

Detección automatizada de grietas en pavimentos flexibles en vías urbanas para asegurar el tiempo de vida útil

Automated crack detection in flexible pavements on urban roads to ensure service life

Recibido: 21 de febrero de 2026 | Revisado: 17 de mayo de 2026 | Aceptado: 28 de mayo de 2026

Edwar Garcia Arevalo¹

¹ Escuela Universitaria de Posgrado – Universidad Nacional Federico Villarreal. Lima, Perú

Correo: edwargarciaarevalo@gmail.com
<https://orcid.org/0000-0002-6827-2411>

<https://doi.org/10.62428/rcvp2026512106>

Abstract

The objective of this study was to use artificial intelligence-based image analysis to detect cracks in flexible pavements within the urban area of the La Banda de Shilcayo district (Tarapoto). This is a non-experimental study with a descriptive-comparative design. The method involved collecting photographic images, which were then processed using the Python programming language and the YOLO algorithm to a model was developed that allows for the identification and quantification in millimeters of cracks in the pavement through image visualization. These cracks were categorized into analysis units according to the PCI method, thereby not only providing reliable and rapid information but also reducing the costs and time required for technical staff sent to the field to gather this same information. The results obtained have been compared with the information collected in the field, yielding an average error margin of 1 cm to 2 cm difference from the information provided by the developed model, specifically regarding the length of the cracks. Using the PCI method, it has been possible to determine the condition of the pavement and identify which areas require routine maintenance, recurring maintenance, or periodic maintenance. Furthermore, the method has demonstrated a reduction in manual labor and time spent obtaining real-time information on road conditions, which has resulted in economic benefits for road administrators. However, beyond economic benefits, the importance of keeping this information up-to-date lies in enabling timely interventions that facilitate the services provided to citizens.

Keywords: Artificial intelligence, flexible pavement, operation and maintenance, pavement condition index, cracks.

Resumen

La investigación tuvo como objetivo determinar mediante imágenes con el uso de la inteligencia artificial la detección de grietas en pavimentos flexibles dentro de la zona urbana del distrito de La Banda de Shilcayo (Tarapoto). La investigación es de tipo no experimental, con un diseño descriptivo – comparativo, el método utilizado fue la recolección de imágenes fotográficas, para que posteriormente con la ayuda del lenguaje de programación Python y el algoritmo YOLO, se obtenga un modelo que permita con la visualización de imágenes la identificación y cuantificación en mm de las grietas en el pavimento, las cuales fueron separadas en unidades de análisis de acuerdo al método PCI, haciendo que de esta forma no solo se obtengan información confiable y rápida, sino se reduzcan costos y tiempos del personal técnico enviado a campo que se emplea para obtener esta misma información. Los resultados obtenidos han sido comparados con la información que se ha levantado en campo, arrojando un nivel de error en promedio de 1 cm a 2 cm de diferencia con la información que nos arroja el modelo desarrollado, esto con respecto a la longitud de las grietas. Mediante el método PCI se ha podido determinar cuál es el estado del pavimento, en que zonas se necesita intervención con mantenimiento rutinario, mantenimiento recurrente o mantenimiento periódico, así mismo se ha demostrado la reducción de trabajo humano y tiempo empleado en obtener información real del estado de las vías, lo cual se ha traducido en beneficios económicos para los administradores de las vías, pero más que beneficios económicos la importancia de tener actualizada esta información se traduce en intervenciones oportunas que facilitan los servicios que brindan hacia los ciudadanos.

Palabras clave: Inteligencia artificial, pavimento flexible, operación y mantenimiento, índice de condición del pavimento, grietas.



Este artículo es de acceso abierto distribuido bajo los términos y condiciones de la licencia Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International

Introducción

La infraestructura de transporte, particularmente las redes de vías de transporte terrestre, se ha desarrollado rápidamente para satisfacer las demandas de transporte y conectar centros económicos, de acuerdo con Koch et al. (2023) indican que, si bien la construcción es una condición necesaria, las condiciones suficientes para que cualquier vía de transporte sirva de manera segura a los usuarios del tráfico incluyen la gestión, la operación y el mantenimiento. Con la construcción de ciudades inteligentes entrando en una nueva fase, es necesario ampliar los requisitos de las vías tradicionales para proporcionar servicios eficientes de operación y mantenimiento (O&M). Los sistemas de infraestructura vial existentes no cumplen con los requisitos funcionales inteligentes de O&M ya que no incorporan un método unificado para organizar e integrar datos espacio-temporales del ciclo de vida de la vía (Yu et al., 2021).

Una red de transporte, como activo nacional valioso, desempeña un papel importante en la economía de cada país. Este activo se deteriora con el tiempo y requiere un mantenimiento oportuno para mantener un nivel adecuado de servicio. De lo contrario, impone costos masivos a las agencias viales y a los usuarios. El objetivo principal de un Sistema de Gestión de Pavimentos (SGP) es proporcionar un plan óptimo para determinar qué sección del pavimento debe repararse, cómo y cuándo (Maeda et al., 2018). Las redes viales urbanas (URN) son las arterias y la infraestructura central de las ciudades modernas, considerando que desempeñan un papel crucial en las actividades diarias y las respuestas a emergencias. Sin embargo, las URN están inevitablemente expuestas a desastres naturales y provocados por el hombre que no solo dañan directamente la propia red, sino que también afectan indirecta y gravemente el comportamiento/costo de los viajes, la economía social y el bienestar de la comunidad (Boayke et al., 2022).

Ouma y Hahn (2016) indican que la inadecuada operación y mantenimiento generan daños en las vías de transporte, lo que provoca accidentes de tráfico lamentables para los usuarios, una menor eficiencia operativa en las vías y, en última instancia, un aumento de los costos de reparación de las vías de transporte debido a una degradación severa e irreversible. En el mismo sentido Zhengji et al. (2024) manifiestan que la detección de daños del pavimento es vital en el mantenimiento y la seguridad de los viajes por vías terrestres, considerando que daña la estructura del pavimento, reduce la velocidad del tráfico y acorta el tiempo de operación. Los daños severos en el pavimento también debilitan la capacidad de carga dentro de la plataforma de las vías, causando el colapso del pavimento, problemas de seguridad vial y pérdidas económicas.

El deterioro del pavimento avanza rápidamente con un aumento en la carga de tráfico y la vida útil, de acuerdo con Zhu et al. (2022) por lo tanto, las agencias de transporte deben evaluar constantemente las condiciones del pavimento y tomar decisiones apropiadas de planificación de mantenimiento. La infraestructura de transporte está sujeta a un alto volumen de tráfico, daños y deterioro de componentes, así como a eventos de desastre durante el período de servicio. El monitoreo y la gestión de la infraestructura de transporte es siempre una tarea crítica, de acuerdo a lo indicado por Chang et al (2024). El desarrollo y la operación de un Sistema de Gestión de Pavimentos Urbanos (UPMS) enfrentan numerosas barreras en el sector público. Brasil presenta una deficiencia de documentos de referencia en el ámbito urbano, lo que desalienta la implementación de mejores procedimientos en las agencias gubernamentales de planificación y operación. Las agencias municipales dependen de los conceptos utilizados por las agencias viales, incluso contradiciendo sus características de tráfico y red vial (Hvala et al., 2022).

Así mismo Paredes y Rodríguez (2011) indican que, en el Ecuador, y en general en los países en vías de desarrollo, la falta de una adecuada Gestión de conservación vial, ha producido que las redes viales tengan un ciclo fatal, que incluye la construcción, su abandono, el deterioro excesivo, colapso y su reconstrucción. Este ciclo fatal, afecta directamente a los usuarios, los cuales ven reflejarse los daños de la vía en el aumento de los costos de operación vehicular, de la misma manera, los recursos de las Instituciones Administradoras de las redes viales, las cuales de no actuar en el momento justo y con actividades necesarias, se ven obligadas a futuro a realizar mayores gastos para mantener las vías en niveles de servicio aceptables, llegando a los extremos de realizar una rehabilitación o reconstrucción dependiendo el grado de deterioro.

El Ministerio de Economía y Finanzas (MEF, 2021), ente rector de la inversión en el Perú indica que existen diversos factores que afectan la sostenibilidad de las inversiones, como, por ejemplo, los desastres naturales, la

disponibilidad de recursos, los conflictos sociales, la administración de la inversión, los cambios tecnológicos, los efectos del cambio climático, entre otros. Dentro de estos un aspecto particularmente importante al evaluar la sostenibilidad es analizar la capacidad de la entidad titular de los activos o responsable de la provisión de los servicios en la fase de Funcionamiento, para cubrir los costos de mantenimiento de la inversión ejecutada.

Guerrieri y Parla (2022), desarrollaron un método automatizado robusto, de bajo costo y en tiempo real para detectar y medir los diversos tipos de deterioro de pavimentos flexibles y rígidos, utilizando para esto la detección, clasificación y medición del deterioro basándose en las aplicaciones del enfoque de aprendizaje profundo y el algoritmo YOLOv3. Primero se creó un conjunto de datos para la detección de daños en pavimentos de carreteras con aproximadamente 9,150 imágenes y 15,585 cuadros delimitadores de daños en pavimentos flexibles y rígidos, y luego se utilizó en la fase de entrenamiento de redes neuronales.

Así mismo, de acuerdo con Sun et al. (2024) emplean 04 modelos de detección de objetos con You Only Look Once (YOLOv5), (YOLOv7), redes neuronales convolucionales de región más rápida (Faster R-CNN) con laboratorio de grupo de geometría visual (VGG) y Faster R-CNN con red residual (ResNet) para lograr el reconocimiento inteligente de defectos en las marcas viales mediante aprendizaje profundo. Cada modelo se sometió a 1000 épocas de entrenamiento y utilizó 2,000 imágenes de inspección de carreteras anotadas. Mediante el aumento de datos, la optimización de módulos y el rediseño de anclajes, estos modelos pueden localizar las marcas viales y clasificar sus defectos. La precisión y eficiencia del modelo se evaluó mediante la precisión media promedio (mAP) y los fotogramas por segundo. Además, se introdujo indicadores de evaluación centrados en los tipos de defectos para facilitar la selección de modelos con alta aplicabilidad en la detección de marcas. Entre estos modelos, el Faster R-CNN optimizado, con VGG como red troncal, presenta una mAP del 93.96% y puede detectar más de 28 imágenes por segundo, lo que cumple con los requisitos de ingeniería.

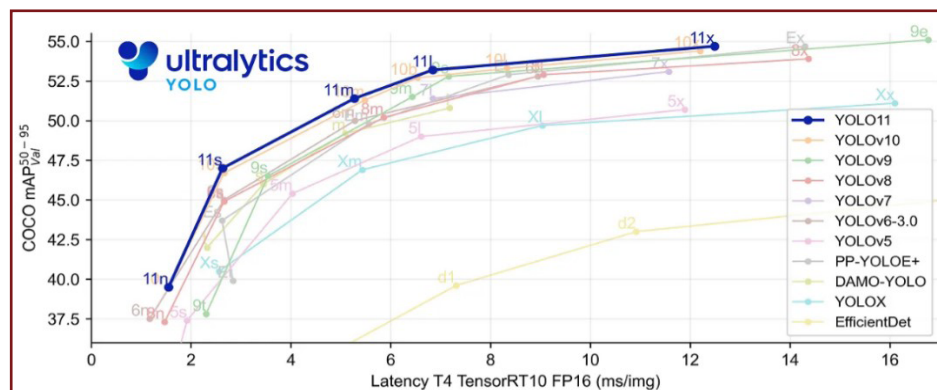
Es por esa razón que con la presente investigación se desarrolló una propuesta tecnológica y de bajo costo a base de imágenes e inteligencia artificial que permita conocer en tiempo real el estado de las vías urbanas con pavimento flexible dentro del distrito de La Banda de Shilcayo, para acciones de operación y mantenimiento.

En ese contexto, la investigación tuvo como objetivo determinar mediante imágenes con el uso de la inteligencia artificial la detección de grietas en pavimentos flexibles dentro de la zona urbana del distrito de La Banda de Shilcayo (Tarapoto).

Materiales y métodos

Para la investigación se ha utilizado el algoritmo YOLO versión 11 pues de acuerdo con la empresa Ultralytics desarrolladora que esta inteligencia artificial de visión por computadoras este modelo es superior a los anteriores, presenta mayor rapidez, precisión y eficiencia, pues admite toda gama de tareas de visión artificial, posee la característica de tener una extracción mejorada de información y una implementación fluida entre plataformas, para poder comparar y hacer demostrable su eficacia, se presenta el análisis desarrollado por la empresa Ultralytics donde se compara YOLO versión 11 con sus versiones anteriores en la Figura 1.

Figura 1
Comparación de YOLO versión 11 con las versiones anteriores




Se recolectó una base de datos basada en imágenes de las grietas que se presentan en los pavimentos flexibles, los cuales son necesarios para alimentar al modelo, razón por la cual se seleccionó una calle distinta en las que se realizó el estudio de las grietas, por lo cual se instaló una cámara a mitad de cuadra en el Jr. San Martín cuadra N°01 del distrito de Tarapoto, este jirón y especialmente esta cuadra de todas las calles del distrito de Tarapoto es una de las que presentaba mayor cantidad de grietas en su estructura y lo que se buscaba era obtener imágenes de ese tipo de fisuras que sirven como data para alimentar el modelo. Las imágenes fotográficas fueron tomadas en distintos momentos del día, en promedio una foto cada hora en el lapso de 6:00 a.m. a 6:00 p.m. (12 horas), en un promedio de 2.5 meses, es decir un aproximado de 866 imágenes.

Posteriormente se procedió con el etiquetado de las mismas, este etiquetado corresponde a definir dentro de la imagen fotográfica la grieta que muestra, para que la plataforma vaya reconociendo y diferenciando que es una grieta del resto de objetos presentes en las fotografías. Este trabajo se desarrolló a través de la plataforma ROBOFLOW, la cual es una plataforma integral de visión computacional que permite construir, entrenar y desplegar modelos de IA personalizados con flujos de trabajo optimizados e infraestructura escalable, el proceso de etiquetado de las imágenes se muestra a continuación en la Figura 2.

Figura 2

Etiquetado de grietas del pavimento con la plataforma ROBOFLOW



Finalmente, a través del lenguaje de programación Python se procedió a realizar el análisis de las imágenes que habían pasado por el proceso de etiquetado en ROBOFLOW, que obtuvo una base de datos de grietas o dataset cuyo tamaño fue la siguiente manera: 756 imágenes fueron de entrenamiento, 73 imágenes fueron de validación y 37 imágenes fueron de prueba, imágenes necesarias a ser utilizadas por el algoritmo YOLO (You Only Look Once) versión 11. En este algoritmo se realizó 40 iteraciones de todas las imágenes, es decir separo por paquetes de imágenes las que habían sido etiquetadas con grietas y las analizó 40 veces, de las cuales se extrajo el mejor modelo de trabajo llamado “BEST” en formato “PT”, que sirvió como modelo base y herramienta de detección de grietas en imágenes de pavimentos que nunca antes ha visto.

La investigación se desarrolló en la zona de la muestra del estudio, el cual fue determinado por la población del estudio, las cuales son las vías urbanas con pavimento flexible ubicadas en el distrito de La Banda de Shilcayo, Provincia de San Martín y Departamento de San Martín que hacen un total de 134 cuadras pavimentadas con pavimento flexible administradas por la Municipalidad Distrital de la Banda de Shilcayo (MDBSH). La muestra de la investigación son las calles comprendidas en los proyectos de inversión con CUI N°2653467 denominado: Reparación de plataforma; en el (la) Jirón Perú C-01 a la C-02, Santa María C-01, Yurimaguas C-02 a la C-03, Miraflores C-01 y Amazonas C-01 a la C-02, Distrito de la Banda de Shilcayo, Provincia San Martín, Departamento San Martín y el proyecto con CUI N° 2455330 denominado: Mejoramiento de la infraestructura vial urbana de la Av. Cerro Escalera C_01 a C_04; Av. Ahuashiyacu C_05 a la C_12; Jr. La Campiña C_01; Jr. Floresta C_01 y C_02; Jr. Silvestre C_01 y C_02 y Jr. Naturaleza C_01; en la localidad de la Banda del Distrito de la Banda de Shilcayo - Provincia de San Martín - Departamento de San Martín. con un total de 18 cuadras, haciendo un porcentaje entre ambos proyectos de 18.57% del total de calles como muestra con respecto al total de la población.

La razón por la que se ha tomado en consideración esta muestra es que ambos proyectos fueron ejecutados por la MDBSH el año 2024, haciendo que estén dentro del periodo de vida útil en el cual deben funcionar adecuadamente, considerando el que son 10 años el horizonte de evaluación de los proyectos de la tipología de pistas y veredas.

Se realizó la búsqueda en la plataforma consulta amigable del MEF para identificar el porcentaje de recursos destinados a la O y M en vías urbanas en el distrito de La Banda de Shilcayo, la cual no refleja gastos de recursos invertidos en este tipo de actividades, lo que refleja la poca importancia que se le da al tema de mantenimiento.

De acuerdo a lo señalado líneas arriba, se identifican que la fase de operación y mantenimiento en las vías de transporte urbanas, ya sea una vía afirmada o asfaltada es de vital importancia para asegurar el tiempo de vida útil de los activos y la provisión óptima del servicio, por lo tanto las entidades encargadas de su administración que en el caso del Perú son los gobiernos locales (municipalidades distritales y provinciales) deben estar en constante monitoreo para identificar posibles fallas en algunos tramos o sectores, para prevenir el colapso del servicio, así como destinar los recursos necesarios para la O y M.

Se procedió a recolectar las fotografías en las cuadras de los proyectos a analizar con una cámara de celular; de acuerdo al método PCI, donde para cada unidad de análisis existe un promedio de $230 \pm 93 \text{ m}^2$ en el caso de pavimentos flexibles, es decir que se tiene que tener un área de estudio mínima de 137 m^2 y un área máxima de 323 m^2 , se procedió la toma de fotografías en áreas de 140 m^2 en promedio, es decir 7 ml de ancho por 20 ml de largo, a una altura de 3ml cada imagen, tal como se muestra en las Figuras 3 y 4 que se presenta a continuación:

Figura 3

Etiquetado de puntos rojos como área limitante dentro de la imagen a analizar por el modelo en el proyecto con CUI N°2653467



Figura 4

Etiquetado de puntos rojos como área limitante dentro de la imagen a analizar por el modelo en el proyecto con CUI N°2455330



Por cada imagen recolectada de la muestra se elaboró un archivo de Excel, y se procedió a indicar las coordenadas de cada uno de los vértices de las imágenes, las cuales fueron representadas con puntos rojos previamente identificados en cada una de las imágenes tomadas en campo. Luego de obtener toda la información, se procedió a procesarla en gabinete de acuerdo a los parámetros del método PCI para trabajar unidades de análisis, las cuales son las que entraron a estudio y permitieron conocer el estado del pavimento en esa determinada zona. Finalmente, con el lenguaje Python a través de códigos de programación insertando el modelo “BEST”, se procedió a realizar

el análisis de cada uno de las imágenes, que para el caso del proyecto con CUI N°2653467 son 20 imágenes y en el proyecto con CUI N°2455330 son 38 imágenes.

Resultados

La presente investigación determinó que para el proyecto con CUI N° 2653467 donde se analizaron 20 imágenes los resultados fueron los siguientes: De las 20 imágenes analizadas, 10 de ellas se identificaron grietas dentro de la superficie del pavimento flexible, las cual se muestran a continuación:

Figura 5

Imagen con grietas en el pavimento Jr. Perú Cdra N°01 – Unidad de análisis 01



Nota. Esta imagen corresponde al Jr. Perú cuadra N°01 – Unidad de análisis 01, el modelo ha detectado 01 grieta en el pavimento con una longitud de 0.35 ml respectivamente.

Figura 6

Imagen con grietas en el pavimento Jr. Perú Cdra N°01 – Unidad de análisis 03



Nota. La imagen corresponde al Jr. Perú cuadra N°01 – Unidad de análisis 03, el modelo ha detectado 02 grietas en el pavimento con una longitud de 0.21 ml y 0.97 ml respectivamente, haciendo un valor entre las dos de 1.18 ml de grietas con el modelo.

Figura 7

Imagen con grietas en el pavimento Jr. Perú Cdra N°01 – Unidad de análisis 04



Nota. Jr. Perú cuadra N°01 – Unidad de análisis 04, el modelo ha detectado 02 grietas en el pavimento con una longitud de 0.20 ml y 1.61 ml respectivamente, haciendo un valor entre las dos de 1.81 ml de grietas con el modelo.

Figura 8


Imagen con grietas en el pavimento Jr. Perú Cdra N°01 – Unidad de análisis 05



Nota. Esta imagen corresponde al Jr. Perú cuadra N°01 – Unidad de análisis 05, el modelo ha detectado 01 grieta en el pavimento en una longitud de 0.62 ml respectivamente.

Figura 9


Imagen con grietas en el pavimento Jr. Perú Cdra N°01 – Unidad de análisis 06



Nota. Esta imagen corresponde al Jr. Perú cuadra N°01 – Unidad de análisis 06, el modelo ha detectado 01 grieta en el pavimento en una longitud de 0.22 ml respectivamente.

Figura 10


Imagen con grietas en el pavimento Jr. Perú Cdra N°02 – Unidad de análisis 10



Nota. Esta imagen corresponde al del Jr. Perú cuadra N°02 – Unidad de análisis 10, el modelo ha detectado 01 grieta en el pavimento en una longitud de 0.47 ml respectivamente.

Figura 11


Imagen con grietas en el pavimento Jr. Santa María Cdra N°01 – Unidad de análisis 12



Nota. Esta imagen corresponde al Jr. Santa María cuadra N°01 – Unidad de análisis 12, el modelo ha detectado 01 grieta en el pavimento en una longitud de 0.31 ml respectivamente.

Figura 12


Imagen con grietas en el pavimento Jr. Santa María Cdra N°01 – Unidad de análisis 13



Nota. Esta imagen corresponde al Jr. Santa María cuadra N°01 – Unidad de análisis 13, el modelo ha detectado 02 grietas, que lo unifico como una sola grieta en el pavimento, haciendo un valor entre las dos de 6.12 ml respectivamente.

Figura 13

Imagen con grietas en el pavimento Jr. Santa María Cdra N°01 – Unidad de análisis 14



Nota. Esta imagen corresponde al Jr. Santa María cuadra N°01 – Unidad de análisis 14, el modelo ha detectado 02 grietas en el pavimento en una longitud de 1.09 ml y 1.40 ml respectivamente, haciendo un valor entre las dos de 2.49 ml de grietas con el modelo.

Figura 14

Imagen con grietas en el pavimento Jr. Amazonas Cdra N°01 – Unidad de análisis 15



Nota. Esta imagen corresponde al Jr. Amazonas cuadra N°01 – Unidad de análisis 15, el modelo ha detectado 03 grietas en el pavimento en una longitud de 0.29 ml, 0.30 ml y 0.23 ml respectivamente, haciendo un valor entre las tres de 0.82 ml de grietas con el modelo.

Para las 10 imágenes restantes del proyecto con CUI N° 2653467, no se detectaron grietas por parte del modelo, esa afirmación es concordante de acuerdo con la inspección visual realizada en campo, donde tampoco se identificó grietas, haciendo que de esta manera la información que arroja el modelo no varíe de lo que existe las vías analizadas.

Por su parte en las 38 imágenes del proyecto con CUI N° 2455330 no se detectaron grietas por parte del modelo, lo cual es concordante con el reconocimiento visual desarrollado en campo, ambos proyectos analizados están ubicados dentro del distrito de la Banda de Shilcayo, con condiciones de temperatura y humedad similares, puesto que la distancia que existe entre uno y otro proyecto es de 1 km aproximadamente, la ejecución física se desarrolló en el año 2024 para ambos proyectos, existen dos condiciones identificadas las cuales podrían ser las razones por el cual no se encontró grietas en un proyecto y si en el otro, la primera que en el proyecto con CUI N°

2653467 fue ejecutada por administración directa, y en proyecto con CUI N° 2455330 por contrata, así mismo el primero de los proyectos esta frente a la plaza del distrito, presentando un mayor porcentaje de transitabilidad, el segundo proyecto si bien esta en una zona con un tránsito considerable, existe momento en que este no es muy alto, lo cual hace que el desgaste del pavimento sea menor y más lento. En la siguiente imagen se muestra la unidad de análisis 01 del proyecto con CUI N° 2455330.

Figura 15

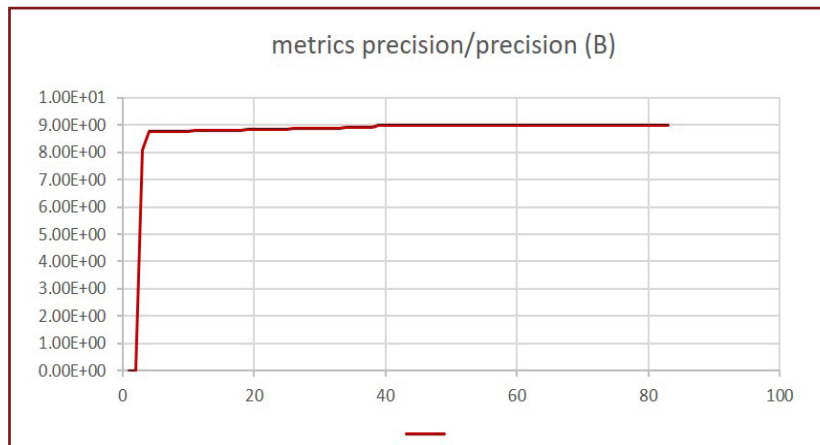
Imagen sin grietas en el pavimento Jr. Ahuashiyacu Cdra N°01 – Unidad de análisis 01



Para medir la confiabilidad de los resultados de la investigación, se desarrollaron las métricas como las de precisión/Precision, Recall, mAP@50, mAP@50-95, las cuales se muestra a continuación:

Figura 16

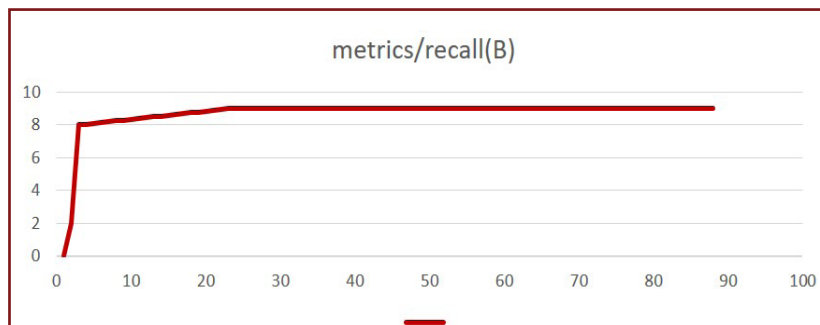
Imagen de la métrica Precisión/Precisión



Crece desde el punto 0 hasta el 80% de manera vertical, en adelante mantiene un rendimiento estable lo cual asegura la confiabilidad de los resultados, pues indica que de todas las veces que el modelo a identificado una grieta el 90% ha sido verdad.

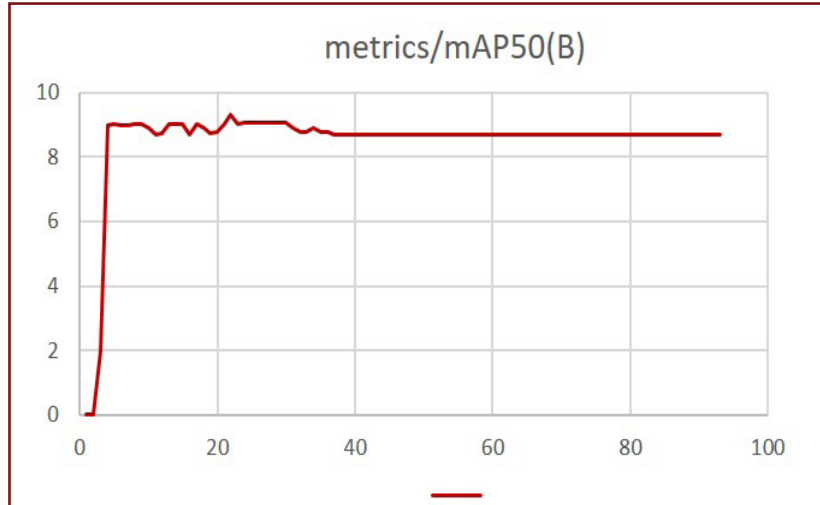
Figura 17

Imagen de la métrica Recall



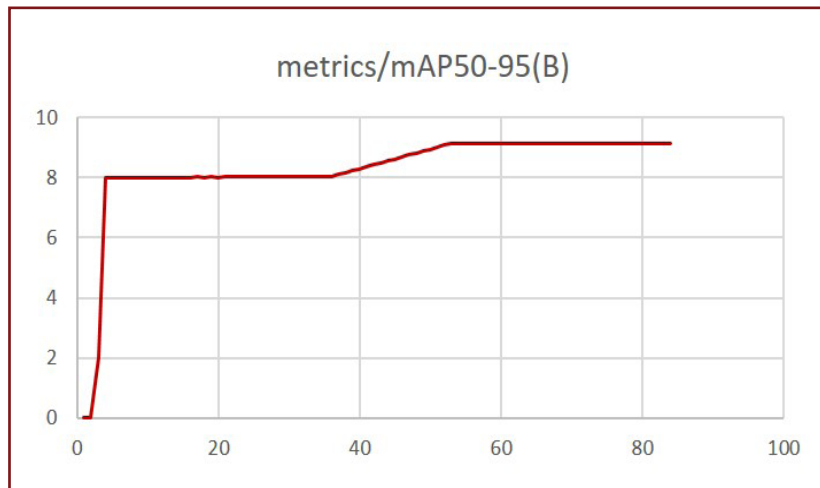
La métrica de recall indica que el modelo aprende rápidamente, y pasa de 0 a 80% muy rápidamente, con fluctuaciones muy leves dentro de los valores de 5 a 25, como se observa se mantiene estable desde del punto 25 con un valor de 90%, indicando que, de 10 grietas realmente verdaderas, detecta correctamente 9.

Figura 18
Imagen de la métrica mAP50



La métrica mAP50 igualmente en sintonía con las métricas anteriores demuestra un aprendizaje rápido del modelo, presentando fluctuaciones entre los puntos 10 al 38, luego se estabiliza y presenta una precisión de 87%, indicando que las detecciones consideradas fáciles han sido detectadas en ese porcentaje.

Figura 19
Imagen de la métrica mAP50-95



La métrica mAP50-95 presenta un aprendizaje rápido del modelo, así como fluctuaciones entre los puntos 35 al 55, luego presenta una estabilidad que llega hasta el 91%, lo cual indica el porcentaje de detección del modelo ante diferentes niveles de dificultad.

Con todos estos resultados obtenidos, se desarrolló el análisis del estado situacional de la condición del pavimento a través del método PCI, solo para el proyecto con CUI N° 2653467, considerando que fue en este proyecto donde el modelo identificó grietas en el pavimento, no obstante para tener un estado real de las cuadradas se tuvieron que incluir para este proyecto las unidades de análisis que presentaron grietas en el pavimento como las que no, tal como se muestra a continuación en la Tabla 1.

Tabla 1

Resumen de resultados de las unidades de análisis estudiadas del proyecto con CUI N°2653467

Unidad de muestra	Prog. inicial (km)	Prog. final (km)	Área (m2)	Max v.d.	(PCI) Calculado	Clasificación Pavimento	Intervención de rango (PCI)
M - 01	Km 0+000	Km 0+020	140	22.18	77.82	Muy bueno	Mantenimiento
M - 02	Km 0+020	Km 0+040	140	0	100	Excelente	Mantenimiento
M - 03	Km 0+040	Km 0+060	140	16.62	83.38	Muy bueno	Mantenimiento
M - 04	Km 0+060	Km 0+080	140	19.62	80.38	Muy bueno	Mantenimiento
M - 05	Km 0+080	Km 0+100	140	17.62	82.34	Muy bueno	Mantenimiento
M - 06	Km 0+100	Km 0+120	140	15.52	84.48	Excelente	Mantenimiento
M - 07	Km 0+120	Km 0+140	140	0	100	Excelente	Mantenimiento
M - 08	Km 0+140	Km 0+160	140	0	100	Excelente	Mantenimiento
M - 09	Km 0+160	Km 0+180	140	0	100	Excelente	Mantenimiento
M - 10	Km 0+180	Km 0+200	140	16.88	83.12	Muy bueno	Mantenimiento
M - 11	Km 0+200	Km 0+220	140	0	100	Excelente	Mantenimiento
M - 12	Km 0+220	Km 0+240	140	15.96	84.04	Excelente	Mantenimiento
M - 13	Km 0+240	Km 0+260	140	36.41	63.59	Bueno	Mantenimiento
M - 14	Km 0+260	Km 0+280	140	27.2	72.8	Muy bueno	Mantenimiento
M - 15	Km 0+280	Km 0+300	140	21.53	78.47	Muy bueno	Mantenimiento
M - 16	Km 0+300	Km 0+320	140	0	100	Excelente	Mantenimiento
M - 17	Km 0+320	Km 0+340	140	0	100	Excelente	Mantenimiento
M - 18	Km 0+340	Km 0+360	140	0	100	Excelente	Mantenimiento
M - 19	Km 0+360	Km 0+380	140	0	100	Excelente	Mantenimiento
M - 20	Km 0+380	Km 0+400	140	0	100	Excelente	Mantenimiento

Con la cuantificación de grietas desarrollada por el modelo de forma automática, a través de los formatos del método PCI, se ha logrado obtener por cada unidad de análisis de los jirones en estudio, la condición actual en la que se encuentran, obteniendo el PCI calculado que determinada la clasificación de cada unidad de análisis del pavimento que va desde excelente para las áreas analizadas con valor PCI igual a 100, hasta bueno para las áreas analizadas con valores PCI entre 70 a 55, proponiendo de acuerdo a estos valores el rango de intervención que se debe realizar que va desde los mantenimiento hasta las rehabilitaciones.

Discusión

La obtención de la información de grietas en el pavimento flexible de los jirones analizados es muy importante, porque permite determinar sin ir a campo la longitud y la cantidad de grietas encontradas en cada unidad de análisis, considerando que en la actualidad estas tareas se realizan con frecuencia mediante métodos de inspección tradicionales y manuales, lo que requiere horas de trabajo sustanciales para lograr una aproximación básica del daño de la vía. Además, la identificación visual de los defectos en las vías incurre en costos notables y es inherentemente propensa a errores humanos (Abu et al., 2025). Es por esa razón que existe una necesidad crucial de sistemas automatizados que puedan mejorar la detección y cuantificación de defectos en el pavimento (Alkhedher et al., 2025).

La inversión monetaria que se debería haber desarrollado contratando personal de campo para obtener esta información, que para el proyecto con CUI N°2653467 se requirió 04 personal técnico en campo por un lapso de 04 horas, haciendo un total de 16 horas labores, y para el proyecto con CUI N° 2455330, 04 técnicos de campo por un lapso de 05 horas, haciendo un total de 20 horas, al multiplicarlo por el precio de 01 hora hombre de trabajo para un operario establecido por la cámara peruana de la construcción (CAPECO) que tiene el costo de S/ 87.30 (Ochenta y siete con 30/100 soles), finalmente para procesar la información en gabinete se necesita en promedio 04 horas de un personal técnico, lo cual nos da un valor de S/ 3,492.00 (Tres mil cuatrocientos noventa y dos con 00/100 soles).

Si se compara esta inversión en personal técnico de campo, con la inversión necesaria para poner en practica

esta visión por computadora, tenemos el costo de los equipos electrónicos como cámara para tomar las imágenes con un costo de S/ 600.00 soles, así como tiempo de recorrido para cada unidad de análisis que son 20 ml de largo por 7 ml de ancho, aproximadamente 5 minutos por cada unidad. Ahora si se quiere implementar este método para que no sea necesario ir a campo, se tendría un costo de inversión mucho mayor, pues se necesitaría 02 cámaras en promedio por cada cuadra analizada, el costo de cada cámara tiene un valor de S/ 350.00 soles, para mayor detalle se realiza el análisis de costos en la siguiente tabla:

Tabla 2

Resumen comparativo de costos entre la forma tradicional, semiautomatizada y automatizada para el levantamiento de información sobre grietas

Ítem	Forma Cantidad	Tradicional Costo S/	Semi Cantidad	Automatizada Costo S/	Auto Cantidad	Matizada Costo S/
Equipos						
Cámaras	0	0.00	1	600.00	52	350
Laptop	1	3,000.00	1	3,000.00	1	3,000.00
Total		3,000.00		3,600.00		21,200.00
Horas						
Hombre						
Campo	1x36	87.30	2x11	87.30	0	0.00
Gabinete	1x4	87.30	1x2	87.30	1x1	87.20
Total		3,492.00		2,095.20		87.20
Materiales						
Escalera	0	0.00	1	450.00	0	0.00
Total		0.00		450.00		0.00
Servicios						
Luz		0.00		0.00		200.00
Internet		0.00		0.00		200.00
Total		0.00		0.00		400.00
Total		6,492.00		6,415.20		21,687.20

Se puede apreciar que el costo de realizar la semiautomatización para el levantamiento de información de campo sobre las grietas es el menor, pero teniendo la limitación de que solo se pueda levantar información en épocas u horas con presencia solar, puesto que en la selva las lluvias son intensas y en este lapso de tiempo no se podría realizar un recojo de información. Para el método tradicional se tendría que el factor humano de error y el tiempo que se utiliza para recabar la información serán determinantes en el costo promedio, además que cada que se requiera de información se tendría que ir a campo, lo cual limita mucho la disponibilidad de personal técnico con que se cuente en ese momento. Finalmente, la automatización, si bien es costosa al momento inicial lo que permite es tener información en tiempo real y todos los días del año, ya sea en épocas de lluvia o sol, haciendo que sea la alternativa técnicamente más recomendable de implementar, pudiendo empezar con proyectos pilotos en calles céntricas del distrito para luego expandirlos a las zonas urbano – marginales, además en la mayoría de distritos existen las cámaras de serenazgo, las cuales se podrían acoplar a la implementación del proyecto, abaratando costos de inversión.

En la selva del Perú las lluvias son fuertes, teniendo promedios anuales de 1,488.90 mm de acuerdo con el servicio nacional de meteorología e hidrología del Perú (Senami), la información de las imágenes que se recolecten para el análisis de grietas pueden ser soleadas, nubladas o cuando recién está empezando a llover, considerando que el dataset fue armado con imágenes en esas mismas condiciones, no existiría problemas para realizar el reconocimiento de las grietas en esos entornos adversos, así mismo la presente investigación solo se centró en el reconocimiento de grietas en pavimentos flexibles, para poder realizar el reconocimiento de otras fallas en el pavimento como piel de cocodrilo, ahuellamientos, se tendría que realizar la recolección de información en una calle que presente estas fallas, para poder armas el proceso de etiquetado en ROBOFLOW y entrenar al nuevo modelo en el reconocimiento de este tipo de deficiencias que presentan los pavimentos.

De acuerdo con las métricas de evaluación del modelo, la métrica de precisión/Presición analiza que, de la cantidad de cosas detectadas, cuantas son verdaderamente grietas con un valor del 90%, lo cual indica que de cada 10 cosas que el modelo interpreta como grietas, 9 son verdaderas y 1 es falsa, teniendo de esta forma un alto porcentaje de confiabilidad. La métrica Recall, analiza que, de todas las grietas que realmente eran grietas, cuantas he conseguido detectar, con un valor estable del 90%, haciendo que, de 10 grietas reales, 9 sean detectadas y 1

no, presentando un alto valor de confiabilidad. La métrica mAP50 presenta un valor de 87%, esta métrica mide la precisión del modelo para las detecciones fáciles, como por ejemplo grietas cuando en la imagen del pavimento no existe ningún otro elemento como sombras, lluvias, vehículos, u otra falla, y finalmente la métrica mAP50-95, mide la precisión del modelo para las detecciones en entornos con dificultad de detección, es decir cuando en la imagen se presentan otro tipo de fallas como piel de cocodrilo o ahuellamientos, así como sombras, lluvias, vehículos entre otros, teniendo un valor del 91%, haciendo que la confiabilidad del modelo ante las imágenes presentadas de los proyectos analizados sea muy alta, lo cual ha sido reforzada con la comparación visual en campo.

Para la correcta asignación de recursos para la operación y mantenimiento de las vías urbanas con pavimento flexible, los administradores de estas que son los gobiernos locales, deben contar con el estado situacional de las vías, para esto es necesario enviar personal técnico a campo y que puedan recolectar esta información, para que posteriormente en gabinete lo procese, y se pueda presentar un plan de acción de los requerido, que incluye el presupuesto y las acciones ha desarrollar, hasta eso el tiempo ha transcurrido y pueden ir pareciendo nuevas grietas, de acuerdo con Callcut et al. (2021) las vías son una de las infraestructuras críticas de cada país, y para mantener su condición estructural y funcional adecuada, las autoridades viales necesitan una evaluación continua de las condiciones del pavimento para la asignación óptima del presupuesto y las operaciones de mantenimiento y rehabilitación (M&R). Los sistemas de gestión de pavimentos convencionales (PMS) utilizan principalmente un enfoque reactivo (tratar las fallas a medida que aparecen) para planificar actividades de mantenimiento que no son rentables en comparación con un enfoque proactivo (evitar que ocurran fallas).

Para la detección automática de grietas en el pavimento flexible de la zona en estudios se empleó cámaras celulares y cámaras de videovigilancia comunes, que se pueden encontrar fácilmente, esto con la intención de permitir que se pueda replicar esta procedimiento en cualquier parte del país sin necesidad de un presupuesto considerable, pues es muchas veces los escasos recursos los que impiden adquirir equipos o tecnologías avanzadas para realizar el trabajo de detección de grietas como por ejemplo los escáneres láser que están bien establecidos en la comunidad de teledetección para adquirir geometría e imágenes que representan la realidad de manera precisa. En comparación con los escáneres láser terrestres (TLS) tradicionales, los escáneres láser móviles (MLS) combinan sensores LiDAR y cámaras con sistemas de posición y navegación que permiten la recopilación de nubes de puntos de georreferenciación de alta calidad de manera productiva. Los beneficios del uso de LiDAR móvil sobre los instrumentos de topografía terrestre aéreos y convencionales incluyen ahorro de costos, ahorro de tiempo, alta resolución y seguridad (Puente et al., 2013).

Al comparar las grietas identificadas en las imágenes mostradas al modelo con las grietas visualizadas en campo, se obtuvo un porcentaje de confianza elevado, considerando que el promedio de variación entre las longitudes que arroja el modelo y las longitudes obtenidas en la inspección de campo oscila en 1.00 cm a 2.00 cm respectivamente, así mismo en la investigación realizada por Hong et al. (2023) esta se basa en la aplicación de la inteligencia artificial a la detección autónoma de daños en el firme de las carreteras, utilizando para ello el software del Sistema de Gestión Inteligente de Infraestructura de Tráfico Vial (RTI IMS), que utiliza la plataforma de programación Yolo V5. Este software está diseñado para identificar automáticamente los daños en la superficie de las carreteras durante la operación. Basado en tecnología de reconocimiento de imágenes de aprendizaje automático, el modelo se entrena con una base de datos diversa de imágenes de daños en la superficie de las carreteras de Japón, India y Vietnam.

De todo lo indicado se puede señalar que la presente investigación busca de forma fácil, sencilla, con equipos y herramientas disponibles en cualquier parte del país, obtener información sobre el estado de las grietas en los pavimentos flexibles, que ayudaran a los técnicos de los gobiernos locales a identificar al momento inicial de la aparición de una grieta, cuantificar el nivel de afectación de la zona donde se encuentra, determinar el tipo de intervención que se pretende realizar sin necesidad de salir a campo, pero sobre todo que los datos obtenidos a través del uso de inteligencia artificial sean confiables.

Conclusiones

Las imágenes iniciales recolectadas deben tomarse en el rango de altura de 3ml a 5ml, pues es una altura ideal para obtener una visualización adecuada de las grietas, además está dentro de la altura de los semáforos que

por normal están ubicados en zonas urbanas entre 2.10 ml y 5.30 ml respectivamente, si es que se quiere incluir las cámaras con las que cuentan las áreas de serenazgo de los gobiernos locales, para disminuir el costo de inversión inicial para un proceso automatizado en su totalidad. Los equipos para entrenar el modelo, deben ser los mismo con que se capten las imágenes para su análisis, evitando así que pueda haber diferencias en lo que se refiere al tamaño y calidad de las imágenes. La cantidad de imágenes a recolectar para armar el dataset debe ser la mayor posible, mayor a 1,000 de ser el caso, considerando que a mayor información de entrenamiento se obtendrá mayores resultados, puesto que de acuerdo con las métricas de cada 10 elementos analizados, como grietas, 9 eran verdaderas, si lo llevamos a escala de cada 100 elementos analizados, como grietas, 90 son verdaderas, con una mayor cantidad de imágenes de podrá obtener niveles de confiabilidad mayor donde de cada 1,000 elementos analizados, 995 sean grietas, otorgándonos una confiabilidad de casi un 100%.

El proceso de etiquetado de imágenes en la plataforma ROBOFLOW, debe ser lo más preciso posible, pues sino desarrollamos de forma adecuada este procedimiento, se obtendrá resultados que difieran de la realidad, haciendo que las cosas que detecten, para la presente investigación grietas, no sean reales, y detecten por ejemplo, las sombras de los cables de luz, lo cual serian perjudicial para toma de datos y futuras decisiones, afectando no solo la confiabilidad del modelo, sino también la veracidad de los resultados obtenidos, ya sea en cantidad de grietas y longitud de las mismas.

El modelo presenta un alto valor de confiabilidad en los resultados obtenidos, pues de acuerdo a las métricas como el de precisión/Precision, su valor es del 90% considerándose muy alto con respecto a este tipo de procesamiento de información. Por su parte la métrica Recall, arroja valores del 90%, presentando alta confiabilidad de los valores reales, así mismo las métricas mAP@50 y mAP@50-95, presentan valores del 87% y 91% respectivamente, lo cual hace que el modelo este altamente preparado para la identificación de su objetivo que son las grietas, tanto para entornos fáciles como para entornos de una mayor dificultad.

Los gobierno locales no destinan recursos para el tema de O y M en vías urbanas, y más aún presupuesto para obtener información del estado de estas vías, haciendo que no se realicen actividades de mantenimiento periódico, rutinario o recurrente, los cuales son menos costosos que la inversión necesaria cuando estas vías presentan deterioros mayor o fallas estructurales, las cuales con acciones de mantenimiento no pueden ser reparadas y se requieren de inversiones IOARR mínimamente, y que si estas últimas no se atienden derivaran en la necesidad de formular proyectos de inversión, con costos requeridos mucho mayores.

La investigación contribuye con la eficacia para obtener información necesaria, confiable y actualizada que ayuda al campo de la ingeniería vial en zonas urbanas del país, puesto que la forma en cómo se recolecta la información sigue siendo la misma desde hace muchos años atrás hasta la actualidad, mayormente en las zonas alejadas del país, puesto que en su mayoría están a administrada cargo de gobiernos locales que los administran que no cuentan con recursos necesarios para realizar un monitoreo constante al estado de sus vías. Con esta investigación de forma empírica se demostró la veracidad de los resultados y la rapidez para obtenerlos, adecuando la ingeniería a los nuevos tiempos, teniendo de aliado a la inteligencia artificial, la cual usada de manera correcta resulta de mucha utilidad.

Recomendaciones

Se recomienda recolectar una mayor cantidad de imágenes para armar el dataset, obtener más información sobre las grietas en el pavimento flexible y hacer que el error entre la cuantificación de la longitud de las grietas detectadas con el modelo y las detectadas en campo sea menor a 0.5 cm. Así mismo incluir nuevas fallas del pavimento flexible como piel de cocodrilo, hundimientos, ahuellamientos en próximos estudios para obtener un resultado más completo del estado actual del pavimento y no solo limitarlo a la cuantificación de grietas.

Implementar dentro de los gobiernos locales del país el uso de inteligencia artificial para simplificar y ayudar en los procesos de trabajo, más que todo en lo relacionado al área de infraestructura, que es un área de requiere de muchos recursos tanto humanos como económicos, siendo estos últimos escasos dentro de las municipalidades, para que a través de políticas públicas adecuadas se puedan implementar este tipo de alternativas de solución y con un trabajo integrado de las diversas áreas se pueda materializar y poder obtener información oportuna de estado real de

las vías urbanas con pavimento flexible que administran.

El desarrollo de estas nuevas estrategias dentro de los gobiernos locales disminuirá el costo de inversión no solo en personal técnico de las áreas de infraestructura o gerencias de obras, que dispondrá de más tiempo para desarrollar otras actividades necesarias, sino también de poder cuantificar de forma segura la cantidad de recursos necesarios a invertir en acciones de mantenimiento, considerando que para todas las infraestructuras del país es necesarios y de su importancia planificar y ejecutar este tipo de acciones para garantizar su tiempo de vida útil.

Realizar un monitoreo por parte del gobierno central para que las entidades de los gobiernos locales una vez culminado la ejecución física de un proyecto, asigne de manera semestral recursos para la O y M, para que de esta forma se pueda cumplir de manera adecuada con el tiempo de vida útil de un proyecto de la tipología de pistas y veredas, que en la actualidad es de 10 años.

Referencias

- Abu, S., Ait, M., Zeiada, W., Hamad, K., & Al-Ruzouq, R. (2025). Artificial intelligence applications in pavement infrastructure damage detection with automated three-dimensional imaging – A systematic review. *Alexandria Engineering Journal*, *117*, 510-533. <https://doi.org/10.1016/j.aej.2024.11.081>
- Alkhedher, M., Alsit, A., Alhalabi, M., AlKhedher, S., Gad, A., & Ghazal, M. (2025). Novel pavement crack detection sensor using coordinated mobile robots. *Transportation Research Part C: Emerging Technologies*, *172*, 105021. <https://doi.org/10.1016/j.trc.2025.105021>
- Boakye, J., Guidotti, R., Gardoni, P., & Murphy, C. (2022). The role of transportation infrastructure on the impact of natural hazards on communities. *Reliability Engineering & System Safety*, *219*, 108184. <https://doi.org/10.1016/j.res.2021.108184>
- Callcut, M., Cercesau, J., Vargas, L., & McMillan, L. (2021). Digital twins in civil infrastructure systems. *Sustainability*, *13*, 11549. <https://doi.org/10.3390/su132011549>
- Chang, X., Zhang, R., Mao, J., & Fu, Y. (2024). Digital Twins in Transportation Infrastructure: An Investigation of the Key Enabling Technologies, Applications, and Challenges. *IEEE Transactions on Intelligent Transportation Systems*, *25*(7), 6449-6471. <https://doi.org/10.1109/TITS.2024.3401716>
- Guerrieri, M., & Parla, G. (2022). Flexible and stone pavements distress detection and measurement by deep learning and low-cost detection devices. *Engineering Failure Analysis*, *141*, 106714. <https://doi.org/10.1016/j.engfailanal.2022.106714>
- Hong, S. V., Tien, K. V., Quang Le, H., & Tran, P. (2023). Road surface damages allocation with RTI-IMS software based on YOLO V5 model. *Sustainable and Resilient Infrastructure*, *9*(3), 242–261. <https://doi.org/10.1080/23789689.2023.2287857>
- Hvala, B., Dos Santos, M., Lopes, L., Lellis, M., & De Araújo, I. (2022). Analysis of maintenance activities in Urban Pavement Management Systems based on Decision Tree Algorithm. *Procedia Computer Science*, *214*, 712-719. <https://doi.org/10.1016/j.procs.2022.11.233>
- Koch, C., Jog, G., Brilakis, I. (2023). Automated pothole distress assessment using asphalt road surface video data. *Journal of Computing in Civil Engineering*, *27*(4). [https://doi.org/10.1061/\(ASCECP.1943-5487.0000232](https://doi.org/10.1061/(ASCECP.1943-5487.0000232)
- Maeda, H., Sekimoto, Y., Seto, T., Kashiyama, T., & Omata, H. (2018). Road damage detection and classification using deep neural networks with smartphone images. *Computer-Aided Civil and Infrastructure Engineering*, *33*(12), 1127-1141. <https://doi.org/10.1111/mice.12387>
- Ministerio de Economía y Finanzas del Perú [MEF]. (2021). *Nota técnica para la identificación y estimación de los costos de mantenimiento de inversiones*. https://www.mef.gob.pe/contenidos/inv_publica/anexos/anexo1_RD006_2021EF6301.pdf
- Ouma, Y., & Hahn, M. (2016). Wavelet-morphology based detection of incipient linear cracks in asphalt pavements from RGB camera imagery and classification using circular Radon transform. *Adv. Eng. Inform.*, *30*, 481–499. <https://doi.org/10.1016/j.aei.2016.06.003>

- Paredes, V., & Rodríguez, R. (2011). *Modelo de gestión de conservación vial para reducir los costos de mantenimiento vial y operación vehicular en los caminos rurales de las poblaciones de Riobamba, San Luis, Punín, Flores, Cebadas de la provincia de Chimborazo* [Tesis de pregrado, Universidad Técnica de Ambato]. Repositorio UTA. <https://repositorio.uta.edu.ec/jspui/handle/123456789/2199>
- Puente, I., González, H., Martínez, J., & Arias, P. (2013). Review of mobile mapping and surveying technologies. *Measurement*, 46(7), 2127-2145. <https://doi.org/10.1016/j.measurement.2013.03.006>
- Sun, Y., Tang, H., & Zhang, H. (2024). Automatic Detection of Pavement Marking Defects in Road Inspection Images Using Deep Learning. *Journal of Performance of Constructed Facilities*, 38(2). <https://doi.org/10.1061/JPCFEV.CFENG-4619>
- Yu, G., Wang, Y., Hu, M., Shi, L., Mao, Z., & Sugumaran, V. (2021). RIOMS: An intelligent system for operation and maintenance of urban roads using spatio-temporal data in smart cities. *Future Generation Computer Systems*, 115, 583-609. <https://doi.org/10.1016/j.future.2020.09.010>
- Zhengji, L., Jiacheng, X., Yuxiao, F., Wentao, W., Gang, C., Liqiang, Z., & Tianyang, W. (2024) A Efficient and Robust Framework for Pavement Damage Detection. *Journal of Latex Class Files*, 14(8), <https://doi.org/10.48550/arXiv.2405.17905>
- Zhu, J., Zhong, J., Ma, T., Huang, X., Zhang, W., & Zhou, Y. (2022). Pavement distress detection using convolutional neural networks with images captured via UAV. *Automation in Construction*, 133, 103991. <https://doi.org/10.1016/j.autcon.2021.103991>