

UNIVERSIDAD PERUANA UNIÓN

FACULTAD DE INGENIERIA Y ARQUITECTURA

Escuela Profesional de Ingeniería Civil



**Implementación de un método automatizado para detectar
fallas y severidad en pavimentos flexibles mediante
procesamiento de imágenes**

Tesis para obtener el Título Profesional de Ingeniero Civil

Autores:

Natalia Martina Manchay Huancas

July Ariday Ccacyavilca Umiyauri

Asesor:

Dr. Edwin Parillo Escarsena

Juliaca, noviembre de 2025

DECLARACIÓN JURADA DE ORIGINALIDAD DE TESIS

Yo Dr. Edwin Parillo Escarsena, docente de la Facultad de Ingeniería y Arquitectura, Escuela Profesional de Ingeniería Civil, de la Universidad Peruana Unión.

DECLARO:

Que la presente investigación titulada: **“IMPLEMENTACIÓN DE UN MÉTODO AUTOMATIZADO PARA DETECTAR FALLAS Y SEVERIDAD EN PAVIMENTOS FLEXIBLES MEDIANTE PROCESAMIENTO DE IMÁGENES”** de los autores **Natalia Martina Manchay Huancas** y **July Ariday Ccacyavilca Umiyauri** tiene un índice de similitud de 17% verificable en el informe del programa Turnitin, y fue realizada en la Universidad Peruana Unión bajo mi dirección.

En tal sentido asumo la responsabilidad que corresponde ante cualquier falsedad u omisión de los documentos como de la información aportada, firmo la presente declaración en la ciudad de Juliaca, a los 21 días del mes de noviembre del año 2025



Dr. Edwin Parillo Escarsena

Asesor

ACTA DE SUSTENTACIÓN DE TESIS



En Puno, Juliaca, Villa Chullunquiari, a 21 día(s) del mes de noviembre del año 2020, siendo las 8:30 horas, se reunieron los miembros del jurado en la Universidad Peruana Unión Campus Juliaca, bajo la dirección del (de la) presidente(a):

Mtro. Leonel Chulucanas Paucor el (la) secretario(a) Mg. Herson Duberly Paz Gusi y los demás miembros: Mtro. Eder Mamani Chambi y el (la) asesor(a) Dr. Edwin Parillo Escarona

con el propósito de administrar el acto académico de sustentación de la tesis titulado: Implementación de un método automatizado para detectar fallas y severidad en pavimentos flexibles mediante procesamiento de imágenes

del(los) bachiller(es): a) Natalia Martina Marchay Huancas
 b) July Ariday Cacyanilo Umizauri
 c)

conducente a la obtención del título profesional de: Ingeniero Civil
(Denominación del Título Profesional)

El Presidente inició el acto académico de sustentación invitando al (a la) / a (los) (las) candidato(a)s hacer uso del tiempo determinado para su exposición. Concluida la exposición, el Presidente invitó a los demás miembros del jurado a efectuar las preguntas, y aclaraciones pertinentes, las cuales fueron absueltas por al (a la) / a (los) (las) candidato(a)s. Luego, se produjo un receso para las deliberaciones y la emisión del dictamen del jurado.

Posteriormente, el jurado procedió a dejar constancia escrita sobre la evaluación en la presente acta, con el dictamen siguiente:

Bachiller (a): Natalia Martina Marchay Huancas

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
<u>Aprobado</u>	<u>15</u>	<u>B-</u>	<u>Buena</u>	<u>Muy Buena</u>

Bachiller (b): July Ariday Cacyanilo Umizauri

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
<u>Aprobado</u>	<u>15</u>	<u>B-</u>	<u>Buena</u>	<u>Muy Buena</u>

Bachiller (c):

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	

(*) Ver parte posterior

Finalmente, el Presidente del jurado invitó al (a la) / a (los) (las) candidato(a)s a ponerse de pie, para recibir la evaluación final y concluir el acto académico de sustentación procediéndose a registrar las firmas respectivas.


 Presidente/a

 Asesor/a

 Bachiller (a)

 Miembro

 Bachiller (b)

 Secretario/a

 Miembro

 Bachiller (c)

ÍNDICE DE CONTENIDO

Resumen.....	V
Abstract.....	VI
1. Introducción.....	7
2. Revisión de literatura.....	8
3. Metodología.....	9
3.1. Muestras y adquisición de imágenes.....	9
3.2. Organización del Conjunto de Datos.....	11
3.3. Arquitectura del modelo de Yolov11.....	12
4. Resultados.....	13
4.1. Desempeño de YOLOv11 en la detección automática de fallas.....	13
4.1.1. Métricas de precisión (Precision), sensibilidad (Recall) y F1-Confidence (F1-score con umbral de confianza).....	16
4.1.2. Análisis comparativo del método tradicional y método automatizado.....	18
□ Limitaciones para la aplicación del método automatizado.....	23
i. Cobertura limitada de tipos de falla.....	23
ii. Estimación parcial de severidad.....	23
iii. No analiza la evolución del deterioro.....	23
iv. Integración limitada en Sistemas de Gestión de Pavimentos (SGP).....	23
v. Dependencia de condiciones específicas de captura.....	23
vi. Necesidad de validación en más escenarios.....	24
5. Conclusión.....	24
Declaración.....	25
6. Referencias.....	25
7. Anexos.....	27
7.1. Evidencia de sumisión.....	27
7.2. Copia de la resolución de inscripción del perfil de proyecto de tesis en formato artículo aprobado por el consejo de facultad correspondiente.....	28
7.3. Fichas de evaluación.....	29
7.4. Demostración del método automatizado.....	33

Implementación de un método automatizado para detectar fallas y severidad en pavimentos flexibles mediante procesamiento de imágenes

Implementation of an automated method to detect faults and severity in flexible pavements using image processing

Ccacyavilca Umiyauri July Ariday, Manchay Huancas Natalia Martina, Parillo Escarsena Edwin

EP. Ingeniería Civil, Facultad de Ingeniería y Arquitectura, Universidad Peruana Unión – Filial Juliaca

Resumen

En el Perú, el método manual de inspección de pavimentos flexibles presenta limitaciones importantes, especialmente en cuanto a tiempo y detección. Este proceso requiere identificar, medir y registrar manualmente cada falla, lo que alarga la inspección y retrasa las intervenciones. Además, la subjetividad del inspector puede afectar la clasificación de la severidad, generando diagnósticos inconsistentes y dificultando una adecuada planificación del mantenimiento rutinario. Frente a esta problemática, se desarrolló un método automatizado de detección basado en un lenguaje de programación Python en el modelo de YOLOv11. Para entrenarlo, se recolectaron 7,735 imágenes en calles de la provincia de San Román, etiquetadas manualmente según los criterios del Manual del MTC, según su tipo de falla y severidad. El modelo YOLOv11 alcanzó una Precisión de 0.90, un F1-Confidence de 0.74 y un Recall de 0.90. En una prueba realizada en un tramo urbano de medio kilómetro (Jr. 7 de junio), logró un 95.6% en la clasificación del tipo de falla con su severidad, con un tiempo en procesamiento por imagen en un rango de 5 a 10 segundos. La concordancia entre el método manual y el método automatizado fue evaluada mediante el coeficiente Kappa de Cohen ponderado valores en grieta longitudinal $\kappa_w = 0.85$, grieta transversal $\kappa_w = 0.79$ y en bache $\kappa_w = 0.95$, indicando buena concordancia. Este proyecto representa un avance hacia la integración de inteligencia artificial en la gestión vial en conservación rutinaria, al mejorar la detección de fallas y permitir decisiones más oportunas en las labores de conservación rutinaria.

Palabras Claves: Clasificación de severidad, detección automatizada, fallas en pavimentos, pavimentos flexibles, YOLOv11

Abstract

In Peru, the manual method for inspecting flexible pavements has significant limitations, especially in terms of time and detection. This process requires manually identifying, measuring, and recording each defect, which lengthens the inspection and delays interventions. Furthermore, the inspector's subjectivity can affect the severity classification, leading to inconsistent diagnoses and hindering proper planning of routine maintenance. To address this problem, an automated detection method was developed using the Python programming language and the YOLOv11 model. To train the model, 7,735 images were collected from streets in the province of San Román, manually labeled according to the criteria of the MTC Manual, based on their defect type and severity. The YOLOv11 model achieved a Precision of 0.90, an F1-Confidence of 0.74, and a Recall of 0.90. In a test conducted on a half-kilometer urban section (Jr. 7 de junio), the system achieved 95.6% accuracy in classifying the type of failure and its severity, with image processing time ranging from 5 to 10 seconds. The agreement between the manual and automated methods was evaluated using Cohen's weighted Kappa coefficient, with values of 0.85 for longitudinal cracks, 0.79 for transverse cracks, and 0.95 for potholes, indicating good agreement. This project represents progress toward the integration of artificial intelligence in road management for routine maintenance, by improving failure detection and enabling more timely decisions in routine maintenance tasks.

Keywords: Severity classification, automated detection, pavement failures, flexible pavements, YOLOv11

1. Introducción

En el Perú, la inspección visual de pavimentos flexibles continúa siendo el método más empleado para evaluar su estado, a pesar de sus evidentes limitaciones. Este procedimiento requiere personal capacitado para registrar las fallas de forma manual, lo que lo convierte en un proceso lento, costoso, y altamente subjetivo, afectando directamente la precisión del diagnóstico (Soto & Robustiano, 2022). Aunque los manuales técnicos establecen criterios claros, la interpretación del inspector puede variar. En términos de tiempo, la inspección a lo largo de todo el tramo, que implica la identificación, medición con herramientas básicas y registro de cada falla, puede resultar un proceso extenso (Bardales & Salomón, 2017)

Estudios recientes evidencian la ineficiencia del método tradicional: por ejemplo, evaluar seis unidades de muestra puede tomar entre 9 y 15 horas, dependiendo de la condición del pavimento (Bravo & Arévalo, 2023). Además, se ha determinado que las fallas más frecuentes en pavimentos flexibles son los baches (11.8%) y las grietas longitudinales y transversales (11.6%), cuya detección temprana resulta fundamental para planificar el mantenimiento y evitar su deterioro progresivo (León & Alejandra, 2021). En concordancia, el (MTC, 2018) cap. 400, contempla dentro de sus actividades de conservación rutinaria intervenciones específicas orientadas a estas fallas. Para el caso de las grietas, se contempla el sellado de fisuras y grietas sección 401 como medida preventiva para controlar su propagación. En lo que respecta a los baches, se dispone su rehabilitación mediante parchado superficial sección 410, con el propósito de restablecer las condiciones de servicio del pavimento y prolongar su vida útil en buen estado. A nivel internacional, se ha corroborado que los métodos tradicionales, como las inspecciones visuales y los reportes manuales, presentan deficiencias similares: son poco eficientes, consumen recursos y generan retrasos en las reparaciones, lo que incrementa tanto los costos de mantenimiento como el riesgo de accidentes (Sathya & Saleena, 2022).

Ante esta situación, surge la necesidad de implementar soluciones tecnológicas que optimicen la detección y evaluación de fallas. El procesamiento automatizado de imágenes, a través de algoritmos de inteligencia artificial como YOLO (You Only Look Once), representa una alternativa eficaz. Este modelo se caracteriza por su alta velocidad y precisión en la detección de objetos dentro de imágenes. En combinación con el lenguaje de programación Python, permite analizar las características morfológicas de las fallas viales, como la forma circular de los baches o la estructura lineal de las grietas, clasificándolas en niveles de severidad (bajo, medio o alto).

En este contexto, el presente proyecto propone un método automatizado de detección de fallas en pavimentos flexibles, basado en el modelo de visión por computadora YOLOv11. En este método permite no solo identificar el tipo de falla (bache, grieta longitudinal o transversal), sino también clasificar su severidad. A diferencia de los antecedentes revisados, como los trabajos de (Wang, 2022), que se centraron únicamente en la detección de baches con clasificación en dos categorías (con y sin agua), de (Ukhwah, 2019), que aplicó YOLOv3 para la detección de baches sin considerar severidad, y de (Becker1, 2019), que empleó CNNs para la detección de baches a partir de imágenes de UAV, este proyecto amplía el alcance al proponer la detección simultánea de tres tipos de fallas y su respectiva clasificación de severidad en el Perú, lo cual constituye un aporte novedoso que no se había implementado en los estudios previos. El proyecto busca demostrar que el uso de técnicas automatizadas mejora significativamente la velocidad y detección de las fallas. Para validar su efectividad, se realizó

una prueba en campo, comparando los resultados del método automatizado con los obtenidos por un método manual tradicional.

La concordancia entre ambos enfoques fue evaluada mediante la estadística Kappa de Cohen ponderada que se emplea cuando se analizan variables ordinales o con múltiples categorías, asignando pesos a los desacuerdos según su gravedad, lo que permite una estimación más precisa de la concordancia entre evaluadores (Szklo & Nieto, 2003). Por otro lado, el coeficiente Kappa de Cohen ponderado toma valores entre 0.00 y 1.00, donde 0.00 indica un desacuerdo total y 1.00 representa el máximo nivel de acuerdo. Según (Landis & Koch, 1997), su interpretación se clasifica en: pobre (0.00), leve (0.01–0.20), aceptable (0.21–0.40), moderada (0.41–0.60), buena (0.61–0.80) y muy buena (0.81–1.00), lo que permitió evidenciar el potencial del método automatizado propuesto como herramienta complementaria o incluso alternativa al método tradicional.

2. Revisión de literatura

Los estudios previos han explorado el uso de YOLO para la detección de baches en pavimentos flexibles, destacando el trabajo de (Ukhwah, 2019), que evaluó YOLOv3 y sus variantes en 448 imágenes de carreteras en Indonesia, logrando un mAP de hasta 88.93%, aunque limitado a baches sin clasificar su severidad y con datos restringidos a un entorno específico. De manera similar, (Wang, 2022) desarrolló una versión mejorada de YOLOv3 para detectar y medir baches en 500 imágenes de pavimentos asfálticos, alcanzando un mAP del 89.3%, pero sin incluir otros tipos de fallas ni una clasificación estandarizada de severidad. En contraste, el presente proyecto amplía el alcance al incluir la detección de baches, grietas longitudinales y transversales, junto con la clasificación de su severidad basada en los criterios del Manual del MTC, permitiendo una evaluación más integral y aplicable.

Los estudios previos han explorado diversas técnicas de aprendizaje profundo para la detección y clasificación de fallas en pavimentos. (Obunguta, 2024) utilizó Mask R-CNN en imágenes de RDD-2020, con el lenguaje de programación Python para detectar defectos sin especificar tipos de fallas, enfocándose en la gestión automatizada de pavimentos, mientras que el presente proyecto implementa un método específico para fallas comunes en Perú según el MTC. (Becker1, 2019) y (Pei, 2022) aplicaron Faster R-CNN para detectar baches en imágenes UAV y de pavimentos asfálticos, respectivamente, pero sin abordar otros tipos de fallas ni su severidad. (Dhakal, 2022) empleó CNN y ANN para clasificar grietas según su origen, distinto del enfoque de este proyecto, que clasifica su severidad según el ancho. (Sathya & Saleena, 2022) lograron una alta precisión con ODRNN para detectar baches, pero sin considerar otras fallas. (Liu, 2022) usó termografía infrarroja para clasificar grietas por fatiga, técnica diferente al procesamiento de imágenes convencionales de este proyecto. (Tayo, 2019) diseñó un dispositivo para medir anchos de grietas en pavimentos de hormigón sin considerar otras fallas. Finalmente, (Xu & Yu, 2023) desarrollaron un método basado en señales de aceleración para evaluar la rugosidad del pavimento, una métrica distinta a la detección de fallas. En contraste, el presente proyecto busca detectar baches, grietas longitudinales y transversales, y clasificar su severidad con base en el Manual del MTC, utilizando imágenes visuales accesibles para la inspección rutinaria de pavimentos flexibles en el Perú.

3. Metodología

La investigación es de tipo aplicada, orientada al uso del conocimiento científico para resolver problemas concretos mediante la aplicación práctica de teorías y métodos (Carlessi & Meza, 2015); se aplica un método automatizado para detectar la severidad (bajo, medio, alto) de fallas como baches, grieta longitudinal y transversal en pavimentos flexibles según el Manual de Carreteras: Mantenimiento o Conservación Vial RD N.º 08 – 2014 – MTC/14. El enfoque mixto se centra en la medición objetiva y el análisis estadístico de datos para validar hipótesis (Hernández Sampieri, 2014), siendo clave para evaluar la efectividad del método automatizado. El diseño experimental implica la manipulación de variables para observar sus efectos en condiciones controladas o naturales (Hernández Sampieri, 2014); se tomarán imágenes de pavimentos en su entorno real para evaluar el modelo sin intervención. El nivel explicativo busca entender cómo y por qué ocurren los fenómenos, analizando la relación entre variables (Carlessi & Meza, 2015) en este caso, nuestras variables son independiente es el método automatizado de detección de fallas y variable dependiente es el desempeño del método automatizado (concordancia en detección y clasificación, y tiempo de procesamiento).

3.1. Muestras y adquisición de imágenes

Se recopiló un conjunto de imágenes digitales de fallas en pavimentos flexibles en diversas calles de la provincia de San Román, las cuales presentaban distintos niveles de severidad superficial. Cada imagen fue identificada y evaluada manualmente conforme a los criterios establecidos en el Manual del MTC. Durante este proceso, se registraron características visibles como el ancho de grietas longitudinales y transversales, así como el diámetro de los baches, midiendo en todos los casos el punto de mayor extensión para determinar la severidad de cada falla. Las mediciones se realizaron con una cinta métrica, lo que permitió cuantificar con precisión las dimensiones relevantes. Adicionalmente, con el fin de proporcionar una escala visual uniforme en las imágenes, se utilizó un alambre galvanizado N.º 16 de un metro de longitud, colocado junto a cada falla durante la captura fotográfica, como se muestra en la Fig 2. Las imágenes fueron tomadas a una distancia constante de un metro respecto a la superficie del pavimento, empleando cámaras móviles con sistema operativo Android, lo que garantizó un nivel de detalle adecuado para el análisis visual y el procesamiento digital posterior. Asimismo, la toma de imágenes digitales se realizó en entornos reales, considerando distintas condiciones ambientales y de iluminación como clima lluvioso, soleado y nublado; en turnos de mañana y tarde; además de escenarios con presencia de polvo, residuos u otros elementos contaminantes que afectan la visibilidad; sombras proyectadas de árboles y postes; sin embargo, no se consideró tomas con luces artificiales (iluminación pública). En total, se obtuvieron 7,735 imágenes, las cuales conformaron el conjunto de dataset utilizado en un 70% para entrenamiento, 20% para validación y 10% para el test del método automatizado de detección. Este dataset robusto permitió alimentar el algoritmo de procesamiento con información suficiente para lograr una detección y clasificación de las fallas en pavimentos flexibles.




Figura 1 Tipo de falla con su severidad en pavimentos flexibles según MTC




Figura 2 Representación de adquisición de imágenes en campo

Fig. 1 presenta la clasificación visual de tres tipos de fallas comunes en pavimentos flexibles: grietas transversales, grietas longitudinales y baches, cada una organizada según su severidad: baja, media y alta. Las grietas longitudinales, generadas por fatiga estructural del pavimento, se clasifican como baja (≤ 1 mm), media (> 1 mm y ≤ 3 mm) y alta (> 3 mm con bordes desintegrados). Las grietas transversales, asociadas a retracciones térmicas o juntas defectuosas, siguen la misma clasificación por ancho: baja (≤ 1 mm), media (> 1 mm y ≤ 3 mm) y alta (> 3 mm con desintegración). En cuanto a los baches, provocados por el desgaste

acumulado y la falta de mantenimiento, su severidad se determina por el diámetro del hueco: baja (≤ 0.2 m), media (> 0.2 m y ≤ 0.5 m), y alta (> 0.5 m). Esta figura permite visualizar el deterioro progresivo de estas fallas (MTC, 2018).

3.2. Organización del Conjunto de Datos

El conjunto de datos adquirido, que comprende una serie de captura de imágenes digitales de grietas transversales, grietas longitudinales y baches, se dividió aleatoriamente en conjuntos de entrenamiento, validación y test, para el desarrollo y evaluación del modelo. Para preparar el conjunto de datos adecuado para desarrollar el algoritmo para la detección de fallas según su tipo y severidad, se muestreó 7,735 imágenes digitales en total de las fallas. Posteriormente, las imágenes extraídas fueron anotadas para identificar las fallas y su severidad correspondiente utilizando la herramienta de código abierto CVAT (Computer Vision Annotation Tool), donde se dibujaron manualmente rectángulos en el contorno de cada falla presente en la imagen y se asignó una etiqueta de grado de calidad, como bajo, medio o alto, según el estado visual de la falla. La Fig. 3 muestra las etiquetas realizadas según la falla y el tipo de severidad correspondiente a la inspección del método manual. Se anotaron un total de 1,350 de grieta transversal alto, 850 de grieta transversal medio, 1350 transversal bajo, 1,400 de grieta longitudinal alto, 900 de grieta longitudinal medio, 1,250 de grieta longitudinal bajo, 600 de bache alto, 750 de bache medio y 1,300 de bache bajo, en total una cantidad de 9,750, con 5,414 para el conjunto de entrenamiento, 1,547 para el conjunto de validación y 774 para el conjunto de prueba. La Fig. 4 muestra la distribución de las etiquetas de fallas anotadas. Los datos etiquetados para las fallas se utilizaron para el entrenamiento, validación y test del modelo YOLOv11.




Figura 3 Etiquetas manuales en CVAT (Computer Vision Annotation Tool)

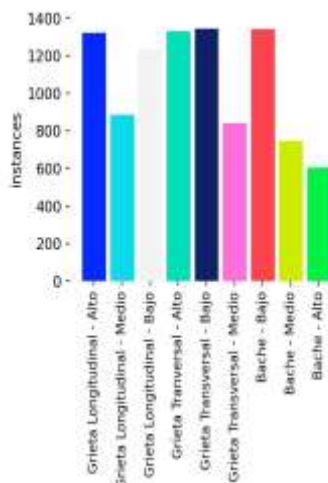


Figura 4 Distribución de las etiquetas de fallas anotadas

La recopilación de 7,735 imágenes digitales en el presente proyecto representa un aporte significativo frente a investigaciones previas sobre detección automatizada de fallas en pavimentos. A diferencia de trabajos como los de (Ukhwah, 2019) que empleó 448 imágenes capturadas con cámaras especializadas, o (Becker1, 2019) con 300 imágenes aéreas obtenidas mediante drones, este estudio destaca por el mayor volumen y diversidad del conjunto de datos, compuesto por grietas longitudinales, transversales y baches, clasificados en tres niveles de severidad (baja, media y alta). Frente a estudios como los de (Pei, 2022), que amplió su muestra a 3,704 imágenes mediante aumento de datos, o (Liu, 2022) que utilizó 2,211 imágenes visibles e infrarrojas procesadas con CNNs, este proyecto no solo supera en cantidad de datos, sino que además implementa una metodología replicable y de bajo costo, basada en cámaras móviles, cinta métrica y alambre galvanizado como escala visual.

3.3. Arquitectura del modelo de Yolov11

En este proyecto, utilizamos un modelo de detección basado en YOLOv11, una arquitectura mejorada que mantiene la eficiencia del enfoque YOLO pero incorpora optimizaciones internas para un procesamiento más preciso. El modelo incluye tres componentes fundamentales que contribuyen a su desempeño. En primer lugar, se empleó el backbone de YOLOv11, que mejora el procesamiento jerárquico de características a través de bloques eficientes de convolución y módulos como C3K2 (bloque de convolución compuesto con 3 capas y 2 convoluciones internas), SPPF (Spatial Pyramid Pooling Fast, que mejora la captura de contexto espacial) y C2PSA (Cross-Stage Partial Selective Attention, mecanismo de atención que resalta características relevantes), lo cual permite una extracción de características más detallada y precisa. En segundo lugar, se integró una red de fusión de características (neck) que permite combinar información a diferentes escalas mediante operaciones como upsample (reescalado de características a una resolución mayor), concat (concatenación de mapas de características) y convoluciones, mejorando así la capacidad del modelo para detectar objetos de distintos tamaños. Finalmente, se incorporó una cabeza de detección (head) optimizada, compuesta por tres salidas independientes que operan a diferentes escalas. Cada salida está diseñada para detectar objetos de distintos tamaños, asegurando un

equilibrio entre precisión y velocidad. Esta parte del modelo aplica directamente las predicciones de las clases, las coordenadas de los cuadros delimitadores (bounding boxes) y las puntuaciones de confianza, utilizando una estructura de convolución simple pero eficaz. Gracias a esta arquitectura modular, YOLOv11 conserva una estructura ligera y rápida, ideal para tareas de detección en tiempo real y entornos con recursos limitados.




Figura 5 Arquitectura de proceso de datos de YOLOv11

4. Resultados

4.1. Desempeño de YOLOv11 en la detección automática de fallas

La Fig. 6 presenta las curvas de entrenamiento del mAP50 para dos variantes del modelo YOLOv11, YOLOv11n y YOLOv11l, empleadas para la detección automática de fallas en pavimentos flexibles. YOLOv11n (nano) es una versión ligera con menos capas y parámetros, optimizada para velocidad y eficiencia en dispositivos con recursos limitados. Por su parte, YOLOv11l (large) posee una arquitectura más profunda y amplia, lo que le permite

captar patrones más complejos y alcanzar mayor precisión, aunque con mayor demanda computacional. Ambos modelos mostraron una rápida convergencia, estabilizando su rendimiento alrededor de las 250 épocas tras 500 épocas de entrenamiento, las precisiones generales de detección alcanzadas fueron de 72.5 % para YOLOv11n y 74 % para YOLOv11l.

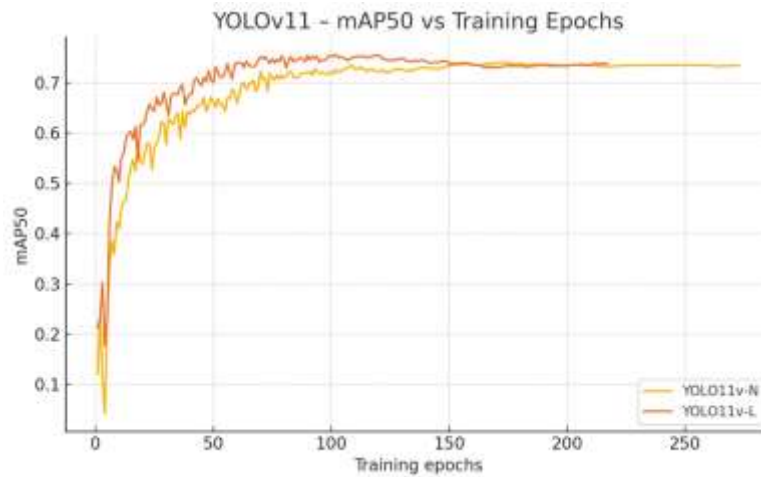


Figura 6 Curvas de entrenamiento de mAP50 de los modelos YOLOv11 para la detección de instancias de fallas en pavimentos flexibles

La Fig. 7 presenta la matriz de confusión correspondiente al conjunto de prueba, mostrando el desempeño de cada modelo en la detección de fallas, tales como grietas longitudinales, grietas transversales y baches. Las precisiones generales de detección alcanzaron 76 % para YOLOv11n y 78 % para YOLOv11l, lo que evidencia que el modelo de mayor capacidad, YOLOv11l, supera al modelo más ligero en términos de precisión y eficacia en la identificación de fallas.

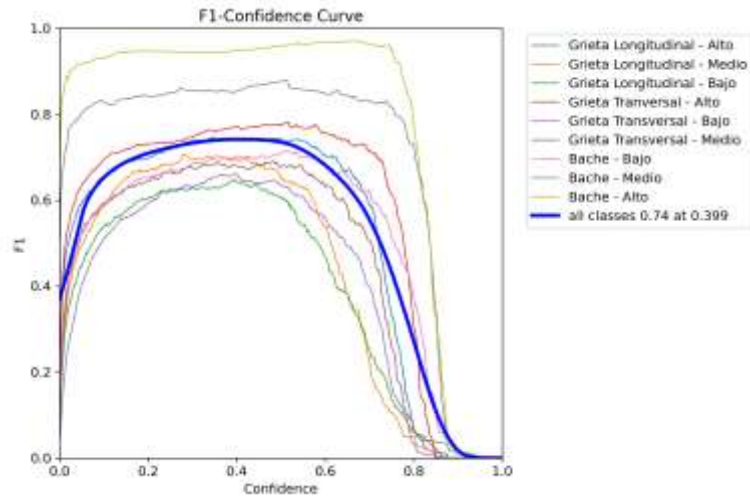
La Fig. 8 presenta los resultados de imágenes procesadas con la salida del modelo YOLOv11l aplicado. Las imágenes muestran las máscaras de instancia y las cajas delimitadoras generadas automáticamente, su clasificación según el tipo de falla superficial, el nivel de severidad correspondiente y la confianza asociada a cada detección. En este conjunto se incluyeron fallas como baches, grietas longitudinales y grietas transversales, clasificadas en los niveles de severidad bajo, medio y alto



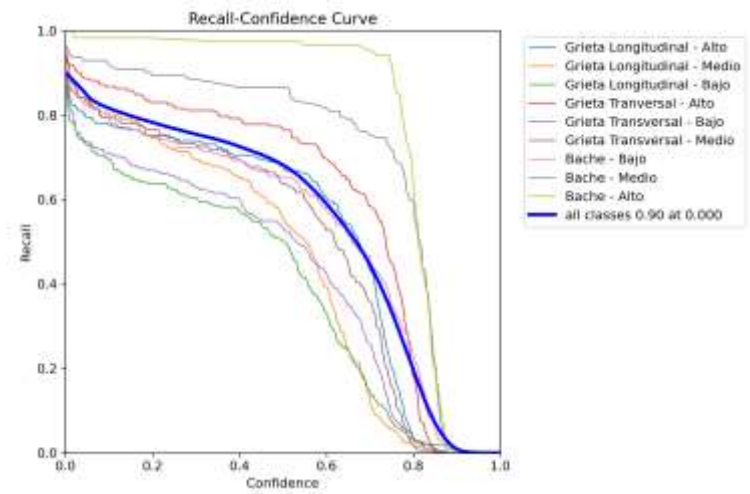
Figura 8 Resultados de imágenes procesadas correspondientes al conjunto de prueba, en las que se aplicó el modelo YOLOv11l.

4.1.1. Métricas de precisión (Precision), sensibilidad (Recall) y F1-Confidence (F1-score con umbral de confianza)

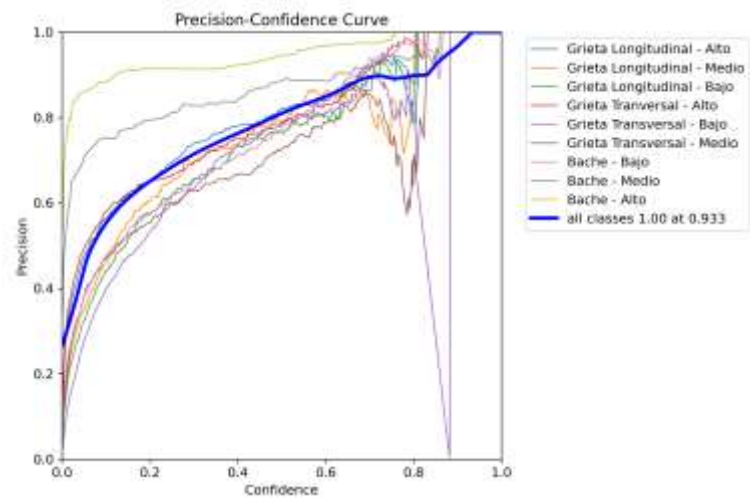
Dado que el modelo YOLOv11l fue seleccionado para el desarrollo final de este proyecto por su desempeño en tareas de detección, las siguientes métricas permiten evaluar su rendimiento específico en la detección automática de fallas en pavimentos flexibles. En la Fig. 9a, la curva F1-Confidence muestra la variación del F1-score respecto al umbral de confianza. El modelo alcanzó un F1-Confidence de 0.74 a un umbral óptimo de 0.399, con resultados destacados para clases como bache-alto (0.990) y grieta transversal-alto (0.828), evidenciando un buen balance entre precisión y sensibilidad en la clasificación de diferentes tipos y niveles de severidad. La Fig. 9b corresponde a la curva Recall-Confidence, donde se observa un Recall 0.90, lo cual indica una alta capacidad del modelo para detectar correctamente la mayoría de los casos reales presentes en los datos. Finalmente, en la Fig. 9c, la curva Precision-Confidence evidencia como la precisión de un 0.90 del modelo mejora al aumentar el umbral de confianza, lo cual permite minimizar las detecciones erróneas. En conjunto, estos resultados reflejan una capacidad sólida del modelo para realizar detecciones confiables y consistentes, aportando valor en entornos donde la identificación eficiente de fallas contribuye a una toma de decisiones más oportunas.



(a)



(b)



(c)

Figura 9 Desempeño del Modelo YOLOv11l: Curvas (a) F1-Confidenc, (b) Recall-Confidence y (c) Precision-Confidence

El modelo desarrollado con YOLOv11n y YOLOv11l obteniendo un mAP50 de 72.5 % y 74 % en detección de fallas y clasificación de severidad en pavimentos flexibles. Comparado con estudios previos, como (Ukhwah, 2019) o (Wang, 2022), que reportaron mAP superiores al 88 % en detección de baches. A pesar de resultados más altos en estudios específicos, este proyecto aborda una mayor complejidad, al clasificar tres tipos de fallas en tres niveles de severidad, demostrando que YOLOv11l es eficaz para detectar y clasificar fallas viales con severidad en entornos reales. Al comparar los resultados de métricas del modelo YOLOv11l con estudios previos, se observa un desempeño competitivo en distintas métricas clave. El F1-Confidence de 0.74 se sitúa por debajo del 0.865 alcanzado por el modelo YOLOv3 mejorado, según el estudio de (Wang, 2022). No obstante, al analizar la curva Recall-Confidence del modelo YOLOv11l, se evidencia una capacidad de detección del 0.90, comparado al recall total de 0.861 en el análisis de (Wang, 2022) y al recall promedio de 0.82 descrito por (Ukhwah, 2019), lo que indica una alta sensibilidad del modelo para identificar correctamente las fallas reales. Finalmente, la curva Precision-Confidence del YOLOv11l muestra una mejora progresiva en la precisión conforme aumenta el umbral de confianza, superando el 0.90; este comportamiento coincide con la precisión total de 0.869 registrada en (Wang, 2022) y la precisión promedio de 0.94 indicada por (Ukhwah, 2019). En conjunto, aunque algunos valores absolutos son ligeramente inferiores, el modelo YOLOv11l demuestra una solidez notable en métricas críticas, posicionándose como una alternativa para la detección automática de fallas en pavimentos flexibles.

Si bien se menciona YOLOv3 en nuestros antecedentes donde alcanza altos niveles de precisión, pero en escenarios controlados y sus limitaciones de YOLOv3 persisten en escenarios muy complejos y con la detección de objetos muy pequeños, su elevada demanda computacional limita su aplicabilidad práctica. En cambio, YOLOv11 ofrece innovaciones que demuestran una optimización en la extracción de características y la atención a objetos pequeños y de baja resolución, mayor velocidad en su rendimiento y eficiencia con menos recursos computacionales, lo que facilita su implementación en dispositivos.

Para mejorar los resultados de las métricas de este proyecto, se requiere el uso de un procesador gráfico (GPU) de alto rendimiento que sea mayor a 16GB, ya que este permite entrenar y validar modelos de detección automática con mayor eficiencia, procesar imágenes en alta resolución y optimizar los parámetros de aprendizaje. De esta manera, se incrementa la precisión y confiabilidad de las métricas obtenidas.

4.1.2. Análisis comparativo del método tradicional y método automatizado

Se realizó una prueba en un entorno real para evaluar el desempeño del método automatizado, desarrollado basada en el modelo YOLOv11, diseñada para la detección automatizada de fallas en pavimentos flexibles, específicamente grietas transversales, grietas longitudinales y baches, clasificadas según su severidad (bajo, medio y alto). En la Fig. 10 se presenta el plano del tramo de evaluación ubicado en el Jr. 7 de junio, donde se visualizan las fallas detectadas durante el método manual. En este tramo se comparó el método automatizado con el método manual, tanto en términos de tiempo como en capacidad de detección. En cuanto al tiempo de evaluación, la inspección manual tomó aproximadamente 2.59 horas, mientras que el método automatizado, que analiza imágenes individuales, requirió entre 5 y 10 segundos

por imagen. Esto representó un tiempo total estimado de 0.44 horas para procesar el mismo tramo.




Figura 10 Plano del tramo de evaluación

Tabla 1
Comparativa de ambos métodos en la detección de fallas

	GL-Bajo	GL-Medio	GL-Alto	GT-Bajo	GT-Medio	GT-Alto	HUE-Bajo	HUE-Medio	HUE-Alto
M. Manual	1	1	30	0	2	73	17	15	22
M. Automatizado	0	1	30	0	2	72	16	11	22
Método A. Error	0	1	0	0	1	0	3	1	1

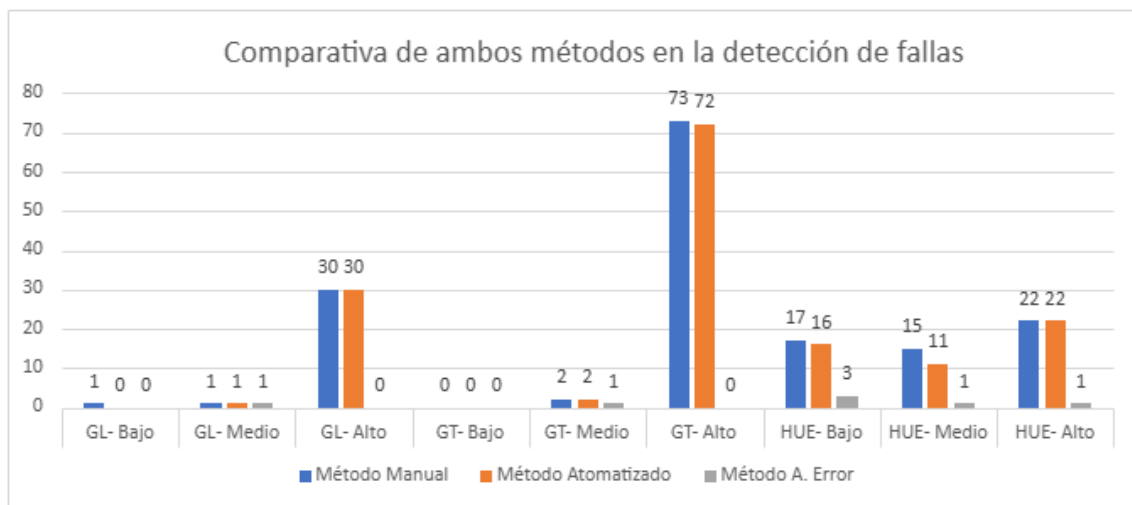


Figura 11 Gráfico de representación de resultados en ambos métodos

Los resultados del método fueron comparados con el método manual considerada como estándar de referencia (100 % de acierto). El método automatizado alcanzó un 95.6 % en la detección del tipo de falla y su severidad, como se muestra en la Tabla 1 y se representa gráficamente en la Fig. 11. Se observaron 7 desaciertos en un total de 161 fallas detectadas y evaluadas en el tramo previamente mencionado. Para evaluar la concordancia entre ambos métodos, se utilizó la estadística Kappa de Cohen ponderada, obteniéndose valores en grieta longitudinal $\kappa_w = 0.85$, grieta transversal $\kappa_w = 0.79$ y en bache $\kappa_w = 0.95$, lo que indica un nivel de acuerdo "muy bueno" entre el método manual y el método automatizado. Estos resultados demuestran que el modelo YOLOv11, adaptado al contexto vial, puede ser una herramienta confiable y eficiente para el monitoreo automatizado de pavimentos flexibles en tiempo real.

Tabla 2

Matriz de confusión ponderada entre el método manual y el automatizado para la clasificación de grieta longitudinal

Evaludador A/B	B	M	A	Total
B	0	1	0	1
M	0	1	0	1
A	0	0	30	30
Total	0	2	30	32

Tabla 3

Matriz de confusión ponderada entre el método manual y el automatizado para la clasificación de grieta transversal

Evaludador A/B	B	M	A	Total
B	0	0	0	0
M	0	2	0	2
A	0	1	72	73
Total	0	3	72	75

Tabla 4

Matriz de confusión ponderada entre el método manual y el automatizado para la clasificación de baches

Evaludador A/B	B	M	A	Total
B	16	1	0	17
M	3	11	1	15
A	0	0	22	22
Total	19	12	23	54

Las Tablas 2, 3 y 4 presentan las matrices de confusión ponderadas que comparan los resultados obtenidos mediante el método manual y el método automatizado en la clasificación de grietas longitudinales, grietas transversales y baches, respectivamente, considerando los niveles de severidad bajo (B), medio (M) y alto (A). En la Tabla 2, correspondiente a grietas longitudinales, se observa una concordancia total en la categoría de severidad alta, mientras que en los niveles bajo y medio se presentan discrepancias entre ambos métodos. La Tabla 3, que muestra los resultados para grietas transversales, evidencia también una alta coincidencia en la categoría de severidad alta, aunque se registran diferencias en las categorías media y baja. Por otro lado, la Tabla 4, relacionada con la detección de baches, refleja una distribución más equilibrada, con coincidencias significativas en los tres niveles de severidad.

Esta ec.1 calcula el grado de acuerdo entre dos evaluadores (métodos), considerando el desacuerdo parcial entre categorías. El resultado se ajusta por el acuerdo esperado por azar. Un valor de κ cercano a 1 indica un alto nivel de concordancia, mientras que valores cercanos a 0 sugieren acuerdo al azar. Se utiliza una matriz de pesos w_{ij} para penalizar los desacuerdos según su magnitud.

$$\kappa_w = 1 - \frac{\sum w_{ij} \cdot o_{ij}}{\sum w_{ij} \cdot e_{ij}} \quad (1)$$

La ponderación cuadrática ec. 2, se basa en la fórmula que permite asignar penalizaciones que crecen de forma exponencial según el grado de desacuerdo entre categorías. Así, cuanto más alejadas estén las clasificaciones entre los evaluadores, mayor será el peso del error en el cálculo del Kappa ponderado.

$$w_{ij} = \left(\frac{i-j}{k-1}\right)^2 \quad (2)$$

Las proporciones observadas y esperadas, utilizadas en el cálculo del coeficiente Kappa ponderado, se definen en las ec. 3 y 4. La proporción observada o_{ij} ec. 3, se obtiene al dividir la frecuencia observada en la celda (i,j) de la matriz de confusión por el total de observaciones, reflejando el acuerdo real entre los evaluadores. Por otro lado, la proporción esperada e_{ij} ec. 4, representa el acuerdo que se esperaría por azar si no existiera relación entre los evaluadores, y se calcula a partir del producto de los totales marginales de la fila i y la columna j, dividido entre el cuadrado del total de observaciones.

$$o_{ij} = \frac{f_{ij}}{N} \quad (3)$$

$$e_{ij} = \frac{f_i \cdot f_j}{N^2} \quad (4)$$

Fig. 12 representa los resultados del coeficiente Kappa de Cohen ponderado k_w obtenidos al comparar el método manual con el método automatizado muestran distintos niveles de concordancia según el tipo de falla evaluada. Para grietas longitudinales se obtuvo un valor de $k_w = 0.85$, lo que indica una concordancia muy buena. En el caso de las grietas transversales, el resultado fue $k_w = 0.79$, correspondiente a una buena concordancia. Finalmente, para la clasificación de baches se alcanzó un $k_w = 0.95$, reflejando una concordancia muy buena entre ambos métodos. Estos valores fueron calculados a partir de la fórmula general del Kappa de Cohen ponderado ec. 1, usando las proporciones observadas ec. 3 y esperadas ec.4, junto con una matriz de pesos obtenida mediante la ponderación cuadrática ec. 2, que penaliza más severamente los desacuerdos entre categorías más distantes.





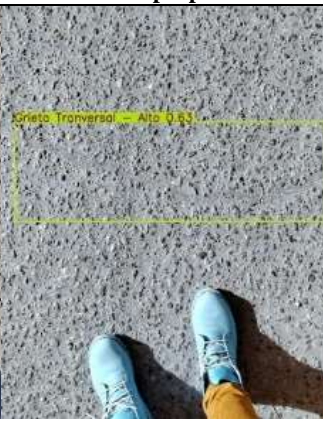










Figura 12 Gráfico de representación de resultados de Kappa de cohen ponderado

Cabe resaltar que esta estadística no fue utilizada en las fuentes de referencia consideradas en este proyecto. A diferencia de nuestro enfoque, los trabajos revisados no realizaron pruebas estadísticas formales para medir el grado de acuerdo entre métodos o la validez de sus clasificaciones. En este proyecto aplicamos esta prueba con el propósito de evaluar la efectividad del método automatizado frente al método manual en un entorno real, permitiendo cuantificar el grado de coincidencia en la clasificación de fallas según su severidad, lo cual aporta una perspectiva más precisa sobre la viabilidad de su uso práctico. En este sentido, los valores obtenidos de k_w respaldan la efectividad del método automatizado, ya que reflejan un nivel aceptable de concordancia en todas las clases evaluadas. Esto refuerza

la confiabilidad del método automatizado propuesto para apoyar tareas de inspección vial, especialmente en condiciones reales donde se requiere eficiencia.

Tabla 5

Resultado de detección de fallas en el Jr. 7 de junio mediante el método automatizado

Imágenes originales	Resultado de detección del método propuesto	Imágenes originales	Resultado de detección del método propuesto
			
			
			



La Tabla 5. presenta una muestra representativa del desempeño del método automatizado propuesto para la detección automática de fallas en pavimentos flexibles. En las columnas 1 y 3 se observan imágenes originales del tramo evaluado, mientras que en las columnas 2 y 4 se muestran los resultados generados por el método automatizado. Se evidencia que el método logra detectar correctamente distintos tipos de fallas, como baches, grietas longitudinales y grietas transversales, incluyendo su clasificación de niveles de severidad. No obstante, en la primera fila, cuarta columna, se aprecia un caso de clasificación errónea, donde una grieta longitudinal de severidad baja fue confundida con una de severidad media. A pesar de este error puntual, en la misma imagen se puede ver una grieta longitudinal de severidad media correctamente detectada.

- **Limitaciones para la aplicación del método automatizado.**

- Cobertura limitada de tipos de falla**

El método solo detecta baches, grietas longitudinales y grietas transversales según la Tabla 4-8 del MTC. No identifica fallas más complejas como piel de cocodrilo, ahuellamiento, desprendimientos o deformaciones. Esta limitación reduce su capacidad para evaluar de manera integral el estado del pavimento.

- Estimación parcial de severidad**

La severidad se determina únicamente mediante el diámetro (baches) y el ancho (grietas). La ausencia de parámetros como profundidad, longitud real o extensión del deterioro produce una clasificación incompleta y puede subestimar el nivel real de daño.

- No analiza la evolución del deterioro**

El método evalúa el estado superficial del pavimento y no incorpora la progresión del daño bajo cargas repetidas, condiciones ambientales o fatiga del pavimento. Por ello, no permite predecir cómo evolucionará el deterioro con el tiempo.

- Integración limitada en Sistemas de Gestión de Pavimentos (SGP)**

Al no incluir una variedad más amplia de fallas ni métricas estructurales adicionales, el método aún no puede incorporarse directamente en un SGP. Para ello, requiere ampliar su base de fallas detectables y estandarizar nuevas métricas de evaluación.

- Dependencia de condiciones específicas de captura**

El rendimiento del método depende de factores operativos como:

- **Altura fija de captura (1 metro):** Variaciones en la distancia afectan la escala de la imagen y disminuyen la precisión.
- **Condiciones de iluminación:** Se observan problemas bajo la radiación solar del medio día, sombras intensas y reflejos.
- **Limitaciones relacionadas con el hardware:** Las imágenes fueron capturadas con dispositivos móviles de gama media (Samsung A32) y gama media–alta (Honor 70). Si bien ambos equipos ofrecen buena resolución, su capacidad de detalle es menor a la de dispositivos de gama alta o cámaras profesionales, lo que puede influir en la clasificación de fallas con severidad baja.

vi. Necesidad de validación en más escenarios

El método fue evaluado en un entorno controlado y de alcance limitado. Aún requiere validación en tramos más extensos, diversos climas y niveles de tráfico.

5. Conclusión

Se implementó un método automatizado eficiente para la detección del tipo de fallas y su severidad en pavimentos flexibles mediante el procesamiento de imágenes, utilizando el modelo YOLOv111 desarrollado en lenguaje Python. Se logró identificar baches, grietas longitudinales y grietas transversales de acuerdo con los estándares establecidos en el Manual del MTC. Este proceso fue clave para la recopilación de muestras y la garantía de que los criterios de clasificación se ajusten a lo dispuesto por la normativa. Se desarrolló un método automatizado el cual alcanzó un desempeño destacado con una Precisión de 0.90, un F1-Confidence de 0.74 y un Recall cercano al 0.90. El método automatizado logró identificar baches, grietas longitudinales y grietas transversales, clasificándolos por niveles de severidad (bajo, medio y alto) conforme a los criterios establecidos en el Manual del MTC. Se evaluó la efectividad del método en un tramo urbano de medio kilómetro en el Jr. 7 de Junio. El método alcanzó un 95.6 % de efectividad en la detección y clasificación de fallas, con tiempos de procesamiento de 5 a 10 segundos por imagen y un costo del servicio en la nube de 1 dólar/hora, resultando accesible y fácil de usar. La concordancia entre el método automatizado y el manual fue medida mediante el coeficiente Kappa de Cohen ponderado, obteniéndose $\kappa_w = 0.85$ para grietas longitudinales, $\kappa_w = 0.79$ para grietas transversales y $\kappa_w = 0.95$ para baches, lo que evidencia un alto grado de confiabilidad en condición real.

Este proyecto constituye un aporte relevante en el campo de la automatización de la gestión vial mediante técnicas de procesamiento de imágenes, fomentando el desarrollo de métodos automatizados aplicados a la inspección de pavimentos flexibles para mantenimientos rutinarios. Su principal aporte radica en la detección simultánea de tres tipos de fallas bache, grieta longitudinal y grieta transversal e incorporación de su clasificación por severidad bajo criterios del MTC, lo que no había sido abordado en los antecedentes revisados y representa un avance significativo aplicado en condición real.

Para obtener resultados óptimos, se recomienda realizar las capturas fotográficas durante la mañana o la tarde, evitando el mediodía por los reflejos y sombras que dificultan la detección de fallas. Asimismo, se sugiere a futuras investigaciones ampliar el enfoque hacia un mayor número de fallas y su severidad, con el propósito de entrenar modelos más robustos que incrementen la precisión y la cobertura en la gestión vial.

Declaración

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

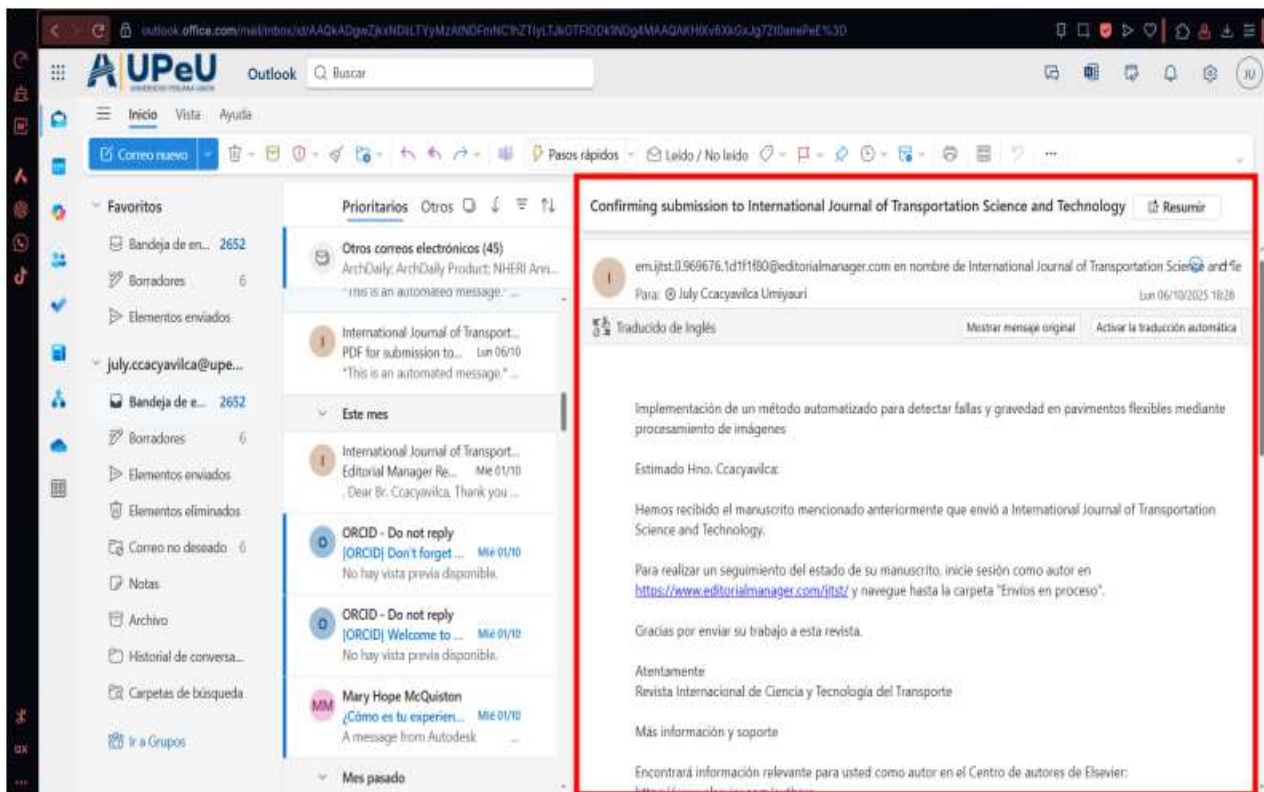
6. Referencias

- Bardales, A., & Salomón, J. (2017). EVALUACIÓN DEL PAVIMENTO MEDIANTE EL MÉTODO PAVEMENT CONDITION INDEX EN UN SISTEMA DE FORMACIÓN GEOGRÁFICA PARA CALCULAR COSTOS DE MANTENIMIENTO. CASO AVENIDA LOS CONSTRUCTORES – LA MOLINA. Perú.
- Bravo, R., & Arévalo, C. (2023). Aplicación de un sistema de gestión de pavimentos (SGP) con datos automatizados por medio del aplicativo TotalPave, bajo el uso del índice de rugosidad (IRI) y el índice de condición del pavimento (PCI) para la determinación del estado situacional actual. Lima- Perú.
- Carlessi, H. S., & Meza, C. R. (2015). Metodología y diseño en la investigación científica (Quinta Edición). Lima: Impreso en Business Support Aneth SRL.
- Hernández Sampieri, C. R. (2014). METODOLOGÍA DE LA INVESTIGACIÓN. Mexico: McGRAW - HILL INTERAMERICANA DE MÉXICO, S.A. de C.V.
- Landis, J. R., & Koch, G. G. (1997). The Measurement of Observer Agreement for Categorical Data. International Biometric Society, 159-174.
- León, V., & Alejandra, C. (2021). Identificación de fallas más frecuentes e índice de condición de los pavimentos flexibles, a partir de investigaciones realizadas en el Perú-Cajamarca 2021. Cajamarca.
- MTC, M. d. (2018). Manual de Carreteras Mantenimiento o Conservación Vial- Incorporación de Parte IV RD N° 05- 2016-MTC/2014. Lima.
- Soto, I., & Robustiano, P. (2022). IDENTIFICACIÓN AUTOMÁTICA DE LAS GRIETAS EN PISTAS DE ASFALTO UTILIZANDO PROCESAMIENTO DIGITAL DE IMÁGENES. Pimentel, Perú.
- Szklo, M., & Nieto, F. J. (2003). Epidemiology. Beyond the basics- Third edition.
- Becker¹, Y. V. F., Siqueira¹, H. L., Matsubara², E. T., Gonçalves², W. N., & Marcato, J. (2019). Asphalt pothole detection in uav images using convolutional neural networks. International Geoscience and Remote Sensing Symposium (IGARSS), 2019-July. <https://doi.org/10.1109/IGARSS.2019.8900621>
- Dhakal, N., Elseifi, M. A., Zihan, Z. U. A., Zhang, Z., Fillastre, C. N., & Upadhyay, J. (2022). Classification of surface pavement cracks as top-down, bottom-up, and cement-treated reflective cracking based on deep learning methods. Canadian Journal of Civil Engineering, 49(4). <https://doi.org/10.1139/cjce-2020-0808>
- Liu, F., Liu, J., & Wang, L. (2022). Asphalt pavement fatigue crack severity classification by infrared thermography and deep learning. Automation in Construction, 143. <https://doi.org/10.1016/j.autcon.2022.104575>

- Obunguta, F., Matsushima, K., & Susaki, J. (2024). PROBABILISTIC MANAGEMENT OF PAVEMENT DEFECTS WITH IMAGE PROCESSING TECHNIQUES. *Journal of Civil Engineering and Management*, 30(2). <https://doi.org/10.3846/jcem.2024.20401>
- Pei, L., Shi, L., Sun, Z., Li, W., Gao, Y., & Chen, Y. (2022). Detecting potholes in asphalt pavement under small-sample conditions based on improved faster region-based convolution neural networks. *Canadian Journal of Civil Engineering*, 49(2). <https://doi.org/10.1139/cjce-2020-0764>
- Sathya, R., & Saleena, B. (2022). A Framework for Designing Unsupervised Pothole Detection by Integrating Feature Extraction Using Deep Recurrent Neural Network. *Wireless Personal Communications*, 126(2). <https://doi.org/10.1007/s11277-022-09790-z>
- Tayo, C. O., Linsangan, N. B., & Pellegrino, R. V. (2019). Portable Crack Width Calculation of Concrete Road Pavement Using Machine Vision. 2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management, HNICEM 2019. <https://doi.org/10.1109/HNICEM48295.2019.9072731>
- Ukhwah, E. N., Yuniarno, E. M., & Suprpto, Y. K. (2019). Asphalt Pavement Pothole Detection using Deep learning method based on YOLO Neural Network. *Proceedings - 2019 International Seminar on Intelligent Technology and Its Application, ISITIA 2019*. <https://doi.org/10.1109/ISITIA.2019.8937176>
- Wang, D., Liu, Z., Gu, X., Wu, W., Chen, Y., & Wang, L. (2022). Automatic Detection of Pothole Distress in Asphalt Pavement Using Improved Convolutional Neural Networks. *Remote Sensing*, 14(16). <https://doi.org/10.3390/rs14163892>
- Xu, J., & Yu, X. (2023). Pavement Roughness Grade Recognition Based on One-dimensional Residual Convolutional Neural Network. *Sensors*, 23(4). <https://doi.org/10.3390/s23042271>

7. Anexos

7.1. Evidencia de sumisión



7.2. Copia de la resolución de inscripción del perfil de proyecto de tesis en formato artículo aprobado por el consejo de facultad correspondiente



"AÑO DE LA RECUPERACIÓN Y CONSOLIDACIÓN DE LA ECONOMÍA PERUANA"

RESOLUCIÓN N° 0151-2025/UPeU-FIA-CF-T

Lima, Naña 15 de abril de 2025

VISTO:

El expediente de **Natalia Martina Manchay Huancas**, identificado(a) con Código Universitario N° 201811986 y **July Ariday Ccacyavilca Umiyauri** identificado(a) con Código Universitario N° 201811982, de la Escuela Profesional de Ingeniería Civil de la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión;

CONSIDERANDO

Que la Universidad Peruana Unión tiene autonomía académica, administrativa y normativa, dentro del ámbito establecido por la Ley Universitaria N° 30220 y el Estatuto de la Universidad;

Que la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión, mediante sus reglamentos académicos y administrativos, ha establecido las formas y procedimientos para la aprobación e inscripción del perfil de proyecto de tesis en formato artículo y la designación o nombramiento del asesor para la obtención del título profesional;

Que **Natalia Martina Manchay Huancas** y **July Ariday Ccacyavilca Umiyauri**, han solicitado: la inscripción del perfil de proyecto de tesis titulado "Implementación de un método automatizado para detectar fallas y severidad en pavimentos flexibles mediante procesamiento de imágenes" y la designación del Asesor, encargado de orientar y asesorar la ejecución del perfil de proyecto de tesis en formato artículo;

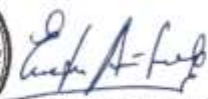
Estando a lo acordado en la sesión del Consejo de la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión, celebrada el 15 de abril de 2025, y en aplicación del Estatuto y el Reglamento General de Investigación de la Universidad;

SE RESUELVE:

Aprobar el perfil de proyecto de tesis en formato artículo titulado "**Implementación de un método automatizado para detectar fallas y severidad en pavimentos flexibles mediante procesamiento de imágenes**" y disponer su inscripción en el registro correspondiente, designar al **Mg. Edwin Parillo Escarsena** como ASESOR para que oriente y asesore la ejecución del perfil de proyecto de tesis en formato artículo el cual fue dictaminado por el **Mg. Herson Duberly Pari Cusi** y el **MSc. Ecler Mamani Chambí**, otorgándoles un plazo máximo de doce (12) meses para la ejecución.

Regístrese, comuníquese y archívese.




Dra. Erika Inés Acuña Salinas
DECANA





Ph.D. Silvia Pilco Quesada
SECRETARIA ACADÉMICA

cc
-Asesorado
-Asesor
-Dirección General de Investigación
-Archivo

7.3. Fichas de evaluación

A UPeU		DETECCION DE FALLAS PAVIMENTO FLEXIBLE CARPETA ASFALTICA				
Evaluado por:	Cecyavilca Umiyawa Jely Andaz - Manchay Huarcas Natalia					
Nombre de la vía:	Tr. 7 de Junio					
Fecha:	19 de Junio					
FALLAS EN PAVIMENTO FLEXIBLE						
N°	Tipo de fallas	Severidad			Cod	
1	Huecos (Bacheo)	Bajo	Medio	Alto	HUE	
2	Grieta longitudinal				GL	
3	Grieta transversal				GT	
N°	Progresiva	Tipo de falla	Severidad			Observación
			Bajo	Medio	Alto	
1	0+000	GT			X	4cm
2		HUE		X		21cm
3		HUE	X			18cm
4		HUE	X			10cm
5		HUE	X			8cm
6		HUE	X			14cm
7		HUE		X		36cm
8		HUE			X	50cm
9		HUE		X		37cm
10		HUE		X		40cm
11		GT			X	2cm
12		HUE			X	55cm
13		HUE		X		30cm
14		HUE		X		32cm
15		HUE		X		38cm
16		GT			X	4cm
17		HUE	X			18cm
18		GL			X	1cm
19		HUE	X			14cm
20		GT			X	4cm
21		GT			X	2cm
22		GT			X	4cm
23		GL			X	2cm
24		GT			X	3cm
25		GT			X	4cm
26		GT			X	4cm
27		GL			X	35cm
28		GT			X	2cm
29		HUE			X	130cm
30		GL			X	3cm
31		GT			X	3cm
32		GT			X	4cm
33		GL			X	3cm
34		HUE			X	60cm
35		GT			X	4cm
36		GT		X		2mm
37		GT			X	4cm
38	0+111	GT			X	5cm
39		HUE	X			18cm
40		HUE			X	135cm
41		HUE			X	60cm

	DETECCION DE FALLAS PAVIMENTO FLEXIBLE CARPETA ASFALTICA	
	Evaluado por: <i>Cecayavita Ursula Joly Andez - Manchoz Heorosa Natalia</i>	
	Nombre de la via: <i>Jr. 7 de Junio</i>	
Fecha: <i>19 de Junio</i>		FALLAS EN PAVIMENTO FLEXIBLE

N°	Tipo de fallas	Cod
1	Huecos (Bacheo)	HUE
2	Grieta longitudinal	GL
3	Grieta transversal	GT


N°	Progresiva	Tipo de falla	Severidad			Observacion
			Bajo	Medio	Alto	
42		HUE		x		40cm
43		GL			x	3cm
44		GT			x	2cm
45		GT			x	3cm
46		GT			x	4cm
47		GT			x	2cm
48		GT			x	1cm
49		GT			x	3cm
50		GT			x	3cm
51		GT			x	3cm
52		GT			x	4cm
53		GT			x	3cm
54		GT			x	3cm
55		HUE			x	31cm
56		HUE			x	90cm
57		HUE			x	121cm
58		GT			x	2cm
59		GT			x	2cm
60		HUE	x			15cm
61		GT			x	3cm
62		HUE			x	70cm
63		HUE			x	82cm
64		HUE			x	112cm
65		HUE			x	114cm
66		HUE			x	94cm
67		HUE		x		30cm
68		HUE		x		28cm
69		HUE	x			17cm
70		HUE		x		35cm
71		HUE		x		21cm
72		HUE	x			19cm
73	0+198	HUE	x			17cm
74		GL			x	3cm
75		GT			x	2cm
76		GL			x	2cm
77		GT			x	3cm
78		GT			x	2cm
79		HUE			x	118cm
80		GL			x	2cm
81		GT			x	3cm
82		GT			x	4cm

A UPEU UNIVERSIDAD PERUANA DE EDUCACIÓN UNIVERSITARIA	DETECCIÓN DE FALLAS PAVIMENTO: FLEXIBLE, CARPETA ASFALTICA
Evaluado por:	Concepcion Umigawa July Arcoy - Mercedes Huarcas Nolasco
Nombre de la vía:	Jr. 7 de Julio
Fecha:	19 de Junio

FALLAS EN PAVIMENTO FLEXIBLE

N°	Tipo de fallas	Cod.
1	Huecos (Bacheo)	HUE
2	Grieta longitudinal	GL
3	Grieta transversal	GT

N°	Progresiva	Tipo de falla	Severidad			Observación
			Bajo	Medio	Alto	
83		GT			X	5cm
84		HUE			X	120cm
85		HUE		X		31cm
86		GL			X	5cm
87		HUE			X	54cm
88	0+278	HUE		X		40cm
89		GL			X	4cm
90		GL			X	4cm
91		GL			X	3cm
92		GL			X	3cm
93		GT			X	3cm
94		GT			X	3cm
95		GT			X	5cm
96		GT			X	5cm
97		GT			X	4cm
98		GT			X	2cm
99		GL			X	5cm
100		GT			X	15cm
101	0+370	HUE			X	52cm
102		HUE			X	65cm
103		GT		X		2cm
104		HUE		X		45cm
105		GT			X	1cm
106		GL			X	4cm
107		HUE	X			12cm
108		GT			X	2.5cm
109		GL			X	2cm
110		GT			X	1.5cm
111		HUE	X			16cm
112		GT			X	2cm
113		GL			X	3cm
114		GT			X	2.5cm
115		GL			X	3cm
116		GT			X	2.5cm
117		GL			X	2cm
118		GT			X	2cm
119		GL			X	3cm
120		GT			X	2.5cm
121		GT			X	2cm
122		GL			X	2cm
123		HUE	X			15cm

	DETECCION DE FALLAS	
	PAVIMENTO FLEXIBLE CARPETA ASFALTICA	
	Carrizavita Vinayavi July Anday - Hanchay Huancay Natukia	
Evaluado por:	Dr. 7 de Agosto	
Nombre de la vía:	19 de Agosto	
Fecha:		


FALLAS EN PAVIMENTO FLEXIBLE		
N°	Tipo de fallas	Cod.
1	Huecos (Bacheo)	HUE
2	Grieta longitudinal	GL
3	Grieta transversal	GT

N°	Progresiva	Tipo de falla	Severidad			Observación
			Bajo	Medio	Alto	
124		GL			X	3cm
125		GL			X	3cm
126		GT			X	1cm
127		GT			X	1cm
128		GT			X	2cm
129		HUE	X			13cm
130		GT			X	2.5cm
131		GT			X	2cm
132		GL		X	X	3cm
133		GL		X		2mm
134		GL	X			1mm
135		GL			X	3cm
136		GT			X	3cm
137		GT			X	2cm
138		GT			X	3cm
139		GT			X	3.5cm
140		GL			X	2.5cm
141		GT			X	2.5cm
142		GT			X	3cm
143		GL			X	2cm
144		GT		X		48cm
145		HUE		X		3cm
146		GT			X	1.5cm
147		HUE	X			3cm
148		GT			X	2cm
149		GT			X	2cm
150		GT			X	1.5cm
151		GL			X	2cm
152		HUE	X			17cm
153		GT			X	1cm
154		HUE			X	6.2cm
155		GT			X	1.5cm
156		GL			X	3cm
157		HUE			X	8.5cm
158		GT			X	3cm
159		GT			X	1cm
160		GT			X	2cm
161	0+530	GT			X	
162						
163						
164						

7.4. Demostración del método automatizado

Detección de fallas y severidad

Subir imagenes a detectar.



Upload Image

Confidence threshold 0.25

IoU threshold 0.45

Clear Submit

This screenshot shows the initial upload stage of the application. A photograph of a pothole on a paved surface is displayed in a window titled 'Upload Image'. Below the image, there are two sliders for 'Confidence threshold' (set to 0.25) and 'IoU threshold' (set to 0.45). At the bottom, there are 'Clear' and 'Submit' buttons.



Result

Boche - Alto 0.82

Share via Link

Construido con Gradio - Configuración

This screenshot shows the application's output. The same pothole image is shown in a window titled 'Result', now with a green bounding box around the pothole. The label 'Boche - Alto 0.82' is displayed in green text above the box. Below the image is a 'Share via Link' button. At the very bottom, there is a footer that reads 'Construido con Gradio - Configuración'.