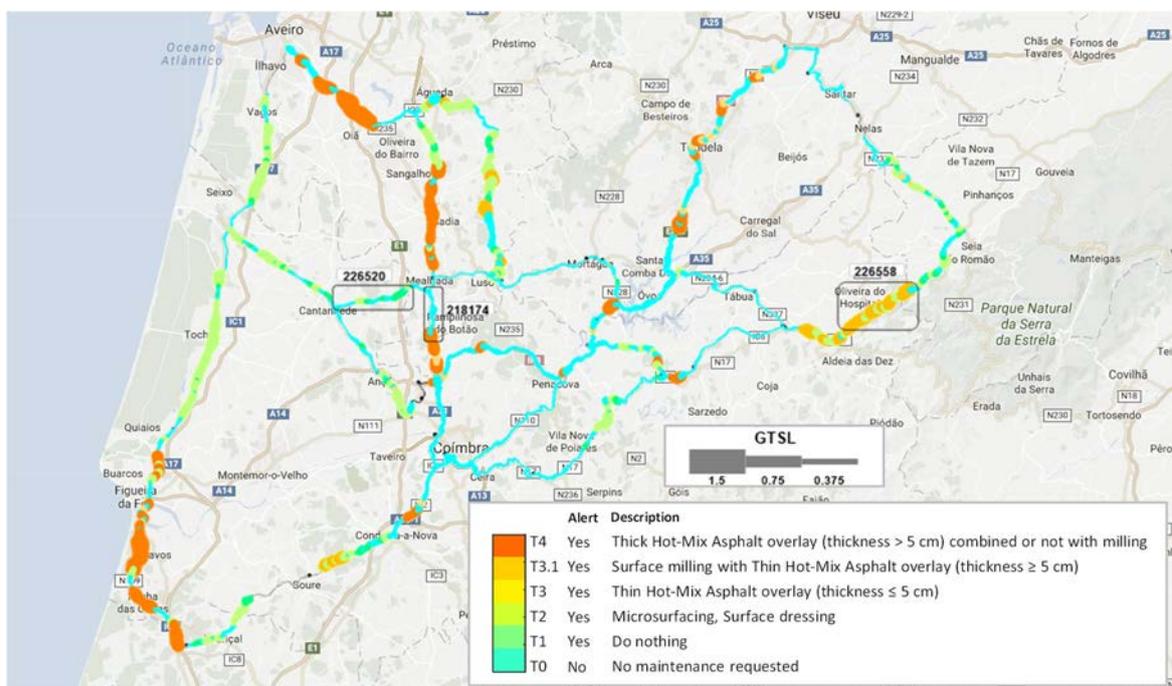


Figura 7. Estimación de la tipología de operaciones de mantenimiento en la red del caso piloto.

6. CONCLUSIONES

Se ha desarrollado una metodología, basada en un conjunto de varias técnicas, de aprendizaje automático supervisado y no supervisado para la predicción de alertas y de las operaciones de mantenimiento requeridas más probables. La aplicación práctica se ha llevado a cabo en una red de carreteras con una dilatada base de datos históricos. Los resultados obtenidos se fundamentan en la elección óptima de los mejores modelos predictivos basados en a) órdenes de trabajo de intervenciones contenidas en la base de datos histórica, b) características de los activos, c) y auscultaciones de medición.

Los principales resultados alcanzados son: i) el tipo de intervención estimado para cada tramo de carretera y la probabilidad de incidencia, ii) una lista ordenada de alertas estimadas según el nivel de gravedad técnica. Cada conjunto de predicciones se refiere a escenarios identificados por fecha. Los resultados evidencian que el marco metodológico proporciona buenas capacidades predictivas.

El trabajo presentado es parte de la generación de una herramienta inteligente de apoyo a la decisión con el objetivo de inferir planes de mantenimiento, basados en la generación de pronósticos de alerta y la selección óptima de operaciones en cuanto a las intervenciones más críticas a realizar. Estas últimas constituyen la información más relevante para avanzar en un sistema de ayuda a la planificación del mantenimiento de infraestructuras lineales de transporte a nivel operativo, táctico y estratégico, bajo un marco de sistema experto.

Las metodologías y resultados aquí presentados distan de ser exhaustivos y concluyentes, y se encuentran abiertos en varias líneas de investigación paralelas: a) sensibilidad a la calidad de la descripción de la intervención en el repositorio histórico con respecto a las fechas de las intervenciones, b) importancia de la descripción detallada/vaga del estado del activo previo a la intervención y, por último y de mayor relevancia a nivel de fiabilidad, c) el enriquecimiento de las bases de datos bajo el esquema procedural de verificación y activación de alertas.

AGRADECIMIENTOS

Esta investigación ha recibido financiación del Programa de Investigación e Innovación Horizonte 2020 de la Unión Europea (acuerdo de subvención n ° 636496). Algunos de los autores agradecen al Ministerio de Economía y Competitividad de España (MINECO) la subvención parcial concedida en el marco del programa nacional de I + D + i (TRA2015-65503) y del Programa Torres Quevedo (PTQ-13-06428). El contenido refleja únicamente la opinión de los autores y se declara que la UE y el MINECO no son responsables del uso que pueda hacerse de la información contenida en él.

Los desarrollos llevados a cabo en esta investigación no habrían sido posible sin la participación de la entidad *Infraestruturas de Portugal*, y la estrecha colaboración de sus técnicos João Morgado, Emanuel Duarte, y Teresa Martins.

REFERENCIAS

- AASHTO. (2008). Mechanistic-Empirical Pavement Design Guide. A manual of Practice. American MEPDG-1. Association of State Highway and Transportation Officials.
- ABAMBRES M., FERREIRA A. (2020). Application of ANN in Pavement Engineering: State-of-Art. TechRxiv. Preprint. <https://doi.org/10.36227/techrxiv.12645038.v1>

ALSUGAIR A.M., AL-QUDRAH A. A. (1998). Artificial neural network approach for pavement maintenance. *Journal of Computing in Civil Engineering*, 12(4), 249-255.

AMERICAN MEPDG-1. Association of State Highway and Transportation Officials.

ATTOH-OKINE N.O. (1994). Predicting roughness progression in flexible pavements using artificial neural networks. In *Proceedings of the Third International Conference on Managing Pavements*. San Antonio, Texas. Conference Proceedings, 1, 55–62.

BENTLEY EXOR. <http://www.bentley.com/en-US/Products/Exor/>.

BENTLEY OPTRAM. <http://www.bentley.com/Optram>.

BOSURGI G., TRIFIRO F. (2005). A model based on artificial neural networks and genetic algorithms for pavement maintenance management. *International Journal of Pavement Engineering*, 6(3), 201–209.

CEYLAN H., BAYRAK M.B., GOPALAKRISHNAN K. (2014). Neural networks applications in pavement engineering: A recent survey. *International Journal of Pavement Research and Technology*, 7(6), 434–444.

DEKKER R. (1996). Applications of maintenance optimization models: a review and analysis, *Reliability Engineering & System Safety*, 51(3), 229-240.

DICK C.T., BARKAN C.P.L., CHAPMAN E.R., STEHLY, M.P. (2003). Multivariate statistical model for predicting occurrence and location of broken rails. *J. Transportation Research Board*, 1825, 48-55.

DOMITROVIC J., DRAGOVAN H., RUKAVINA T., DIMTER S. (2018). Application of an artificial neural network in pavement management system. *Technical Gazette* 25, Suppl. 2, 466-473.

ELDIN N.N., SENOUCI A.B. (1995). A pavement condition-rating model using backpropagation neural networks. *Microcomputers in Civil Engineering*, 10(6), 433-441.

FLINTSCH G.W., CHEN C. (2004). Soft computing applications in infrastructure management. *Journal of Infrastructure Systems*, 10(4), 157-166.

GONG H., SUN Y., MEI Z., HUANG B. (2018). Improving accuracy of rutting prediction for mechanistic-empirical pavement design guide with deep neural networks. *Construction and Building Materials*, 190, 710–718.

HANNA P. B., HANNA A. S., PAPAGIANNAKIS T. A. (1993). Knowledge-based advisory system for flexible pavement routine maintenance. *Canadian Journal of Civil Engineering*, 20, 154-163.

HDM-4. <http://www.hdmglobal.com/>.

INFOR EAM. <http://www.infor.com/solutions/eam>.

INFRALERT (2016). INFRALERT: Linear Infrastructure Efficiency Improvement by Automated Learning and Optimised Predictive Maintenance Techniques. H2020 Programme. European Commission. Research Directorate (Grant agreement No 636496). [http: infralert.eu](http://infralert.eu)

INFRALERT (2017). INFRALERT: Deliverable D4.3. Methodologies and procedures for inferring three-dimensional alert-severity-intervention pattern space. Supervised and unsupervised approaches. [http: infralert.eu](http://infralert.eu)

IQBAL, Z. (2010). A Study of AI techniques for Railheads, Vegetation, Switches & Crossings. Master Thesis, E38440. Högskolan Dalarna.

ISMAIL N., ISMAIL A., ATIQ R. (2009). An overview of expert systems in pavement management. *European Journal of Scientific Research*, 30(1), 99-111.

KARIMZADEH A., SHOGHLI O. (2020). Predictive Analytics for Roadway Maintenance: A Review of Current Models, Challenges, and Opportunities. *Civil Engineering Journal*, 6(3), 602-625.

KARLAFTIS A.G., BADR A. (2015). Predicting asphalt pavement crack initiation following rehabilitation treatments. *Transportation Research C*, 55, 510-517.

LYTTON, R. (1987). Concept of Pavement Performance Prediction and Modelling. *Proceedings 2nd North American Conference on Managing Pavement*, Toronto, Canada.

MORALES, F.J.; REYES, A.; CACERES, N.; ROMERO, L. M.; BENITEZ, F.G.; MORGADO, J.; DUARTE, E.; MARTINS, T. (2017). Historical maintenance relevant information roadmap for a self-learning maintenance prediction procedural approach. *International Conference BestInfra 2017. IOP Conf. Ser.: Mater. Sci. Eng.* 236, 012107.

MORALES F.J., REYES A., CACERES N., ROMERO L.M., BENITEZ, F. G. (2018). Automatic Prediction of Maintenance Intervention Types in Roads using Machine Learning and Historical Records. *Transportation Research Record*, 2672, 44, 43-54.

MORALES F.J., REYES A., CACERES N., ROMERO L.M., BENITEZ, F. G., MORGADO J., DUARTE E.A. (2020). Machine learning methodology to predict alerts and maintenance interventions in roads. *Roads Materials and Pavement Design*. DOI: 10.1080/14680629.2020.1753098

MOUBRAY J. (1998). *Introduction to reliability-centered-maintenance*. USA: TWI Press Inc.

MUBARAKI M. (2010). Predicting deterioration for the Saudi Arabia Urban Road Network. PhD thesis, University of Nottingham.

NCHRP (2004). *Guide for Mechanistic–Empirical Design of New and Rehabilitated Pavement Structures*. Final Report. National Cooperative Highway Research Program. TRB.

PAVER. <http://www.paver.colostate.edu/>.

PLATI C., GEORGIU P, PAPAVASILIOU V. (2015). Simulating pavement structural condition using artificial neural networks. *Structure and Infrastructure Engineering*, 12(9), 1127-1136.

PMS CORE. <https://www.heller-ig.de/index.php?id=171>.

PODDER T. (2010). Analysis & study of AI techniques for automatic condition monitoring of railway track infrastructure. Master Thesis, E3845D. Högskolan Dalarna.

PODOFILLINI L., ZIO E., VATN J. (2006). Risk-informed optimisation of railway tracks inspection and maintenance procedures. *Reliability Engineering and System Safety* 91(1), 20–35.

QUINLAN J.R. (1986). Induction of decision trees. *Machine Learning* 1(1),81–106.

REYES, A.; MORALES, F.J.; CACERES, N.; ROMERO, L. M.; BENITEZ, F.G.; MORGADO, J.; DUARTE, E.; MARTINS, T. (2018). Automatic prediction of maintenance intervention types in transport linear infrastructures using machine learning. *Transport Research Arena TRA2018*, Paper ID 10392, Vienna, Austria, 16-19 April 2018.

ROBERTS R., INZERILLO L. DI MINO G. (2021). Exploiting Data Analytics and Deep Learning System to Support Pavement Maintenance Decisions. *Applied Sciences*, 11, 2458.

SALINI R., XU B, LENNGRE C.A. (2015). Application of artificial intelligence for optimization in pavement management. *International Journal of Engineering and Technology Innovation*, 5(3), 189-197.

SCHWARTZ C.W. (1993). Infrastructure condition forecasting using neural networks. *Proceedings: Infrastructure Planning and Management*, Denver, CO.

SOLLAZZO G., FWA T., BOSURGI G. (2017). An ANN model to correlate roughness and structural performance in asphalt pavements. *Construction and Building Materials*, 134, 684-693.

TAHA M.A., HANNA A.S. (1995). Evolutionary neural network model for the selection of pavement maintenance strategy. *Transportation Research Record*, 1497, 70-76.

TRB A2K05(3). (1999). Use of artificial neural networks in geomechanical and pavement systems. *Transportation Research Circular E-C012*, Transportation Research Board, NRC. Retrieved from <http://onlinepubs.trb.org/onlinepubs/circulars/ec012.pdf>.

WITTEN I.H., FRANK E., HALL M.A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann Publishers.