



Tesis de maestría: *Análisis de la utilidad de la Inteligencia Artificial para identificar daños en la infraestructura vial en el contexto colombiano*. Autor: Sara Inés Alvarado Carvajal. Universidad Santo Tomás (Colombia). Año: 2025

Análisis de la utilidad de la Inteligencia Artificial para identificar daños en la infraestructura vial en el contexto colombiano

Sara Inés Alvarado Carvajal

Universidad Santo Tomás
Facultad de Ingeniería Civil
Bogotá, Colombia
2025



Tesis de maestría: *Análisis de la utilidad de la Inteligencia Artificial para identificar daños en la infraestructura vial en el contexto colombiano*. Autor: Sara Inés Alvarado Carvajal. Universidad Santo Tomás (Colombia). Año: 2025

Análisis de la utilidad de la Inteligencia Artificial para identificar daños en la infraestructura vial en el contexto colombiano

Sara Inés Alvarado Carvajal

Tesis presentada como requisito para optar al título de:
Magister en Infraestructura Vial

Director:

Ph.D. Carlos Alberto González Camargo

Universidad Santo Tomás
Facultad de Ingeniería Civil
Bogotá, Colombia
2025

Agradecimiento

En primer lugar, agradezco a Dios, por brindarme la vida, la salud y la oportunidad de iniciar y culminar mis estudios en esta prestigiosa universidad.

A mis hijos, María Paula y Nicolai, les expreso mi más profundo agradecimiento por su paciencia, amor y comprensión a lo largo de este proceso. Ellos fueron el pilar fundamental para alcanzar esta meta. Su apoyo emocional y la generosidad al compartir su tiempo conmigo hicieron posible la culminación de este trabajo. Este logro también les pertenece.

Un agradecimiento especial al Ingeniero Carlos Alberto González Camargo, director de este trabajo de grado, por su acompañamiento constante, su orientación académica y su apoyo incondicional en cada etapa del proceso. Su experiencia, compromiso y dedicación fueron determinantes para el desarrollo exitoso de esta investigación.

De igual manera, extiendo mi más sincero agradecimiento a los Ph.D. Miguel Castilla-Barbosa y Jesús David García Quintero, cuya retroalimentación oportuna, rigurosa y constructiva fortaleció el enfoque y la calidad de este trabajo académico.

Así mismo, agradezco a todas las personas e instituciones que, de una u otra forma, contribuyeron con su conocimiento, tiempo o respaldo a la realización de esta investigación.

Análisis de la Utilidad de la Inteligencia Artificial para Identificar Daños en la Infraestructura Vial en el Contexto Colombiano

Resumen

Esta tesis examina el uso de la inteligencia artificial (IA) para la detección de daños en infraestructuras viales en Colombia, con el objetivo de evaluar la efectividad de la IA en el mantenimiento y gestión de las carreteras del país. Para lograr esto, se emplearon métodos como la revisión de literatura, el análisis de contexto colombiano la comparación de hallazgos globales, y el análisis de costo-beneficio, con recomendaciones estratégicas específicas. Los resultados revelaron que la IA, especialmente a través de redes neuronales y tecnologías de visión computacional, puede mejorar significativamente la precisión y eficiencia en la identificación de daños en pavimentos, superando las limitaciones de los métodos tradicionales, como las inspecciones visuales. Estos hallazgos son significativos porque indican que la implementación de IA podría transformar la gestión vial en Colombia, optimizando recursos, reduciendo costos operativos y mejorando la seguridad vial. Finalmente, se concluye que la integración de la IA en la intervención vial es factible y tiene una gran habilidad, especialmente en la detección temprana de daños y la optimización de la asignación de recursos. Estos resultados tienen implicaciones para la formulación de políticas públicas y el mantenimiento de la infraestructura vial en Colombia, destacando la necesidad de capacitación y adaptación tecnológica, así como de un marco regulatorio adecuado para garantizar el éxito de esta implementación.

Palabras clave: Redes Neuronales Artificiales (RNA), Clasificación de daños en pavimentos, Algoritmos Genéticos (GA), LiDAR (Light Detection and Ranging), Convolutional Neural Networks (CNN), Detección automática de daños.

Analysis of the Usefulness of Artificial Intelligence for Identifying Road Infrastructure Damage in the Colombian Context

Abstract

This thesis examines the use of artificial intelligence (AI) for damage detection in road infrastructure in Colombia, with the aim of evaluating the effectiveness of AI in the maintenance and management of the country's roads. To achieve this, methods such as literature review, analysis of the Colombian context, comparison of global findings, and cost-benefit analysis with specific strategic recommendations were employed. The results revealed that AI, particularly through neural networks and computer vision technologies, can significantly improve the accuracy and efficiency of damage identification in pavements, overcoming the limitations of traditional methods such as visual inspections. These findings are significant because they indicate that the implementation of AI could transform road management in Colombia, optimizing resources, reducing operational costs, and improving road safety. Finally, it is concluded that the integration of AI in road interventions is feasible and highly promising, especially in the early detection of damage and the optimization of resource allocation. These results have implications for public policy formulation and road infrastructure maintenance in Colombia, highlighting the need for training and technological adaptation, as well as a suitable regulatory framework to ensure the success of this implementation.

Keywords: Artificial Neural Networks (ANN), Pavement damage classification, Genetic Algorithms (GA), LiDAR (Light Detection and Ranging), Convolutional Neural Networks (CNN), Automatic damage detection

Índice

	Pág.
1. INTRODUCCIÓN.....	1
2. JUSTIFICACIÓN.....	3
3. OBJETIVOS.....	6
3.1 Objetivo general	6
3.2 Objetivos específicos	6
4. MARCO DE REFERENCIA	7
4.1 Revisión de la literatura aplicaciones de IA en la detección de daños en infraestructura vial.....	7
4.1.1 Selección de estudios y artículos relevantes.....	7
4.1.2 Síntesis de enfoques tecnológicos y operativos	12
4.1.5 Caracterización visual de daños viales mediante IA	16
4.2 Marco teórico.....	19
4.2.1. La infraestructura vial como eje del desarrollo socioeconómico	19
4.2.2. Métodos tradicionales de inspección y su persistencia en América Latina.....	19
4.2.3. Inteligencia artificial y su aplicación emergente en la infraestructura vial	20
4.2.4. Dinámicas globales y liderazgo en IA aplicada a transporte	20
4.2.5. Limitaciones técnicas, operativas y contextuales de la IA en pavimentos	21
4.2.6. Evaluación financiera y viabilidad de los sistemas basados en IA.....	21
4.2.7 Análisis de costo – beneficio	23
4.2.8 Identificación y estimación de costos	24
5. METODOLOGÍA	26
5.1 Revisión sistemática de la literatura.....	26
5.2 Análisis del contexto colombiano	26
5.3 Análisis comparativo	27
5.4 Análisis de costo-beneficio.....	27
5.5 Elaboración de recomendaciones estratégicas.....	28
6. RESULTADOS	30
6.1 Evaluar la utilidad de la inteligencia artificial (IA) en la identificación de daños en infraestructuras viales, analizando el costo-beneficio de la adaptación de esta tecnología en el contexto colombiano	30
6.1.1 Efectividad de la inteligencia artificial (IA) en la identificación de daños en infraestructuras viales en el contexto colombiano.....	35

6.1.2 Comparación de la precisión de la IA y los métodos tradicionales en la inspección de daños viales.....	36
6.1.3 Análisis costo-beneficio de la implementación de inteligencia artificial en los costos de mantenimiento vial en Colombia	37
6.1.4 Casos internacionales de aplicación de inteligencia artificial en la identificación de daños en infraestructuras viales: Lecciones aprendidas.....	39
6.1.5 Análisis comparativo de casos internacionales sobre implementación de sistemas de inteligencia artificial en la investigación científica.....	51
6.2 Contexto colombiano de infraestructura vial y tecnologías de inteligencia artificial: desafíos, oportunidades y marco regulatorio	56
6.2.1 Desafíos, oportunidades y marco regulatorio.....	57
6.2.2 Desafíos técnicos en la implementación de la Inteligencia Artificial en Colombia	58
6.2.3 Desafíos económicos en la implementación de la IA en Colombia.....	59
6.2.4 Desafíos sociales en la implementación de la IA en Colombia.....	60
6.2.5 Marco regulatorio vigente en la implementación de la IA en Colombia.....	61
6.3 Inspección del estado del pavimento mediante la norma INVIAS y aplicaciones de Inteligencia Artificial sectores prueba piloto	62
6.3.1 Inspección visual conforme a la norma INVIAS	63
6.3.2 Evaluación automatizada mediante inteligencia artificial (Roadly PRO)	63
6.3.3 Comparación de metodologías.....	64
6.3.4 Implementación de la metodología de inspección del pavimento según la norma INVIAS y aplicaciones de Inteligencia Artificial Roadly	65
6.3.5 Evaluación piloto del estado del pavimento basada en el análisis de resultados con la metodología INVIAS	80
6.4 Análisis de costo financiero y costo-beneficio de la implementación de IA en la infraestructura vial en Colombia.....	87
6.5 Análisis financiero de la inversión en la implementación de sistemas de inteligencia artificial en Colombia.....	89
6.5.1 Principales problemas en la inspección de daños de la infra estructura vial	90
6.5.2 Componentes del sistema de inteligencia artificial.....	91
6.5.3 Análisis de costo-beneficio	91
6.5.4 Estrategias financieras para la optimización de costos	92
6.5.5 Estrategias de optimización para la gestión de infraestructura vial.....	95

6.5.6 Balance financiero proyectado (7 años)	96
6.6 Recomendaciones estratégicas para la adopción de tecnologías de inteligencia artificial en la gestión de infraestructuras viales en Colombia desde las dimensiones técnicas políticas y socioeconómicas	110
6.7 Justificación del enfoque estratégico	111
6.8 Estrategias priorizadas por dimensión	111
6.8.1 Dimensión Técnica	111
6.8.2 Dimensión Jurídico-Política	113
6.8.3 Dimensión Socioeconómica	114
6.9 Metodología de evaluación y priorización: Delphi + MCDA	115
6.9.1 Técnica Delphi.....	115
6.9.2 Evaluación Multicriterio (MCDA).....	115
6.10 Matriz de evaluación y priorización (Delphi–MCDA).....	116
6.11 Beneficios estratégicos esperados.....	117
7. DISCUSIÓN Y CONCLUSIONES.....	118
BIBLIOGRAFÍA.....	121

Índice de figuras

	Pág.
Figura 1. Patologías en pavimentos identificadas mediante técnicas de procesamiento de imágenes con Redes Neuronales Convolucionales (CNN).	17
Figura 2. Flujo de procesamiento de imágenes en una Red Neuronal Convolutacional (CNN) para la clasificación de daños en infraestructuras viales.	18
Figura 3. Estado de la red vial pavimentada en Colombia (8.526,39 km): distribución porcentual y kilómetros por condición	31
Figura 4. Precisión, Sensibilidad y Especificidad de Modelos de IA en la Identificación de Daños por Capa del Pavimento.	32
Figura 5. Caso 1 ciudad de Gadsden	51
Figura 6. Caso 2 ciudad de South Bend	52
Figura 7. Caso 3 ciudad de Plumstead Township.	52
Figura 8. Caso 4 Dublin, OH.....	53
Figura 9. Caso 5 ciudad de Van Wert.....	53
Figura 10. Caso 6 ciudad de Maribor.....	54
Figura 11. Caso 7 ciudad de Sonneberg	54
Figura 12. Localización del área de estudio en Tunja, Boyacá, Colombia	65
Figura 13. Mapa de georreferenciación y evaluación del estado de las vías	67
Figura 14. Distribución de Calificaciones PCI.....	69
Figura 15. Análisis de área deteriorada en infraestructura vial según nivel de conservación	70
Figura 16. Distribución de grietas, daños superficiales y estructurales en las vías piloto.	71
Figura 17. Mapa de daños – identificación y clasificación de segmentos viales en very poor y serious	72
Figura 18. Registros visuales de los segmentos viales con mayor afectación	73
Figura 19. Evaluación inteligente del estado del pavimento e identificación de daños críticos en la infraestructura vial clasificados como Very Poor y Serious	74
Figura 20. Georreferenciación y evaluación del estado del pavimento: Categorías Fair y Poor	75
Figura 21. Registros visuales obtenidos mediante análisis automatizado.....	76
Figura 22. Análisis técnico del estado del pavimento en vías clasificadas como 'fair' en Tunja (Boyacá).....	77

Figura 23. Mapa de vías en buen estado según evaluación del sistema de inteligencia artificial	78
Figura 24. Relación entre la longitud total de las vías evaluadas y su PCI Rating	79
Figura 25. Distribución del daño en las vías por área afectada.	83
Figura 26. Distribución del área afectada por patologías según su severidad.	84
Figura 27. Impacto de escenarios pesimistas y optimistas sobre el VPN.....	104
Figura 28. Flujo de caja anual neto del proyecto (años 1–7).....	106
Figura 29. Flujo de caja acumulado del proyecto (años 0–7).....	106
Figura 30. Comparación de costos operativos: Con IA vs. Sin IA	107
Figura 31. Ahorros anuales generados por la implementación de IA	108
Figura 32. Distribución de costos del proyecto – Año 1.....	108
Figura 33. Distribución de ingresos adicionales – Año 2.	109
Figura 34. Impacto del VPN bajo diferentes tasas de descuento (6 %, 8 %, 10 %).....	110

Índice de tablas

Pág.

Tabla 1. Estudios de aplicación de Inteligencia Artificial en la detección de daños en infraestructuras viales, tecnologías, metodologías y resultados.....	9
Tabla 2. Comparación técnica y operativa entre tecnologías LiDAR y métodos basados en visión computacional para la detección de daños viales.	12
Tabla 3. Estimación financiera de componentes fundamentales para sistemas avanzados de detección de daños viales (USD) (Cifras referenciales, sujetas a variación según proveedor, especificaciones técnicas y región geográfica).....	15
Tabla 4. Comparativo internacional de costos estimados por categoría tecnológica para proyectos de mantenimiento vial con inteligencia artificial.	24
Tabla 5. Comparativo entre método tradicional del INVÍAS e IA en evaluación vial.....	33
Tabla 6. Principales hallazgos transversales en la implementación de inteligencia artificial para el mantenimiento vial en contextos internacionales.....	49
Tabla 7. Limitaciones identificadas	50
Tabla 8. Modelos de Implementación de Inteligencia Artificial en Gestión Vial: Análisis Comparativo Internacional	56
Tabla 9. Marco Normativo para la Implementación de la IA en Colombia	61
Tabla 10. Estado de la infraestructura vial según Índice PCI y calificación convencional	68
Tabla 11. Porcentaje de afectación promedio por vía	71
Tabla 12. Resultados del análisis automatizado del deterioro pavimento: clasificación por índice de condición y enlaces interactivos	74
Tabla 13. Distribución de daños fair en las vías de estudio en Tunja (Boyacá) según tipo de deterioro.....	77
Tabla 14. Estado de la infraestructura vial evaluada y vías en peor condición	79
Tabla 15. Intervención y mantenimiento vial.....	80
Tabla 16. Evaluación del estado del pavimento en las vías principales de la ciudad de Tunja mediante inspección visual	81
Tabla 17. Registro fotográfico de los daños más representativos en la inspección visual en campo	85
Tabla 18. Costos de alquiler de sistemas inteligentes para inspección vial	92
Tabla 19. Costos de adquisición de sistemas inteligentes para inspección vial	93

X

Tabla 20. Costos operativos anuales estimados tras adquisición	94
Tabla 21. Análisis de viabilidad financiera para la implementación de un sistema de inteligencia artificial en la inspección de daños viales (proyección a 7 años)).	96
Tabla 22. Flujo de caja neto por año	98
Tabla 23. Análisis de sensibilidad para cada variable (VPN y ROI Anualizado)	103
Tabla 24. Estrategias Técnicas Recomendadas.	111
Tabla 25. Estrategias jurídico-políticas recomendadas para la adopción de IA en infraestructura vial.....	113
Tabla 26. Estrategias socioeconómicas recomendadas para la adopción de IA en infraestructura vial.....	114
Tabla 27. Evaluación Multicriterio (MCDA) de Acciones Estratégicas para la Adopción de IA en la Gestión de Infraestructura Vial.....	115
Tabla 28. Ponderación Justificada de criterios para Evaluación Multicriterio	116
Tabla 29. Matriz Delphi–MCDA: Acciones priorizadas según puntuación global	117

Lista de símbolos y/o abreviaturas y/o acrónimos

AI: Artificial Intelligence (Inteligencia Artificial)

ALOS-2: Advanced Land Observing Satellite-2 (Satélite japonés de observación terrestre avanzado)

APLS: Average Precision-Loss Score (Puntuación de precisión media y pérdida)

CNN: Convolutional Neural Network (Red Neuronal Convolutacional)

CrossEntropyLoss: Función de pérdida en aprendizaje profundo

DCNN: Deep Convolutional Neural Network (Red Neuronal Convolutacional Profunda)

DeepLab: Arquitectura de red neuronal profunda para segmentación semántica

DenseNet: Densely Connected Convolutional Networks (Redes Convolutacionales densamente conectadas)

ECA-Net: Efficient Channel Attention Network

EfficientNet: Familia de modelos de CNN optimizados para eficiencia y rendimiento

F1: Puntuación F1 (medida de precisión y exhaustividad)

FCN: Fully Convolutional Network (Red completamente convolutacional)

FPN: Feature Pyramid Network (Red de pirámide de características)

GA: Genetic Algorithm (Algoritmo Genético)

GAN: Generative Adversarial Network (Red Generativa Antagónica)

GCP: Ground Control Point (Punto de control terrestre)

GFlops: Giga Floating Point Operations Per Second (Gigaflops)

GSD: Ground Sample Distance (Distancia de muestra de suelo)

ImageNet: Base de datos de imágenes para reconocimiento visual

InceptionNet: Arquitectura de CNN con módulos para capturar características a múltiples escalas

iRodd: Intelligent Road Damage Detection (Sistema inteligente para detección de daños en carreteras)

K-means++: Algoritmo de inicialización mejorada del método K-means

LandSat-8: Satélite de observación terrestre del programa Landsat

LiDAR: Light Detection and Ranging (Sensor de detección y medición mediante luz)

LSTM: Long Short-Term Memory (Memoria a corto y largo plazo, tipo de red neuronal recurrente)

mAP: mean Average Precision (Precisión media promedio, métrica de evaluación)

Mask R-CNN: Extensión de Faster R-CNN para detección y segmentación de instancias

ML: Machine Learning (Aprendizaje Automático)

MLP: Multilayer Perceptron (Perceptrón Multicapa)

MobileNet: Familia de modelos CNN ligeros para dispositivos móviles

PDID: Pavement Distress Image Database (Base de datos de imágenes de daños en pavimento)

R-CNN: Region-based Convolutional Neural Network (Red neuronal convolucional basada en regiones)

RDD: Road Damage Dataset (Conjunto de datos sobre daños en carreteras)

RNA: Red Neuronal Artificial (Artificial Neural Network)

RMSE: Root Mean Square Error (Error cuadrático medio)

ROI: Region of Interest (Región de interés)

ROI Align: Region of Interest Align (Alineación de regiones de interés)

RPN: Region Proposal Network (Red de propuesta de regiones)

SDNET2018: Structural Damage Detection Dataset (Conjunto de datos para detección de daños estructurales)

Sentinel-1/2: Satélites del programa Copernicus (observación terrestre)

ShuffleNet: Arquitectura CNN ligera optimizada para móviles

SMC: Systems, Man, and Cybernetics (Sistemas, Hombre y Cibernética)

SOM: Self-Organizing Map (Mapa autoorganizado)

SSD: Single Shot MultiBox Detector (Detector de múltiples cajas de un solo disparo)

UAV: Unmanned Aerial Vehicle (Vehículo aéreo no tripulado)

U-Net: Arquitectura de red neuronal para segmentación de imágenes biomédicas

VGGNet: Arquitectura de red neuronal convolucional profunda

VoTT: Visual Object Tagging Tool (Herramienta de etiquetado visual de objetos, de Microsoft)

YOLO: You Only Look Once (Algoritmo de detección de objetos en tiempo real)

YOLOv5: You Only Look Once, versión 5 (versión mejorada del algoritmo YOLO)

1. INTRODUCCIÓN

La infraestructura vial es un eje fundamental para la cohesión territorial, la integración socioeconómica y la competitividad en Colombia. El país cuenta con una Red Vial Nacional que se divide en tramos no concesionados, gestionados por el Instituto Nacional de Vías (INVÍAS), y tramos concesionados, bajo responsabilidad de la Agencia Nacional de Infraestructura (ANI). Para efectos de seguimiento técnico y diagnóstico periódico, INVÍAS concentra su evaluación en la Red Vial Primaria no concesionada, con énfasis en su componente pavimentado, sin excluir de sus reportes vías sin pavimentar o tramos intervenidos bajo su administración.

Durante el primer semestre de 2024, INVÍAS reportó una longitud de 8.514,11 km de red pavimentada bajo su gestión, evaluada mediante la operación estadística ERVCT-INVÍAS (INVÍAS, 2024). Este modelo pondera cuatro variables técnicas: superficie de rodadura (80 %), drenaje (7,5 %), zonas laterales (5 %) y señalización (7,5 %), clasificando los tramos en cinco estados cualitativos: Muy Bueno, Bueno, Regular, Malo y Muy Malo.

Estas cifras reflejan una vulnerabilidad crítica que compromete la eficiencia operativa y la seguridad de la infraestructura vial. INVÍAS distingue entre daños estructurales (Tipo A), que comprometen la capacidad portante del pavimento, y daños funcionales (Tipo B), que afectan la comodidad, la seguridad del usuario y el desempeño superficial, aunque no impliquen fallas estructurales inmediatas (INVÍAS, 2014). La adecuada diferenciación entre ambos tipos es esencial para una intervención eficiente, pero dicha tarea se ve limitada por la subjetividad inherente a la inspección visual.

Pese a su estandarización, la metodología vigente presenta limitaciones sustanciales. La evaluación visual, aunque práctica, introduce subjetividad al depender de la interpretación del evaluador (Coenen & Golroo, 2017), lo cual dificulta diagnósticos reproducibles y decisiones técnicas consistentes. Además, la ausencia de herramientas automatizadas impide cuantificar con precisión el tipo y progresión del deterioro. Este déficit metodológico reduce la eficacia de los planes de mantenimiento, incrementa los costos operativos y dificulta la toma de decisiones, especialmente en un contexto marcado por restricciones presupuestales, dispersión geográfica y efectos del cambio climático.

Frente a este panorama, la Inteligencia Artificial (IA) representa una solución tecnológicamente viable y estratégicamente necesaria. Su aplicación permite procesar imágenes captadas por drones o cámaras móviles, identificar patrones de deterioro y clasificar las condiciones del pavimento mediante algoritmos entrenados. Diversos estudios han validado su precisión: Tello-Cifuentes et al. (2020) reportaron un 96 % de exactitud en la detección de fallas, Huaynate Gamarra (2024) alcanzó una precisión del 94,3 % en la estimación del *Pavement Condition Index (PCI)*, con reducciones del 75 % en tiempo y del 60 % en costos, mientras Hernández Ortiz (2024) empleó IA para estimar parámetros estructurales como el módulo de elasticidad. Esta tecnología ha sido reconocida en documentos técnicos y propuestas normativas recientes en el contexto colombiano (DNP, 2022; Ministerio de Transporte, 2024; Echeverri Piedrahita, 2024).

Asimismo, experiencias internacionales han demostrado que la IA mejora la precisión diagnóstica, disminuye la carga operativa de inspección y optimiza la toma de decisiones en conservación vial (Zhou et al., 2019; Maeda et al., 2018). Su adopción promueve sistemas de gestión más resilientes, capaces de priorizar intervenciones con base en datos objetivos y en menor tiempo.

En este contexto, la presente investigación se propone evaluar la viabilidad técnica, económica y operativa de la Inteligencia Artificial en la identificación de daños estructurales y funcionales en la red vial colombiana. Para ello, se analizará su precisión comparativa frente a métodos tradicionales, su impacto en costos y tiempos de diagnóstico, y la eficiencia operativa de las condiciones necesarias para su implementación efectiva. Este análisis combinará una prueba comparativa en campo, la revisión de experiencias internacionales y la evaluación del marco normativo y tecnológico nacional, con el fin de proponer recomendaciones estratégicas que respalden una adopción responsable y sostenible de esta tecnología.

Con base en estos análisis, este trabajo de grado no solo propone soluciones técnicas orientadas a la mejora de la infraestructura vial, sino que también aboga por un debate sobre las estrategias de implementación que permitirán aprovechar el potencial de la IA de manera responsable y sostenible. Finalmente, aunque los desafíos para su adopción son considerables, la inteligencia artificial representa una herramienta esencial para modernizar y optimizar la infraestructura vial de Colombia, beneficiando a la sociedad en su conjunto y contribuyendo a la creación de un sistema de transporte más eficiente, seguro y económicamente viable.

2. JUSTIFICACIÓN

La presente investigación se fundamenta en la imperiosa necesidad de optimizar la gestión de la infraestructura vial en Colombia, un componente esencial para el desarrollo económico, social y territorial del país. Según el Informe de Infraestructura del Banco Mundial (2023), cerca del 57 % de la red vial del país se encuentra en estado regular o malo, situación que afecta la conectividad, incrementa los costos logísticos, la economía del país y pone en riesgo la seguridad vial. El deterioro estructural y funcional de las vías, es una problemática recurrente y ampliamente reconocida en la red vial colombiana.

Si bien la inteligencia artificial (IA) ha demostrado beneficios significativos en diversos sectores como la salud, la industria y la agricultura particularmente en eficiencia, reducción de costos y soporte en la toma de decisiones, aún existe un vacío crítico en la aplicación sistemática, validada y adaptada de estas tecnologías a las condiciones específicas de la red vial colombiana. Actualmente, las inspecciones viales se realizan de forma predominantemente manual y visual, lo que las hace inherentemente subjetivas, lentas y con limitada cobertura. Esto impide una detección oportuna de patologías y encarece los mantenimientos correctivos, afectando directamente la vida útil de la infraestructura y la seguridad de los usuarios.

A pesar de que el Instituto Nacional de Vías (INVIAS) ha planteado su interés en incorporar tecnologías de IA para modernizar la gestión vial (Ministerio de Transporte, 2022), y Colombia ha sido clasificada por el Programa de las Naciones Unidas para el Desarrollo como un país “Diferenciador” en preparación para la IA (PNUD, 2025), persisten brechas significativas en la adopción real de estas herramientas en la gestión vial pública. Dichas brechas incluyen limitaciones tecnológicas en las entidades públicas como la falta de capacitación avanzada frente a las nuevas tecnologías que permiten el análisis de pavimentos en tiempo real, así como una baja apropiación institucional de estas tecnologías emergentes.

Es así que esta investigación responde a la necesidad concreta de implementar soluciones innovadoras que permitan mejorar la eficiencia, precisión y oportunidad en la identificación del estado de las vías, permitiendo además maximizar el impacto de la inversión presupuestaria, como los \$4 billones de pesos asignados a Inviás para obras en 2024 (Ministerio de Transporte, 2024), mediante la optimización de la asignación y priorización de recursos.

Frente a esta realidad, el estudio propone una alternativa innovadora para enfrentar el deterioro vial, con un enfoque práctico y replicable, a través del; Desarrollo y validación de un modelo de IA específico para las vías colombianas, teniendo en cuenta particularidades geográficas, climáticas, tipos de materiales y daños predominantes. El diseño de una metodología estandarizada que pueda ser implementada por entidades públicas locales con recursos limitados, contribuyendo a cerrar la brecha tecnológica y de apropiación institucional como la generación de evidencia técnica fundamentada en datos cuantitativos obtenidos en condiciones reales de operación en el contexto colombiano, que permita sustentar con base en resultados verificables la toma de decisiones en inversión tecnológica para la gestión de infraestructura vial.

El proyecto se apoya en avances recientes de la inteligencia artificial, especialmente en visión por computadora y aprendizaje profundo, que han revolucionado la capacidad de detectar y clasificar daños viales a partir de imágenes y videos. Estas herramientas, al ser integradas a procesos de inspección vial, permiten con objetividad la reducción de la subjetividad de la inspección visual tradicional. Por otro lado, la frecuencia y cobertura de este sistema da la posibilidad de aumentar significativamente el número de tramos inspeccionados en menos tiempo. Resultados que permiten realizar un análisis predictivo frente a los deterioros, priorizando acciones preventivas que reduzcan los costos de mantenimiento a largo plazo.

Para la prueba piloto se utilizará la plataforma Roadly Pro, basada en visión por computador y redes neuronales profundas, capaz de detectar automáticamente más de 20 tipos de fallas viales con una objetividad superior al 90 %, según estudios internacionales (Roadly, 2023). El análisis se aplicará a 8.715 metros lineales de vías urbanas en Tunja (101.637 m²), incluyendo tramos críticos como la Transversal 19, Carrera 14, Calle 7 y otros sectores seleccionados por su alto flujo vehicular y deterioro evidente. La intervención se realizará en un plazo máximo de 30 días, preferiblemente en temporada seca, para garantizar la calidad de las imágenes capturadas y asegurar la comparabilidad con los métodos tradicionales del INVIAS, evitando distorsiones por factores climáticos.

Para verificar el costo-beneficio de la propuesta basada en IA, se realizará una comparación directa entre un tramo vial inspeccionado con Roadly Pro y el mismo evaluado mediante el método visual-manual del INVIAS. Se aplicarán métricas cuantitativas como el costo por

kilómetro inspeccionado (COP/km), tiempo total de inspección, precisión diagnóstica (sensibilidad y especificidad), y cobertura de daños detectados. Esta evaluación permitirá establecer una relación objetiva entre eficiencia técnica y económica, validando el rendimiento operativo del modelo de IA frente al método tradicional, en concordancia con los objetivos del estudio

Esta iniciativa surge de una problemática concreta y recurrente en la gestión de mantenimiento vial, y plantea una solución que no solo genera conocimiento académico, sino también herramientas prácticas para mejorar la eficiencia, cobertura y precisión del monitoreo vial en el país. Se prevé que los resultados puedan ser compartidos con instituciones públicas y académicas, como insumo técnico para el diseño de políticas públicas, planes de modernización y estrategias de transformación digital en infraestructura vial. Este trabajo representa un aporte a nivel nacional, al ofrecer una referencia concreta y contextualizada que puede ser utilizada por entidades territoriales, centros de investigación y universidades en el análisis, inversión e implementación de soluciones inteligentes de mantenimiento vial.

3. OBJETIVOS

3.1 Objetivo general

- Evaluar la utilidad de la inteligencia artificial (IA) en la identificación de daños en infraestructuras viales, analizando el costo-beneficio de la adaptación de esta tecnología en el contexto colombiano.

3.2 Objetivos específicos

- Identificar estudios de caso a nivel internacional relacionados con aplicaciones de inteligencia artificial en la detección de daños en infraestructuras viales, realizando un análisis comparativo que permita la identificación de lecciones aprendidas y mejores prácticas aplicables al contexto colombiano.
- Caracterizar el contexto colombiano relacionado con la infraestructura vial y la disponibilidad de tecnologías de inteligencia artificial, identificando desafíos, oportunidades y el marco regulatorio que influye en la implementación de estas tecnologías.y el marco regulatorio que influye en la implementación de estas tecnologías.
- Realizar una prueba sobre un tramo comparando los resultados de la inspección visual y los obtenidos mediante IA.
- Realizar un análisis de costo-beneficio para el desarrollo e implementación de una solución de inteligencia artificial en Colombia destinada a la identificación y análisis de daños en las vías, considerando factores como el desarrollo de software, la infraestructura tecnológica necesaria y los costos asociados a la recopilación de datos.
- Proponer un conjunto de recomendaciones estratégicas basadas en los hallazgos de la investigación que faciliten la adopción de tecnologías de inteligencia artificial en la gestión de infraestructuras viales en Colombia, abordando tanto las dimensiones técnicas como las políticas y socioeconómicas.

4. MARCO DE REFERENCIA

4.1 Revisión de la literatura aplicaciones de IA en la detección de daños en infraestructura vial

En las últimas dos décadas, el uso de inteligencia artificial (IA) ha transformado los métodos tradicionales de inspección vial, permitiendo automatizar procesos de diagnóstico estructural con mayor precisión, frecuencia y cobertura. En particular, las técnicas de aprendizaje profundo como las redes neuronales convolucionales (CNN) y las redes neuronales artificiales (RNA) han demostrado un alto potencial en la detección, clasificación y análisis de daños en superficies viales, tales como fisuras, deformaciones, baches y deterioros estructurales complejos (Zhang et al., 2017; Dorafshan & Azari, 2020; Adi et al., 2024). Esta revisión se enfoca en identificar y sistematizar los enfoques actuales que emplean IA para el monitoreo de infraestructura vial, haciendo énfasis en su aplicabilidad técnica, precisión operativa, limitaciones y oportunidades de mejora, con una orientación específica hacia contextos emergentes como el colombiano.

4.1.1 Selección de estudios y artículos relevantes

Se revisaron 60 artículos científicos indexados, relacionados con el uso de IA en la detección automatizada de daños en infraestructura vial. Tras aplicar filtros de calidad metodológica y pertinencia temática, se seleccionaron 25 estudios que cumplen con los criterios de inclusión definidos para esta investigación.

Criterios de inclusión: Se priorizaron estudios que implementan modelos de IA en pavimentos, puentes o estructuras viales, centrados en la identificación, caracterización y clasificación de daños. Las técnicas incluidas abarcan redes neuronales convolucionales (CNN), redes híbridas (CNN-RNN), aprendizaje por transferencia (transfer learning), modelos generativos (GAN), así como el uso combinado de sensores RGB, LiDAR, cámaras térmicas y drones (UAV) para la recolección de datos multiespectrales (Ahmed et al., 2019; Jahanshahi et al., 2020; Tello-Cifuentes et al., 2021).

Además, se exigió que los estudios reportaran métricas cuantitativas de desempeño como precisión, exactitud, F1-score o mAP (mean average precision), y que presentaran validación empírica en escenarios reales o simulados, de preferencia replicables en países en desarrollo.

Criterios de exclusión: Se excluyeron investigaciones que no emplean IA como herramienta central, así como aquellas limitadas a la fase constructiva, sin relación directa con la inspección o el mantenimiento vial. También se descartaron trabajos sin evidencia de validación técnica, con datos no reproducibles o con enfoques centrados exclusivamente en edificación vertical (no vial).

La Tabla 1 presenta un resumen de los 25 estudios seleccionados, especificando el tipo de arquitectura utilizada, sensores principales, métricas de evaluación y limitaciones técnicas reportadas.

Tabla 1. Estudios de aplicación de Inteligencia Artificial en la detección de daños en infraestructuras viales, tecnologías, metodologías y resultados

Referencia (Año)	Tecnología Principal	Tipo de Daños Detectados	Nombre/Fuente del Dataset	Número de Muestras	Resolución Típica	Tipo de Sensor/Dispositivo de Captura	Notas del Dataset
Adachi, Y. et al. (2020)	CNN (U-Net o similar) aplicada a datos 3D	Grietas (segmentación en superficies 3D)	Propio (escaneos láser/fotogrametría 3D) o Crack Tree Dataset	Cientos de modelos 3D o miles de imágenes de profundidad 2.5D (ej. 100 escaneos de 1m x 1m)	1 mm a 5 mm por píxel/punto (para escáner láser)	Escáner láser 3D, sistemas de fotogrametría 3D Cámara convencional (motocicleta/aut omóvil con GCP); Smartphone con tecnología LiDAR.	Enfoque en segmentación precisa de grietas en superficies de asfalto tridimensionales.
Adi et al. (2024)	iRodd (CNN con LiDAR de Smartphone)	Tipos de daño general (clasificación); Baches (cálculo de volumen y visualización 3D con LiDAR)	Propio (Datos capturados en tiempo real en 38 provincias de Indonesia)	9290 datasets; 5317 daños detectados	No especificada (cámara convencional y LiDAR de smartphone)		Sistema de bajo costo para detección, clasificación, cálculo y visualización de daños en tiempo real.
Ahmed, T. U. et al. (2019)	CNN-RNN Framework (con LSTM)	Grietas en carreteras ("road crack")	Propio (Imágenes de grietas de varias fuentes)	2.400 imágenes (80% entrenamiento, 10% validación, 10% pruebas)	No especificada (se asume fotográfico)	No especificado (varias fuentes)	Marco integrado que combina extracción de características de CNN con clasificación secuencial de RNN para evaluación de grietas.
Arman, M. S. et al. (2020)	R-CNN y Faster R-CNN	Baches, grietas, desgaste en superficies de carreteras	Road Damage Dataset (RDD 2018)	750 imágenes (600 entrenamiento, 150 validación)	No especificada	Cámara de teléfono inteligente	Datos preprocesados (ajuste de tamaño, balance de blancos, contraste, etiquetado).
Dorafshan, S., & Azari, H. (2020)	CNN (VGG16, ResNet50 con Transfer Learning)	Clasificación de tipos de grietas	SDNET2018 (Structural Damage Detection Dataset)	>56,000 imágenes (se selecciona submuestra)	256x256 píxeles	No especificado	Dataset público muy grande para clasificación de grietas.
Du, J., Zhang, C., Li, S., & Li, C. (2022)	CNN	Múltiples tipos de daños (grietas, baches, parches, etc.)	Combinación de datasets públicos y propios (RDD extendido)	Decenas de miles de imágenes (ej. >30,000)	640x640 o 800x800 píxeles (típico para entrada de CNN)	No especificado	Utilizan versiones extendidas del Road Damage Dataset (RDD).
Gopalakrishnan, K. et al. (2017)	Deep CNN con Transfer Learning (VGGNet, ResNet, AlexNet)	Grietas en pavimento	Pavement Distress Image Database (PDID) de Texas o Propio	2.000-5.000 imágenes	224x224 px (típico para entrada de CNN)	No especificado (imágenes existentes)	Utiliza modelos pre-entrenados para la detección inteligente de grietas, aprovechando el aprendizaje por transferencia.
Huang, C. et al. (2024)	Fusión de datos Multi-modales (CNN)	Daños en pavimento (compreensivo)	Propio (creación de dataset multi-modal)	Cientos o miles de "escenas"/secciones (con datos de múltiples sensores)	Varía por sensor (ópticas: 1000x1000+ px; LiDAR: mm de precisión)	Cámaras ópticas, LiDAR, sensores termográficos, etc.	Detección más robusta por combinación de diferentes tipos de datos.
Jahanshahi, M. R., et al. (2020)	Deep Learning (CNN, ej. U-Net, DeepLab)	Grietas en estructuras de hormigón (incl. pavimentos)	Propio (imágenes de UAV) o datasets limitados de proyectos	Cientos a miles de imágenes completas (generan 10s-100s de miles de parches)	Original UAV: Megapíxeles. Parches: 256x256 o 512x512 píxeles	UAV (Drones)	Detección de grietas finas con imágenes de alta resolución de drones.
Kikin, P. M. et al. (2019)	FCNN (LinkNet con ResNet34) /	Daños en carreteras, vías ferroviarias, rutas peatonales (segmentación en no deteriorada, deteriorada, no disponible)	Propio (UAV) y Satelital (Sentinel-1/2,	UAV: ~2097 imágenes (97 "no disponibles", 2x1000 "dañadas/ordinarias").	UAV: No especificada. Satelital: Sentinel-2:	Imágenes de satélites (ópticas y SAR); UAV	Enfoque en evaluación de daños post-desastre para servicios de emergencia.

	Combinación de Datos (Satélites y UAV)		ALOS-2, Landsat-8)	Satelital: imágenes post-desastre (sin un número total unificado).	Múltiples 10m GSD; Sentinel-1: 5m x 20m; ALOS-2: ~5m GSD; Landsat-8: 30m GSD.	(drones); Google Images (para UAV).	Utiliza métricas como F1-score y APLS.
Kulambayev et al. (2023)	Mask R-CNN / Deep CNN (VGG-16, ResNet, FPN)	Grieta lineal, Grieta de cuadrícula, Juntas de pavimento, Parches, Rellenos, Baches, Alcantarillas/Registros, Manchas, Sombra, Marcas de pavimento, Rayones en marcas, Grietas de cuadrícula en parches (12 tipos)	Propio (Diverso: carreteras urbanas, suburbanas, rurales)	19.440 segmentos anotados (división 0.6 entrenamiento, 0.2 validación, 0.2 prueba)	No especificada (cámaras montadas en vehículos y smartphones)	Cámaras montadas en vehículos, Smartphones	Conjunto de datos único con anotaciones detalladas; uso de Microsoft VoTT para anotación. Enfocado en la detección en tiempo real.
Kulambayev, B. et al. (2024)	Deep CNN / Visual Features	Grietas (fracturas finas a hendiduras amplias)	Road Damage Dataset 2020 (RDD2020)	26.305 imágenes	No especificada	No especificado (imágenes de pavimento bajo condiciones reales)	Enfoque en la detección de grietas en tiempo real; análisis dinámico y consciente del contexto.
Li, M., Li, Y., & Chen, H. (2023)	CNN Ligeras y Eficientes (ej. MobileNet, ShuffleNet) Deep Learning Framework (End-to-End, ej. YOLOv4/v5/v7, SSD)	Grietas (detección en tiempo real)	Combinación de datasets públicos y propios (con smartphones)	Varios miles o decenas de miles de imágenes	224x224 o 300x300 píxeles	Smartphones	Optimizado para eficiencia computacional y bajo consumo de memoria en dispositivos móviles.
Liu, S. et al. (2021)		Detección y evaluación de severidad de daños en pavimento	Propio (imágenes de pavimento con anotaciones de ubicación y severidad)	>20,000 imágenes	640x640 o 800x800 píxeles	No especificado	Detección y evaluación de severidad en tiempo real.
Maeda, H. et al. (2018)	Deep CNN (SSD con MobileNet)	Baches, Grietas de cocodrilo, Grietas longitudinales, Grietas transversales, Otras anomalías (parches, alcantarillas)	Road Damage Dataset (RDD) / Propio	9.053 imágenes (con 15.435 instancias de daños anotadas)	No especificada	Smartphone con cámara (Nexus 5X)	Dataset a gran escala capturado en 7 municipalidades de Japón (más de 40 horas de grabación). Uno de los primeros y más influyentes datasets públicos en el campo.
Mondal, M. R. H. et al. (2023)	YOLO (YOLOv3-tiny, YOLOv4-tiny, YOLOv5/v7)	Daños en carreteras (detección y clasificación)	RDD2020 o Propio (capturado con smartphones)	10.000-30.000+ imágenes (con miles de instancias de daños)	416x416 px, 608x608 px o 640x640 px (resolución de entrada del modelo)	Smartphones	Optimizado para detección y clasificación en tiempo real en dispositivos móviles.
Omarov, B. & Kulambayev, B. (2024)	Deep Learning (Mask R-CNN)	Grietas, baches, tapas de alcantarilla abiertas, pavimento asfáltico parcial, hormigón roto, borrosidad de cruces/líneas divisorias (6 tipos)	Propio (Curado por los autores con smartphones)	No especificado (descrito como "robusto")	No especificada	Smartphones (dispositivos de uso universal)	Enfoque en detección y segmentación de instancias en tiempo real a nivel de píxel. Integra VGG-16/ResNet, FPN, RPN y ROI Align.
Ren, J., Liu, B., Wang, R., Zheng, W., & Zhang, Y. (2020)	DCNN con Transfer Learning	Grietas	CrackForest Dataset (117 imágenes) + 246 imágenes propias	363 imágenes para entrenamiento	3264x2448 píxeles (original, resolución alta)	No especificado	Utilizan ResNet, InceptionNet o DenseNet como backbone.
Sami et al. (2023)	YOLOv5s (Mejorado) / Deep CNN	Grietas verticales, Grietas horizontales, Grietas de cocodrilo (Alligator cracks), Baches (Potholes)	Road Damage Dataset 2022 (RDD 2022)	47.545 imágenes (36.568 entrenamiento, 10.977 validación/prueba)	640 x 640 px (procesadas)	Cámaras de tablero, drones	Dataset de referencia con 4 tipos comunes de daños en pavimento, utilizado para el

Singh, S., Mohan, H., & Jain, M. (2021)	CNN (YOLO o SSD)	Baches	Propio (Pothole Dataset, con datos de smartphones)	1500 imágenes	416x416, 608x608 o 640x640 píxeles (redimensionadas)	(implícito por RDD 2022) Cámaras de smartphones montadas en vehículos	entrenamiento y mejora del modelo YOLOv5s.
Tang et al. (2022)	CNN (VGG-19) / Transfer Learning	Hundimientos (Potholes), Depresiones, Grietas unidireccionales, Aflojamientos, Grietas (generales)	Propio (Combinación de fotografías y datasets públicos)	3000 imágenes aumentadas (2400 entrenamiento, 600 validación) a partir de 100 imágenes originales	256 x 256 px (reprocesadas)	No especificado (Adquisición por fotografía y datasets públicos)	Conjunto de datos expandido mediante técnicas de aumento (volteo, ampliación, ecualización de histograma) para robustecer el entrenamiento. Capturadas a 25-30 km/h; seleccionadas por calidad de imagen. Dataset de entrenamiento balanceado con 30 imágenes (10 por tipo), y validación con 25 imágenes.
Tello-Cifuentes et al. (2021)	RNA / Fotogrametría a Terrestre	Grieta longitudinal, piel de cocodrilo, bache	Propio (Pavimento flexible)	129 imágenes seleccionadas	2624 x 2880 px	Cámara digital GoPro (11 MP)	
Wang, Y. et al. (2024)	GANs (para aumento de datos) + CNNs	Grietas	Dataset existente (ej. CrackForest) complementado con imágenes sintéticas generadas por GANs	Cientos o pocos miles (reales); miles o decenas de miles (sintéticas)	256x256 o 512x512 píxeles	No especificado (imágenes existentes + sintéticas)	Utilizan GANs para generar imágenes sintéticas de grietas y aumentar el dataset de entrenamiento.
Xing, M., Fan, B., & Ma, Z. (2023)	Framework de Aprendizaje Multi-tarea (DCNN)	Detección de grietas y clasificación de tipo/severidad	RDD o colecciones propias, fusionando/expandiendo datos	15,000 - 30,000 imágenes (cada una con múltiples anotaciones)	512x512 o 640x640 píxeles	No especificado	Permite que una única red aprenda simultáneamente varias tareas relacionadas.
Yang, X., Li, J., Yu, H., & Zhou, L. (2019)	DCNN	Grietas	Propio	500 imágenes (divididas en parches)	128x128 o 256x256 píxeles (parches)	No especificado	Segmentación a nivel de píxel, arquitectura inspirada en U-Net o FCN.
Zhang, A. et al. (2017)	Modelo jerárquico de Deep Learning (CNNs, VGGNet/ResNet)	Múltiples tipos de daños en pavimento	RDD o Propio (cámaras de alta resolución)	>10.000 imágenes (ej. 10.000-20.000)	640x480 px o 1280x720 px	Cámaras de alta resolución	Combina CNNs para capturar características a múltiples escalas para detección de diversos daños.
Zhang, X. et al. (2022)	Deep Learning (CNN)	Daños en superficie de carretera (anomalías térmicas)	Propio (imágenes térmicas infrarrojas)	Cientos a pocos miles de imágenes térmicas (ej. 500-2000)	320x240 o 640x480 píxeles	Cámara térmica infrarroja	Detección basada en anomalías térmicas, complementa la detección visual.

Fuente: Elaboración del autor basada en la revisión de artículos y casos de estudio correspondientes a cada uno de los países analizados.

4.1.2 Síntesis de enfoques tecnológicos y operativos

Los enfoques identificados reflejan una convergencia entre modelos de aprendizaje profundo y tecnologías de captura multifuente. Las CNN han sido las más ampliamente utilizadas debido a su capacidad para extraer patrones visuales complejos en superficies dañadas (Adachi et al., 2020). Sin embargo, su desempeño puede verse afectado por pavimentos con texturas heterogéneas y alta variabilidad ambiental (Singh et al., 2021).

Modelos como R-CNN y Faster R-CNN han mostrado precisiones superiores al 90% en imágenes preprocesadas, aunque requieren grandes volúmenes de datos anotados manualmente (Arman et al., 2020; Kulambayev et al., 2023). Arquitecturas híbridas, como CNN-RNN, permiten integrar dimensiones temporales, mejorando el análisis de grietas longitudinales y ramificadas, aunque con sensibilidad a sombras e iluminación (Ahmed et al., 2019).

Paralelamente, se ha incrementado el uso de drones para capturar imágenes aéreas de alta resolución, mejorando la cobertura en zonas de difícil acceso. Asimismo, la incorporación de sensores LiDAR y térmicos ha mejorado la detección en condiciones adversas, aunque exige algoritmos de fusión multimodal más complejos (Huang et al., 2024; Zhang, X. et al., 2022).

Los algoritmos ligeros como MobileNet, ShuffleNet y SSD han sido implementados para aplicaciones en tiempo real en dispositivos móviles, sacrificando precisión por eficiencia computacional (Li et al., 2023; Maeda et al., 2018). Este tipo de soluciones es especialmente relevante para contextos urbanos o rurales con limitaciones de infraestructura tecnológica. La Tabla 2 sistematiza los hallazgos comparando las tecnologías revisadas en función de su precisión, tipo de daño detectado, requerimientos técnicos y restricciones operativas.

Tabla 2. Comparación técnica y operativa entre tecnologías LiDAR y métodos basados en visión computacional para la detección de daños viales.

Tecnología / Modelo Específico	Tipo de Daños Detectados	Métrica y Resultados de Precisión	Tipo de Datos / Sensor Principal	Principales Limitaciones	Referencia Directa
CNN (U-Net o similar)	Grietas en el pavimento	F1-Score: 99.8%	Escáner láser 3D / Fotogrametría 3D	Alta capacidad computacional; ineficaz con texturas complejas	Adachi et al. (2020)

iRodd (CNN + LiDAR)	Baches, grietas	Precisión: 85%; RMSE: 6.47 mm	Cámara RGB / LiDAR	Limitado a tipos de daños entrenados	Adi et al. (2024)
CNN-RNN (con LSTM)	Grietas en carreteras	F1-score: 95%	Smartphone Imágenes RGB (no especificado)	Sensible a iluminación y sombras	Ahmed et al. (2019)
Faster R-CNN / R-CNN	Baches, grietas, desgaste	mAP: 73–75%	Imágenes RDD 2018	Pobre generalización, datos limitados	Arman et al. (2020)
CNN (VGG16, ResNet50, TL)	Clasificación de grietas	Exactitud: 99.8%	SDNET2018	Alta demanda computacional	Dorafshan & Azari (2020)
CNN (no especificada)	Múltiples tipos de daños	mAP: 88.5%	RDD extendido	Necesita datasets diversos	Du et al. (2022)
Deep CNN (VGGNet, ResNet)	Grietas en pavimento	Exactitud: 97.4%	Propio / PDID	Bajo rendimiento en datasets pequeños	Gopalakrishnan et al. (2017)
CNN (Fusión multimodal)	Daños integrales	F1-score: ~90%	RGB + Térmico + LiDAR	Alta complejidad de fusión	Huang et al. (2024)
U-Net / DeepLab (CNN)	Grietas en estructuras	Precisión: 92%	Drones UAV	Dependencia de perspectiva	Jahanshahi et al. (2020)
FCNN (LinkNet-ResNet34)	Segmentación de daños viales	F1-score: ~87%	UAV y satelitales ópticas	Baja resolución satelital	Kikin et al. (2019)
Mask R-CNN (FPN)	12 tipos de daños	mAP: 89%	Vehículos / Smartphone	Necesita mucha anotación y recursos	Kulambayev et al. (2023)
CNN visuales (RDD2020)	Grietas	F1-score: 92.1%	RDD2020	Bajo rendimiento con baja visibilidad	Kulambayev, B. et al. (2024)
MobileNet / ShuffleNet	Grietas en tiempo real	mAP: 85%	Smartphones	Limitado en ruido y entornos complejos	Li et al. (2023)
YOLOvX / SSD	Severidad de daños	mAP: 89.3%	Propio	Requiere gran cantidad de datos etiquetados	Liu et al. (2021)
SSD + MobileNet	Baches, grietas (múltiples)	mAP: 79–80%	Smartphones / RDD	Alta latencia de inferencia	Maeda et al. (2018)
YOLOv3/v5/v7	Clasificación vial	mAP50: 91.5%	RDD2020	Necesita optimización para modelos grandes	Mondal et al. (2023)
Mask R-CNN	Segmentación (6 tipos)	mAP: 89%	Smartphones	Segmentación pixelada compleja	Omarov & Kulambayev (2024)
DCNN (ResNet / TL)	Grietas	Exactitud: 98%	CrackForest + propio	Imágenes de baja calidad afectan resultados	Ren et al. (2020)
YOLOv5 mejorado	Grietas y baches	mAP50: 91.5%	Cámaras de tablero / Drones	Dataset dependiente	Sami et al. (2023)
CNN (YOLO / SSD)	Baches	Precisión: 92%	Smartphones	Afectado por iluminación / ángulo	Singh et al. (2021)
CNN (VGG-19 con TL)	Daños múltiples	Exactitud: 86.2%	Fotografías públicas	Bajo rendimiento en visibilidad reducida	Tang et al. (2022)
RNA + Fotogrametría	Grietas y baches	Exactitud: 96.97%	GoPro terrestre	Lento procesamiento, luz controlada	Tello-Cifuentes et al. (2021)
GAN + CNNs base	Aumento de datos (grietas)	Mejora del 5–10% en F1/mAP	Imágenes sintéticas + reales	Altos requerimientos computacionales	Wang et al. (2024)
Multi-task CNN	Tipo y severidad de grietas	F1-score: ~90%	RDD / Propio	Diseño y entrenamiento complejos	Xing et al. (2023)

FCN / U-Net inspired	Grietas	F1-score: 93%	Datos propios	Requiere datasets grandes para segmentación	Yang et al. (2019)
CNN jerárquica (VGG / ResNet)	Daños múltiples	Exactitud: 96%	Alta resolución / RDD	Ajuste fino por tipo de pavimento	Zhang, A. et al. (2017)
CNN (Térmico)	Anomalías térmicas	Precisión: 88%	Cámaras térmicas	Sensible a temperatura y resolución baja	Zhang, X. et al. (2022)

Fuente: Elaboración propia con base en Adachi et al. (2020); Adi et al. (2024); Ahmed et al. (2019); Arman et al. (2020); Dorafshan & Azari (2020); Du et al. (2022); Gopalakrishnan et al. (2017); Huang et al. (2024); Jahanshahi et al. (2020); Kikin et al. (2019); Kulambayev et al. (2023, 2024); Li et al. (2023); Liu et al. (2021); Maeda et al. (2018); Mondal et al. (2023); Omarov & Kulambayev (2024); Ren et al. (2020); Sami et al. (2023); Singh et al. (2021); Tang et al. (2022); Tello-Cifuentes et al. (2021); Wang et al. (2024); Xing et al. (2023); Yang et al. (2019); Zhang, A. et al. (2017); Zhang, X. et al. (2022).

De acuerdo con los resultados sistematizados en la Tabla 2, los modelos avanzados como Faster R-CNN, Mask R-CNN y configuraciones específicas de RNA han demostrado precisiones superiores al 99% en entornos controlados, utilizando imágenes preprocesadas y conjuntos de datos estandarizados (Adachi et al., 2020; Dorafshan & Azari, 2020; Arman et al., 2020). Sin embargo, su desempeño en condiciones reales depende críticamente de la calidad, diversidad y contextualización de los datos empleados para el entrenamiento y validación.

Una limitación recurrente es la ausencia de datasets adaptados a contextos latinoamericanos, lo que restringe la replicabilidad y transferencia de estos modelos a escenarios urbanos y rurales de países como Colombia (Tello-Cifuentes et al., 2021; Wang et al., 2024). Esta brecha limita la efectividad de modelos entrenados con bases como RDD2018 o SDNET2018, que no reflejan las variaciones geomorfológicas, materiales de pavimento o condiciones climáticas locales.

Tecnologías complementarias como UAV (drones) y sensores LiDAR potencian la captura de datos en alta resolución y el monitoreo de grandes extensiones. No obstante, su aplicación exige inversión en infraestructura, personal técnico calificado y estabilidad operativa, aspectos que dificultan su adopción en municipios con restricciones presupuestales o acceso limitado (Jahanshahi et al., 2020; Huang et al., 2024).

En contraste, modelos livianos como MobileNet, ShuffleNet o versiones optimizadas de YOLOv5 ofrecen una solución viable para inspecciones rápidas y levantamientos preliminares, especialmente en zonas con recursos limitados. Aunque su precisión es menor (75%–89%),

destacan por su bajo requerimiento computacional y compatibilidad con dispositivos móviles (Li et al., 2023; Maeda et al., 2018; Sami et al., 2023).

En síntesis, no existe un modelo único superior de forma universal. La elección debe considerar un balance entre precisión, robustez, costos operativos y adaptabilidad contextual, dependiendo de los objetivos técnicos y capacidades institucionales. Para entornos urbanos complejos, los enfoques basados en visión multiespectral y detección por instancia (p. ej., Mask R-CNN, CNN-RNN) ofrecen mayor granularidad analítica. Por el contrario, en programas piloto o estrategias comunitarias, los algoritmos livianos representan una alternativa estratégica de entrada.

En este sentido, la viabilidad de implementar estos modelos también está condicionada por las capacidades financieras de las entidades operadoras, particularmente en contextos locales con presupuestos restringidos. A fin de aportar criterios comparativos para la toma de decisiones técnico-económicas, la Tabla 3 presenta una estimación referencial de los costos asociados a componentes esenciales de un sistema avanzado de detección de daños viales, incluyendo sensores, infraestructura de procesamiento, almacenamiento y plataformas de adquisición de datos. Estos valores permiten dimensionar la inversión necesaria para escalar soluciones de IA en condiciones reales, considerando tantos escenarios centralizados (internacionales, nacionales o regionales).

Tabla 3. *Estimación financiera de componentes fundamentales para sistemas avanzados de detección de daños viales (USD) (Cifras referenciales, sujetas a variación según proveedor, especificaciones técnicas y región geográfica).*

Categoría de Costo	Componente Específico	Rango de Costo Estimado (USD)	Notas y Justificación
I. Hardware	Sensor LiDAR (Móvil/Terrestre)	\$15,000 – \$150,000+	Costo inicial elevado. Varía según precisión, número de líneas y alcance. Modelos de referencia: Velodyne, Ouster.
	Drone (UAV) con RTK/PPK y capacidad de carga LiDAR	\$5,000 – \$30,000+	UAV profesionales con sistemas GNSS de alta precisión. Modelos de alta gama para aplicaciones geoespaciales.
	Cámara de alta resolución (óptica/térmica/multiespectral)	\$2,000 – \$15,000+	Cámaras industriales, superiores a cámaras comerciales. Usadas para detección de fallas en estructuras e inspección térmica.
	Plataforma de montaje vehicular o portátil	\$1,000 – \$10,000+	Soportes, estabilizadores, estructuras para integración con vehículos o uso en campo.

II. Software	Software de procesamiento de nube de puntos (LiDAR)	\$3,000 – \$20,000 / licencia anual	Ej.: Terrasolid, FARO Scene, Leica Cyclone. Requiere licencia especializada y entrenamiento técnico.
	Software de fotogrametría	\$1,000 – \$5,000 / licencia anual	Ej.: Agisoft Metashape, Pix4D Mapper. Para generación de modelos 3D desde imágenes.
	Licencias de software de IA / ML	\$500 – \$5,000+ / año	Ej.: AWS SageMaker, Google AI Platform. Algunos se cobran por uso.
	Software GIS (Open source o propietario)	\$0 – \$10,000+ / licencia anual	Ej.: QGIS (gratis), ArcGIS (de pago). Para análisis, integración y visualización de datos geoespaciales.
III. Personal Especializado	Ingeniero/a de datos / Científico/a de datos / Especialista en IA	\$30,000 – \$80,000+ / año	Sueldo anual estimado en mercados desarrollados. Encargado del desarrollo de modelos, análisis y validación.
	Especialista en geomática / Topógrafo/a con experiencia en UAV y LiDAR	\$25,000 – \$60,000+ / año	Planificación, adquisición y control de calidad de datos geoespaciales.
	Operador/a de drones certificado/a	\$15,000 – \$40,000+ / año	Profesional certificado para operar drones en contextos técnicos y normativos.
IV. Operación y Mantenimiento	Mantenimiento anual de hardware	5% – 15% del valor del equipo	Calibraciones, reemplazos, soporte técnico, actualizaciones de firmware.
	Procesamiento y almacenamiento en la nube (mensual)	\$100 – \$1,000+ / mes	Dependiente del volumen de datos, frecuencia de análisis y plataforma (ej.: AWS, Azure, Google Cloud).

Fuente: Elaboración propia con base en catálogos de fabricantes (Velodyne, DJI Enterprise, Pix4D), análisis sectoriales (Hexagon Geospatial, Gartner 2023–2024) y estimaciones salariales internacionales (Glassdoor, Payscale, Indeed).

Not: Los valores son aproximados y pueden variar significativamente según el país, tipo de proyecto y especificaciones técnicas.

4.1.5 Caracterización visual de daños viales mediante IA

Con base en la evidencia técnica revisada y los costos estimados en la Tabla 3, se concluye que la implementación de sistemas de inteligencia artificial en la infraestructura vial debe contemplar no solo la disponibilidad de hardware y software, sino también la capacidad institucional para interpretar adecuadamente los resultados generados por los algoritmos. Esta capacidad interpretativa es crítica para convertir las salidas computacionales en decisiones técnicas útiles, particularmente en contextos donde los recursos son limitados y las condiciones ambientales complejas.

En este contexto, la Figura 1 sintetiza los principales tipos de deterioro superficial detectados mediante algoritmos de Redes Neuronales Convolucionales (CNN), incluyendo grietas, baches, depresiones, desagregación de material y surcos de rodadura. Cada una de estas patologías presenta una firma morfológica específica, la cual es aprendida por el modelo durante su entrenamiento supervisado a partir de conjuntos masivos de imágenes etiquetadas (Kulambayev et al., 2023; Sami et al., 2023).

La capacidad de estas redes para reconocer, clasificar y evaluar patrones visuales ha demostrado ser altamente efectiva en tareas de inspección automatizada, particularmente en contextos urbanos densos o zonas de difícil acceso. Esta detección temprana favorece una priorización técnica más objetiva en los planes de mantenimiento vial, optimizando el uso de los recursos públicos. No obstante, la eficacia del modelo sigue condicionada por la calidad del dataset de entrenamiento, la resolución óptica del sensor y las condiciones de iluminación o clima durante la captura, lo cual representa un desafío en entornos no controlados (Jahanshahi et al., 2020; Wang et al., 2024).

Figura 1. *Patologías en pavimentos identificadas mediante técnicas de procesamiento de imágenes con Redes Neuronales Convolucionales (CNN).*



Fuente: Research on Intelligent Detection of Pavement Damage Based on CNN; adaptado de Kulambayev et al. (2023) y Sami et al. (2023).


Una vez identificadas las patologías viales mediante visión computacional, resulta esencial comprender el funcionamiento interno de los sistemas de aprendizaje profundo que posibilitan dicha clasificación. La Figura 2 ilustra el flujo operativo de una Red Neuronal Convolucional (CNN), modelo ampliamente utilizado en el reconocimiento automático de daños viales por su

capacidad para emular principios básicos de la percepción visual humana (Sami et al., 2023; Ren et al., 2020).

El proceso inicia con la captura de imágenes, etapa en la que se registran visualmente los deterioros mediante cámaras instaladas en vehículos, drones o dispositivos móviles. Estas imágenes, previamente referenciadas (véase Figura 1), constituyen el insumo primario del sistema.

Luego, en la fase de preprocesamiento, se aplican transformaciones como el redimensionamiento, la normalización y la supresión de ruido, permitiendo estandarizar la entrada y garantizar un rendimiento óptimo del modelo. A continuación, en la etapa de convolución, se emplean filtros (kernels) que extraen patrones jerárquicos relevantes, como bordes, texturas o deformaciones, facilitando la detección de detalles críticos en el pavimento. Posteriormente, el modelo ejecuta una operación de pooling o submuestreo, cuyo propósito es reducir la dimensionalidad de los datos, conservando únicamente las características esenciales. Esta fase mejora la eficiencia computacional del sistema, al tiempo que fortalece su capacidad de generalización frente a nuevas imágenes. Finalmente, las capas posteriores transforman la representación interna en una predicción precisa del tipo y la severidad del daño.

Figura 2. *Flujo de procesamiento de imágenes en una Red Neuronal Convolucional (CNN) para la clasificación de daños en infraestructuras viales.*



Fuente: Adaptado de “Research on Intelligent Detection of Pavement Damage Based on CNN”, con base en Sami et al. (2023) y Ren et al. (2020).

Los sistemas basados en aprendizaje profundo, como las Redes Neuronales Convolucionales (CNN), han demostrado una alta eficiencia en la identificación de patrones visuales, superando

los métodos tradicionales. El flujo de procesamiento, ilustrado en la Figura 2, permite extraer características esenciales y reducir la dimensionalidad, lo que mejora la precisión en la clasificación de daños. Así, los sistemas inteligentes se consolidan como herramientas fundamentales para la evaluación vial, optimizando recursos y facilitando la toma de decisiones rápidas en el diseño de programas de intervención.

4.2 Marco teórico

4.2.1. La infraestructura vial como eje del desarrollo socioeconómico

La infraestructura vial constituye un componente estructural en la dinámica del desarrollo económico y social de los países. Una red de carreteras eficiente y bien mantenida facilita el tránsito de bienes y personas, potencia la productividad, reduce los costos logísticos y mejora la conectividad entre regiones, estimulando así el crecimiento económico sostenible (Queiroz & Gautam, 1992). Se estima que, por cada dólar invertido en infraestructura vial, el Producto Interno Bruto (PIB) puede incrementarse hasta en 4,6 dólares, lo que ratifica su efecto multiplicador sobre la economía nacional.

No obstante, la calidad de la infraestructura vial presenta marcadas disparidades a nivel internacional. Según el Foro Económico Mundial (El Espectador, 2015), países como Chile lideran el ranking latinoamericano en calidad vial, mientras que Colombia, Haití y Paraguay enfrentan desafíos estructurales en su red vial. Esta situación se traduce en mayores riesgos de accidentalidad, incrementos en los tiempos de desplazamiento y sobrecostos en sectores estratégicos como el agro, la industria y el comercio (Infobae, 2024).

4.2.2. Métodos tradicionales de inspección y su persistencia en América Latina

Históricamente, la evaluación y el mantenimiento de carreteras se han basado en métodos tradicionales, como la inspección visual y la recolección manual de datos estructurales, funcionales y geométricos (Higuera, 2012). Estos procedimientos, si bien son relativamente accesibles, presentan limitaciones en términos de precisión, trazabilidad y escalabilidad, sobre todo en contextos con redes viales extensas y presupuestos limitados.

Países como Chile (Ministerio de Obras Públicas, 2020), Estados Unidos (AASHTO, s.f.) y Canadá (The Ohio Department of Transportation, 2006) siguen aplicando esquemas de evaluación convencional, que incluyen indicadores como deflexiones, inventario vial, resistencia al deslizamiento, características de drenaje y parámetros ambientales. Sin embargo, estas metodologías han sido cuestionadas por su limitada capacidad para anticipar fallos estructurales, especialmente en países en desarrollo (Harral & Faiz, 1989).

4.2.3. Inteligencia artificial y su aplicación emergente en la infraestructura vial

Frente a las limitaciones operativas de los métodos tradicionales de inspección, la inteligencia artificial (IA) se consolida como una solución disruptiva para la gestión moderna de infraestructuras viales. Su capacidad para procesar grandes volúmenes de datos, identificar patrones complejos y ejecutar análisis predictivos en tiempo real permite evaluaciones más objetivas, ágiles y precisas del estado del pavimento, superando las restricciones subjetivas de la inspección visual (Ranyal et al., 2022).

Empresas especializadas como RoadBotics, Vytal.AI, StreetScan, ASIMOB, Pavemetrics y Michelin Mobility Intelligence han desarrollado soluciones avanzadas basadas en visión por computador y aprendizaje profundo, capaces de detectar de forma automatizada daños como grietas, baches, surcos o desprendimientos. Estos sistemas, integrados a vehículos, drones o dispositivos móviles, permiten una recolección sistemática de imágenes del terreno, generando mapas georreferenciados del estado vial, priorización de intervenciones por nivel de riesgo estructural y alertas tempranas sobre eventos críticos (Ayman & Fakhr, 2023).

4.2.4. Dinámicas globales y liderazgo en IA aplicada a transporte

El desarrollo de IA a nivel global ha sido liderado por países como Estados Unidos, China, Reino Unido, Alemania, Corea del Sur y Japón, los cuales integran esta tecnología en múltiples sectores estratégicos mediante ecosistemas de innovación robustos y políticas de fomento a la investigación (Salazar-Xirinachs, 2020). En América Latina, Chile encabeza el despliegue de estrategias nacionales de IA, seguido por Brasil, México, Argentina, Colombia y Costa Rica, según reportes recientes de la CEPAL (2024). Este avance no solo evidencia un cambio de paradigma tecnológico, sino que también plantea desafíos éticos, regulatorios y operativos en su

implementación masiva, sobre todo en países con brechas de conectividad o limitada capacitación técnica.

4.2.5. Limitaciones técnicas, operativas y contextuales de la IA en pavimentos

Si bien la IA ofrece ventajas sustantivas frente a los métodos tradicionales, su implementación enfrenta múltiples desafíos. La precisión de los modelos depende críticamente de la calidad del dataset, la resolución de las imágenes capturadas y las condiciones ambientales durante la adquisición de datos (Guerrieri et al., 2024; Wang et al., 2024). Asimismo, el uso de modelos desactualizados o mal calibrados puede limitar la detección de fisuras finas o deterioros profundos, comprometiendo la utilidad del sistema (Nyirandayisabye et al., 2022).

Otro factor limitante es la complejidad técnica de los algoritmos y la necesidad de personal capacitado para su entrenamiento, ajuste y validación. Además, el acceso a sensores avanzados (LiDAR, cámaras multiespectrales) y plataformas de análisis en tiempo real implica inversiones considerables en infraestructura tecnológica (Jahanshahi et al., 2020; Jagatheesaperumal et al., 2023).

4.2.6. Evaluación financiera y viabilidad de los sistemas basados en IA

Desde la perspectiva de la economía del proyecto, la incorporación de tecnologías de inteligencia artificial (IA) en la gestión vial requiere una evaluación rigurosa de su viabilidad financiera, considerando tanto los costos iniciales como los beneficios operativos proyectados a lo largo de la vida útil del sistema (Meza Orozco, 2013; Rodríguez, 2024). En este análisis, indicadores como el Valor Presente Neto (VPN), la Tasa Interna de Retorno (TIR) y el Retorno sobre la Inversión (ROI) permiten cuantificar la rentabilidad esperada de la inversión y fundamentar decisiones estratégicas basadas en criterios de eficiencia, sostenibilidad y uso racional de los recursos públicos.

En contextos como el colombiano, donde las condiciones geográficas, climáticas y presupuestales representan desafíos estructurales para la conservación de la red vial, el análisis de costo-beneficio (ACB) se consolida como una herramienta para evaluar la conveniencia económica de implementar tecnologías inteligentes. Tal como afirman Goel y Sharma (2022), el

ACB facilita la comparación sistemática entre los costos de inversión e implementación y los beneficios generados por los sistemas, permitiendo una toma de decisiones fundamentada en evidencia y orientada al valor. Asimismo, la inclusión del análisis de sensibilidad refuerza la capacidad de anticipar escenarios de riesgo, variabilidad en ingresos, cambios en costos operativos o fluctuaciones en la tasa de descuento, lo que es especialmente relevante en el ámbito público (Makendran et al., 2024). En este marco, los principales indicadores financieros aplicables se resumen de la siguiente forma:

Tasa Interna de Retorno Modificada (TIRM):

Ecuación 1

Tasa Interna de Retorno Modificada (TIRM):

$$TIRM = \left(\frac{\text{Valor Futuro de los Flujos Positivos}}{\text{Valor Presente de los Flujos Negativos}} \right)^{1/n} - 1$$

Donde:

- Valor Futuro de los Flujos Positivos: Se calcula llevando los flujos positivos al final del período al costo de reinversión.
- Valor Presente de los Flujos Negativos: Se calcula trayendo los flujos negativos al presente al costo de financiamiento.
- n: Número de períodos.

Ecuación 2

Valor Presente Neto (VPN)

$$VPN = \sum_{t=0}^n \frac{C_t}{(1+r)^t} - C_0$$

Donde:

- C_t = Flujo de efectivo neto en el período (t).
- (r) = Tasa de descuento o tasa de retorno requerida.
- (t) = Período de tiempo (por ejemplo, año).

- (n) = Número total de períodos.
- C_0 = Inversión inicial.

Ecuación 3

Retorno sobre la Inversión (ROI) considerando el VPN

$$ROI = \left(\frac{VPN}{Costo\ de\ Inversión} \right) \times 100$$

Donde:

- VPN es el Valor Presente Neto de los flujos de efectivo futuros.
- Inversión Inicial es el costo inicial de la inversión.

4.2.7 Análisis de costo – beneficio

El análisis de costo-beneficio (ACB) constituye una herramienta para evaluar la viabilidad económica de proyectos de inversión, especialmente aquellos con implicaciones estructurales en la infraestructura pública. Permite contrastar cuantitativamente los beneficios proyectados con los costos incurridos, aportando evidencia técnica para decisiones de asignación eficiente de recursos (Goel & Sharma, 2022).

En contextos como el colombiano, donde las condiciones geográficas y presupuestales limitan la efectividad de los métodos tradicionales de mantenimiento vial, el ACB resulta particularmente relevante al sustentar la adopción de tecnologías automatizadas. La capacidad del ACB para monetizar impactos y proyectar valor presente neto (VPN) positivo convierte esta herramienta en un mecanismo de priorización técnica, más allá de percepciones subjetivas (Chen & Reniers, 2020). No obstante, su correcta implementación requiere una estructura metodológica sólida. Según Persky (2001), la diversidad de variables y supuestos exige una formulación analítica rigurosa. Drèze y Stern (1987) refuerzan esta idea al proponer el ACB como un procedimiento comparativo orientado a maximizar el bienestar colectivo desde una lógica económica y social.

En proyectos de inteligencia artificial aplicados al mantenimiento vial, el ACB permite evaluar con precisión los costos de implementación como sensores LiDAR, plataformas de análisis y capacitación frente a beneficios como la reducción de tiempos de inspección, la mejora en la

detección de fallas y el ahorro operativo. Esto posiciona al ACB no solo como un método financiero, sino como un instrumento estratégico para legitimar inversiones tecnológicas bajo criterios de eficiencia, sostenibilidad y racionalidad técnica.

4.2.8 Identificación y estimación de costos

La identificación y estimación precisa de costos constituye un insumo esencial para la aplicación rigurosa del análisis costo-beneficio (ACB), en tanto determina la solidez de las proyecciones financieras y la viabilidad de la intervención. Para tal fin, los costos se agrupan en dos categorías principales: costos iniciales, asociados a la adquisición, integración y puesta en marcha de la tecnología; y costos operativos, relacionados con su sostenibilidad funcional en el tiempo. Dado que la mera clasificación por categorías generales (como *hardware*, *software* o *personal*) resulta insuficiente para sustentar decisiones estratégicas, se incorpora a continuación la Tabla 4. la cual presenta una estimación referencial comparada de los principales componentes tecnológicos. Esta incluye rangos de precios internacionales Estados Unidos, Brasil y México, así como proyecciones aplicables al contexto colombiano. Su incorporación responde a la necesidad de otorgar mayor transparencia, trazabilidad y robustez técnica al análisis económico del proyecto.

Tabla 4. *Comparativo internacional de costos estimados por categoría tecnológica para proyectos de mantenimiento vial con inteligencia artificial.*

Categoría	Subcomponente / Ejemplo Comercial	Rango Estimado (USD)	Especificaciones Técnicas Representativas	EE. UU.	Brasil	México	Fuente / Referencia
Hardware	Sensor LiDAR – Velodyne VLP-16 / RIEGL VUX-1UAV	7,000 – 12,000	100m, 300.000 pts/s (VLP-16); 360° FOV, 1.2M pts/s (VUX-1UAV)	8,000–12,000	7,500–10,000	7,800–11,500	Velodyne.com, Riegl.com, Amazon Business, resellers LATAM (2023–2024)
Hardware	Dron RTK – DJI Matrice 300 RTK + Zenmuse L1	6,000 – 9,000	RTK, multisensor LiDAR RGB IMU, 55 min de vuelo	6,000–9,000	5,800–8,000	6,200–8,500	DJI Enterprise, MercadoLibre, DroneNerds, proveedores LATAM 2024
Software	Plataforma IA – Pix4D / Agisoft / AWS SageMaker	1,200 – 5,000	Modelado 3D, entrenamientos IA, análisis de nubes de puntos	2,000–5,000	1,800–4,500	2,000–4,000	Pix4D.com, AWS Pricing, Agisoft.com
Personal	Científico de Datos Senior /	2,000 – 9,000 (mes)	Roles: Senior (+5 años), Junior (1–2 años),	6,000–9,000	3,000–4,500	2,800–4,000	Glassdoor, LinkedIn Salaries,

	Ingeniero ML Junior		dedicación exclusiva				Statista, Talent.com (2023)
Infraestructura	Servidor GPU – Dell PowerEdge con NVIDIA A100	8,000 – 20,000	GPU A100 40GB, 128 GB RAM, SSD 2TB, Ubuntu Server	10,000– 20,000	9,000– 17,000	9,500– 18,000	Dell.com, NVIDIA, reportes de adquisición gubernamental LATAM (2024) OECD Report 2023,
Mantenimiento	Soporte técnico / actualizaciones anuales	15% – 25% del total	Licencias, refacciones, actualizaciones y soporte remoto	15– 25%	15– 20%	10– 20%	McKinsey Tech Ops Benchmark, contratos estándar

Fuente: Elaboración propia con base en precios de referencia obtenidos de Velodyne.com, Riegl.com, DJI Enterprise, MercadoLibre LATAM, AWS Pricing, Agisoft.com, Pix4D.com, Glassdoor, LinkedIn Salaries, Talent.com, Dell.com, NVIDIA, informes gubernamentales de adquisiciones LATAM (2023–2024), y benchmark técnico de la OECD y McKinsey Tech Ops (2023).

El análisis costo-beneficio (ACB) constituye un instrumento esencial para la evaluación económica de proyectos tecnológicos orientados al mantenimiento vial, particularmente en contextos donde la eficiencia del gasto público y la sostenibilidad operativa son imperativos. Al integrar métricas financieras como el Valor Presente Neto (VPN) y el Retorno sobre la Inversión (ROI), el ACB permite determinar con rigurosidad la rentabilidad de las soluciones basadas en inteligencia artificial frente a métodos tradicionales. Complementariamente, el análisis de sensibilidad amplía el alcance evaluativo al identificar la resiliencia del proyecto ante variaciones en costos, beneficios o tasas de descuento. En conjunto, estos enfoques conforman una base analítica robusta para orientar decisiones de inversión informadas, maximizar impactos positivos y mitigar riesgos financieros y operacionales en escenarios de alta complejidad estructural.

5. METODOLOGÍA

5.1 Revisión sistemática de la literatura

Se llevó a cabo una revisión sistemática en las bases de datos académicas Scopus, IEEE Xplore, Web of Science y, de forma complementaria, Google Scholar, enfocada en publicaciones entre 2010 y 2024 y restringida a los idiomas inglés y español. La búsqueda se estructuró con palabras relacionadas con la temática, tales como "road damage detection", "pavement distress", "machine learning", "deep learning", "inteligencia artificial" e "infraestructura vial". Para maximizar la pertinencia, estas se combinaron utilizando operadores booleanos (AND, OR) y comillas para frases exactas, aplicándose en los campos de título, resumen y palabras de cada base de datos.

Se aplicaron criterios de inclusión y exclusión en dos fases para garantizar la calidad, actualidad y pertinencia de los estudios seleccionados: una revisión inicial de títulos y resúmenes, seguida por la lectura a texto completo de los artículos preseleccionados. Esta estrategia permitió identificar tendencias, metodologías frecuentes, arquitecturas de IA utilizadas (como CNN, YOLO, Mask R-CNN), métricas de evaluación (como mAP, F1 Score) y bases de datos de referencia. Los datos se extrajeron sistemáticamente en una matriz en Excel. Los hallazgos se centraron en el uso de IA para la gestión y detección de daños en vías, analizándose mediante síntesis cualitativa y temática para derivar las aplicaciones potenciales y lecciones aprendidas directamente transferibles al contexto colombiano.

5.2 Análisis del contexto colombiano

Para sustentar la aplicabilidad de la Inteligencia Artificial (IA) en la detección de daños viales, se realizó una revisión documental de carácter mixto, integrando análisis cuantitativo y cualitativo de fuentes técnicas relevantes del contexto colombiano.

Las fuentes cuantitativas se obtuvieron de las bases de datos públicas de INVÍAS del año 2024, en formato Excel. Contenían información sobre el estado del pavimento, la longitud y la clasificación técnica de los tramos. Estos datos se descargaron, organizaron y procesaron estadísticamente en Excel para generar un panorama del deterioro de la red vial y sus costos de mantenimiento asociados.

Para la obtención de información cualitativa, cabe precisar que no se realizaron entrevistas directas. En su lugar, se llevó a cabo un análisis de contenido temático de documentos oficiales de INVÍAS (incluyendo manuales de inspección, procedimientos operativos y declaraciones institucionales) y transcripciones de intervenciones públicas del director técnico en foros académicos y mediáticos. Este enfoque garantizó la validez y representatividad de las perspectivas institucionales al basarse en fuentes verificables. Su rigor se fundamentó en la aplicación de ejes temáticos predefinidos para una codificación sistemática del contenido, permitiendo extraer perspectivas cruciales sobre la operación, las estrategias y los desafíos institucionales. Esta aproximación cualitativa complementó los datos cuantitativos, aportando una comprensión profunda del contexto y las perspectivas relevantes para la gestión vial en Colombia.

5.3 Análisis comparativo

Se realizó un análisis comparativo con enfoque multicriterio cuantitativo para contrastar la aplicación de la inteligencia artificial (IA) en la inspección de daños viales en estudios internacionales frente al contexto técnico y operativo colombiano.

Para este fin, se seleccionó un subconjunto de estudios internacionales de la revisión sistemática (Sección 5.1). Se elaboró una matriz comparativa específica donde cada estudio fue evaluado sistemáticamente con base en los siguientes criterios: precisión en la detección de daños, costos operativos asociados y tiempos requeridos para la inspección. La valoración se llevó a cabo mediante la asignación de una ponderación numérica específica a cada criterio, lo cual permitió cuantificar su importancia relativa y generar una puntuación consolidada para cada enfoque. Esta puntuación facilitó la comparación directa y objetiva entre las prácticas internacionales y las condiciones del entorno colombiano para identificar la adaptabilidad y lecciones aprendidas relevantes.

5.4 Análisis de costo-beneficio

Se estructuró un modelo financiero para estimar la viabilidad económica de implementar un sistema basado en Inteligencia Artificial (IA) para la detección de daños en infraestructura vial. Para ello, se empleó Microsoft Excel, herramienta seleccionada por su versatilidad para proyectar

flujos de caja, automatizar cálculos y aplicar indicadores financieros. El horizonte de análisis se estableció en siete años, con el Año 0 destinado a la inversión inicial (CAPEX) y los Años 1 a 7 a la etapa operativa del sistema.

El proceso de modelado incluyó las siguientes etapas: Definición y Estimación de Variables: Se agruparon las variables financieras en cinco categorías: costos iniciales (CAPEX), costos operativos con IA, costos base sin IA, ahorros esperados e ingresos adicionales. La estimación de cada variable se realizó de manera rigurosa, basándose en cotizaciones formales, tarifas de mercado, referencias sectoriales y entrevistas a expertos. Los costos de inversión abarcaron adquisición tecnológica, desarrollo de software, integración y capacitación; los operativos contemplaron mantenimiento, soporte, consumo energético y personal especializado. Los beneficios consideraron ahorros por eficiencia operativa y nuevos ingresos por monetización de datos o servicios.

Proyección de Flujos de Caja e Indicadores Financieros: El modelo proyectó los flujos netos anuales (beneficios menos costos) y construyó el flujo acumulado para identificar la recuperación de la inversión. Se aplicaron los indicadores financieros estándar: Valor Presente Neto (VPN), Tasa Interna de Retorno (TIR) y Retorno sobre la Inversión (ROI), tanto en sus versiones simple como anualizada. La tasa de descuento del 8% utilizada para la valoración se justificó con base en los lineamientos del Departamento Nacional de Planeación (DNP) para proyectos públicos de mediano riesgo en Colombia.

Análisis de Sensibilidad: Para garantizar la solidez metodológica del modelo y evaluar su robustez ante la incertidumbre, se aplicó un análisis de sensibilidad. Este consistió en la simulación de escenarios optimista, base y pesimista, evaluando variaciones de $\pm 10\%$ y $\pm 20\%$ en ingresos y ahorros. Esto permitió identificar la resiliencia del modelo ante cambios en variables y los puntos de inflexión críticos.

5.5 Elaboración de recomendaciones estratégicas

Las recomendaciones estratégicas se formularon a partir del análisis documental y técnico desarrollado en la investigación, considerando las dimensiones técnica, regulatoria y socioeconómica. Su priorización se estructuró mediante una matriz de evaluación multicriterio,

un enfoque seleccionado por su capacidad para ofrecer una valoración sistemática, transparente y cuantificable, esencial para la toma de decisiones informadas en contextos institucionales complejos.

El proceso de priorización incluyó los siguientes pasos: Se establecieron criterios predefinidos para valorar cada propuesta: impacto estratégico, viabilidad técnica, factibilidad económica, alineación normativa, requerimientos de recursos, riesgo de implementación y sostenibilidad.

Recolección de juicio experto: La evaluación de cada recomendación frente a estos criterios se realizó con el apoyo de juicio experto. Este proceso se facilitó mediante un proceso estructurado (con elementos de la Técnica Delphi), que incluyó rondas de evaluación para consolidar perspectivas diversas y mitigar sesgos, asegurando la solidez de las valoraciones.

Ponderación y calificación en la matriz: Los expertos asignaron una ponderación a cada criterio y calificaron cada recomendación individualmente, utilizando una escala de valoración uniforme. Cálculo de prioridad y ranking: La puntuación final de cada recomendación se obtuvo multiplicando la calificación de cada criterio por su peso ponderado, sumando los resultados para generar un ranking de prioridad.


6. RESULTADOS

6.1 Evaluar la utilidad de la inteligencia artificial (IA) en la identificación de daños en infraestructuras viales, analizando el costo-beneficio de la adaptación de esta tecnología en el contexto colombiano

En el contexto colombiano, la planificación estratégica de la infraestructura vial recae en el Ministerio de Transporte, entidad que define las directrices de política pública en materia de tránsito, transporte y conectividad. Su implementación técnica se delega al Instituto Nacional de Vías (INVIAS), organismo adscrito con responsabilidad directa sobre la red vial nacional no concesionada, que actualmente abarca más de 8.500 kilómetros pavimentados. El INVIAS no solo ejecuta proyectos de construcción, mantenimiento y rehabilitación, sino que también desarrolla ejercicios sistemáticos de diagnóstico de las condiciones funcionales y estructurales de la red, los cuales constituyen insumos fundamentales para la asignación eficiente de recursos públicos y la toma de decisiones basadas en evidencia.

Conforme al más reciente inventario nacional, se observa una distribución dispar del estado de conservación de la red: el 47% se encuentra en condiciones buenas o muy buenas, mientras que el 19,6% evidencia deterioro significativo (malo o muy malo), lo que no solo compromete la eficiencia del sistema de transporte, sino que genera externalidades negativas sobre la seguridad vial, los costos logísticos y la equidad territorial. La Figura 3 sintetiza esta distribución porcentual por condición, constituyéndose en un punto de partida para el análisis sobre la pertinencia de incorporar tecnologías disruptivas como la inteligencia artificial en los procesos de inspección y mantenimiento vial.

Figura 3. Estado de la red vial pavimentada en Colombia (8.526,39 km): distribución porcentual y kilómetros por condición



Fuente: Elaboración propia con base en datos del Instituto Nacional de Vías (INVÍAS), 2024.


La información anterior evidencia que, aunque existe una parte importante de la red en condiciones aceptables, persiste una proporción crítica de vías en mal estado que afecta la conectividad nacional, incrementa los tiempos de desplazamiento y eleva el riesgo de accidentalidad. Por lo general, el INVÍAS realiza diagnósticos basados en inspecciones visuales efectuadas por profesionales expertos. Sin embargo, esta metodología presenta varias limitaciones: es altamente subjetiva, dependiente de la experiencia individual, y no garantiza evaluaciones cuantitativas ni precisión estructural (Coenen & Golroo, 2017).

Estas limitaciones han sido documentadas ampliamente: la variabilidad entre evaluadores humanos, el sesgo por fatiga y las condiciones adversas del clima dificultan la recolección estandarizada de datos confiables, generando retrasos, costos elevados y diagnósticos imprecisos (INVIAS, 2022). En consecuencia, el INVÍAS ha iniciado un proceso de exploración tecnológica mediante sus “Ruedas de Innovación”, evaluando 43 soluciones emergentes, incluyendo sistemas de visión artificial y aprendizaje automático para el diagnóstico vial. No obstante, hasta la fecha no se han publicado estudios con métricas cuantitativas verificables que permitan comparar el desempeño real de estas tecnologías frente al método tradicional.

A pesar del creciente interés institucional y la exploración tecnológica, persisten desafíos estructurales para una adopción efectiva, como la ausencia de métricas estandarizadas en los informes oficiales del INVÍAS. Esta falta de trazabilidad ha sido señalada por expertos como una

debilidad para justificar o descartar la adopción de herramientas de inteligencia artificial. Frente a este vacío, la academia ha comenzado a suplir esa brecha con investigaciones rigurosas. Un referente Hernández Ortiz (2024), desarrollada en la Universidad del Norte, la cual presenta un modelo basado en árboles de decisión potenciados (GBDT) que logra una precisión del 99% en la predicción de parámetros de deflexión del pavimento. Este estudio, sustentado en una base de datos estructurada con más de 5.000 registros de campo y variables medidas bajo condiciones controladas, constituye el referente más robusto en Colombia sobre el uso de IA para diagnóstico vial, garantizando confiabilidad metodológica. Adicionalmente, en el marco de dicha investigación, se evaluó la precisión de la IA en la identificación de daños por capa del pavimento, arrojando resultados altamente prometedores que se presentan en la Figura 4.

Figura 4. Precisión, Sensibilidad y Especificidad de Modelos de IA en la Identificación de Daños por Capa del Pavimento.



Fuente: Elaboración propia con base en datos de Hernández Ortiz (2024), Universidad del Norte.

Nota: Los modelos probabilísticos de IA muestran una alta precisión para identificar condiciones críticas. La información detallada de precisión, sensibilidad y especificidad de cada capa se muestra directamente sobre cada barra para una visibilidad inmediata

Esta Figura 5 ilustra que los modelos de IA pueden alcanzar precisiones generales muy elevadas en la identificación de condiciones en las diferentes capas del pavimento, con la Capa Intermedia mostrando la mayor precisión (98.57%), seguida de la Capa Inferior (Subrasante) con 92.94% y la Capa Superficial (HMA) con 85.00%. Es importante destacar que estas métricas incluyen, además de la precisión, la sensibilidad y especificidad, lo que proporciona una visión más completa del desempeño del modelo. La alta sensibilidad (99.79%) para la Capa Superficial, por ejemplo, evidencia una excelente capacidad para detectar la presencia de daños en esta capa, aunque la precisión general sea ligeramente menor que en otras capas. El contraste metodológico entre la inspección tradicional y la IA, ahora con métricas cuantificables de precisión y tamaños muestrales definidos en el ámbito académico, se resume en la Tabla 5.

Tabla 5. *Comparativo entre método tradicional del INVÍAS e IA en evaluación vial*

Criterio	Método tradicional INVÍAS	Inteligencia Artificial (IA - GBDT)
Tipo de inspección	Visual, in situ	Automatizada, predictiva
Precisión documentada	No cuantificada; depende del evaluador	99% (predicción de deflexión, Hernández Ortiz, 2024); Ver Figura 2 para precisión por capa de daño
Tamaño muestral	No reportado públicamente	10.000 combinaciones (simulado, entrenamiento y validación)
Base de cálculo	Criterio técnico-experto (subjetivo)	Algoritmo entrenado con datos estructurales cuantitativos; Modelos probabilísticos para detección de daños
Tiempo de ejecución por segmento	Alto (promedio 2-3 h/km)	Bajo (minutos con procesamiento en lote)
Costo por tramo inspeccionado	Elevado (personal, viáticos, logística)	Bajo (una vez implementado el modelo entrenado)
Aplicabilidad en zonas remotas	Limitada	Alta (con drones o imágenes satelitales)

Fuente: Elaboración propia con base en Hernández Ortiz (2024) e INVÍAS (2022).

A la fecha, no existen estudios piloto públicos que documenten tamaño muestral, sensibilidad, especificidad o tasa de error de modelos IA aplicados a vías reales colombianas.

A pesar de la sólida evidencia académica sobre la capacidad de la IA, existe una brecha significativa en su aplicación institucional en Colombia. Se identifican lagunas de evidencia significativa en las iniciativas que utilizan IA a nivel estatal, lo cual limita la materialización de los beneficios observados en entornos controlados:

- **Proyecto “IA Vías Terciarias” del DNP:** Este proyecto emplea imágenes satelitales (4.77 m/píxel) para georreferenciar vías terciarias. No obstante, no incluye una detección granular de daños superficiales ni publica métricas de precisión, sensibilidad o especificidad, impidiendo una evaluación cuantitativa de su capacidad para el diagnóstico de deterioro.
- **Ruedas de Innovación del INVÍAS:** A pesar de haber evaluado 43 tecnologías emergentes, el INVÍAS no ha divulgado información sobre la precisión alcanzada por los modelos de IA implementados ni sobre su rendimiento comparado con la inspección visual humana bajo condiciones operativas reales. Esta falta de transparencia en los resultados limita la validación y la justificación de inversiones a gran escala.

A la fecha, no existen estudios piloto públicos en Colombia que documenten tamaño muestral, sensibilidad, especificidad o tasa de error de modelos de IA aplicados a vías reales del país, utilizando un enfoque científico-operativo que permita la replicabilidad y el contraste con los métodos tradicionales. Esta "brecha de datos" impide la adopción generalizada de la tecnología, a pesar del alto potencial técnico demostrado en la academia.

Costo-Beneficio y Prospectivas para la Adaptación de la IA. La evidencia académica evidencia que la IA puede superar ampliamente al método tradicional en términos de precisión, eficiencia y costo. La automatización del diagnóstico reduce la subjetividad, acelera los procesos y permite una asignación de recursos más estratégica al identificar de manera precisa las secciones más afectadas. Los beneficios se proyectan no solo en la optimización de los presupuestos de mantenimiento, sino también en la mejora de la seguridad vial y la reducción de los costos logísticos asociados a una infraestructura vial deficiente.

Sin embargo, la incorporación efectiva de la IA en el contexto colombiano requiere cerrar la brecha entre investigación y práctica. Esto implica desarrollar estudios de validación técnica con participación de actores públicos (INVÍAS, Ministerio de Transporte), el sector privado y las instituciones de educación superior. Tales pilotos controlados deberán:

- Validar las tasas de precisión de la IA en la detección de daños superficiales (baches, fisuras, desprendimientos) en condiciones reales de operación en Colombia.

- Documentar el tamaño muestral, la sensibilidad, la especificidad y la tasa de error de los modelos.
- Medir los impactos logísticos, financieros y funcionales del cambio metodológico.
- Solo a través de esta validación empírica y transparente se podrá fundamentar la decisión de inversión tecnológica desde una lógica de costo-beneficio verificable y se podrá avanzar hacia la masificación de estas herramientas disruptivas en la gestión de la infraestructura vial nacional.

6.1.1 Efectividad de la inteligencia artificial (IA) en la identificación de daños en infraestructuras viales en el contexto colombiano

Aplicaciones de las redes neuronales artificiales en la ingeniería del pavimento. Las Redes Neuronales Artificiales (ANN) son herramientas avanzadas que abordan problemas complejos y no lineales en diversas disciplinas. Según el estudio de Banharnsakun (2017), estas redes se emplean ampliamente en la detección y clasificación de daños en superficies de una vía debido a su capacidad para almacenar y obtener grandes volúmenes de datos y representar el conocimiento a través de cálculos paralelos (Gong et al., 2019).

Una de las configuraciones más utilizadas es la red neuronal multicapa con el algoritmo de aprendizaje Backpropagation (BP), reconocida por su efectividad en la predicción, lo que resalta la efectividad de las redes BP en la detección automática de los daños en una vía. Las ANN procesan la información de manera simultánea durante su fase de entrenamiento, permitiéndoles aprender de manera eficiente y mejorar su desempeño con la experiencia acumulada. Esta capacidad de procesamiento paralelo facilita la resolución de problemas complejos que son difíciles de abordar mediante modelos cuantitativos para analizar datos y resolver problemas (Tarawneh & Nazzal, 2014).

Gracias a su estructura de capas interconectadas, estas redes son ideales para el reconocimiento de voz, análisis de imágenes y procesamiento de lenguaje natural (Abdelaziz et al., 2020; Sollazzo et al., 2017). Existen varios tipos de ANN; Perceptrones: Modelos básicos utilizados en clasificación, Redes Neuronales Convolucionales (CNN): Especializadas en el análisis de imágenes, estas redes reconocen patrones espaciales y características visuales y

Redes Neuronales Recurrentes (RNN): Adecuadas para el procesamiento de series temporales y datos secuenciales, como textos y secuencias de voz.

De igual manera, la IA puede analizar grandes volúmenes de datos visuales de manera automática, reduciendo el riesgo de errores humanos y mejorando la eficiencia operativa a bajo costo. En contraste con los métodos tradicionales de inspección visual que implementa el INVIAS dependen en gran medida del profesionalismo y responsabilidad de una persona, lo que puede ser subjetivo y menos consistente, la integración de la IA ha revolucionado este campo al ofrecer, soluciones más eficaces y objetivas (Hoang, 2018). Sin embargo, en Colombia aún no se ha implementado inteligencia artificial de forma amplia para identificar los daños en las vías pavimentadas.

6.1.2 Comparación de la precisión de la IA y los métodos tradicionales en la inspección de daños viales

La inteligencia artificial (IA) ha demostrado una precisión superior en la identificación de daños viales en comparación con los métodos tradicionales. En particular, las redes neuronales convolucionales (CNN) y el aprendizaje profundo (DL) analizan grandes volúmenes de datos, detectan defectos con mayor exactitud y reducen el tiempo de inspección (Hoang, 2018). Además, minimizan errores humanos y optimizan la eficiencia operativa a bajo costo.

Los métodos tradicionales, como los empleados por INVIAS, dependen del criterio del inspector o profesional, lo que puede generar inconsistencias en los resultados. Aunque siguen siendo esenciales, la integración de IA ha revolucionado la inspección vial al proporcionar resultados más confiables (Hoang, 2018). Investigaciones de Lei Zhang et al. (2016) y Keqin Chen et al. (2019) han validado la eficacia de CNN en la detección de grietas en estructuras de hormigón, mientras que estudios de Hiroya Maeda et al. (2018) y Sadra Naddaf-Sh et al. (2020) han confirmado su precisión en la clasificación de daños en carreteras.

Los sistemas de inteligencia artificial (IA) ayudan a reducir la subjetividad en el análisis al basarse en datos y algoritmos en lugar de interpretaciones humanas, mejora la precisión en la detección de fallas y optimiza los costos de mantenimiento, consolidándose como una herramienta fundamental para la gestión eficiente de la infraestructura vial. Como se presenta en la Tabla 2,

los modelos avanzados de IA, como Faster R-CNN y RNA, alcanzan altas precisiones, aunque requieren datos específicos y condiciones controladas. A pesar de su mayor precisión, estos modelos enfrentan desafíos relacionados con la calidad de los datos y la falta de conjuntos estandarizados.

6.1.3 Análisis costo-beneficio de la implementación de inteligencia artificial en los costos de mantenimiento vial en Colombia

El mantenimiento de la red vial en Colombia enfrenta limitaciones estructurales derivadas de su amplia extensión, condiciones geográficas disímiles y restricciones presupuestarias. Tradicionalmente, el país ha dependido de métodos manuales e inspecciones visuales, los cuales, si bien han sido funcionales, presentan desventajas importantes: altos costos operativos, demoras significativas y subjetividad en la evaluación técnica.

Este estudio plantea la incorporación de inteligencia artificial (IA) como alternativa para modernizar la gestión del mantenimiento vial, a partir de los avances recientes impulsados por entidades como el Departamento Nacional de Planeación (DNP), INVÍAS y el Ministerio de Transporte. Experiencias piloto, como la evaluación de la red vial terciaria mediante imágenes satelitales (cobrimiento del 87 % del territorio nacional), han sido validadas por organismos multilaterales como el BID y USAID, mostrando resultados prometedores en términos de eficiencia diagnóstica y focalización de intervenciones.

6.1.3.1 Costos de implementación de IA. La adopción de IA conlleva costos iniciales y operativos que deben ser analizados con precisión:

- Infraestructura tecnológica: adquisición de sensores (LiDAR, cámaras multiespectrales), drones, plataformas de análisis y licencias de software especializado.
- Integración y adaptación institucional: interoperabilidad con sistemas existentes (p. ej., bases de datos del INVÍAS), actualización de protocolos y arquitectura digital.
- Capacitación técnica: formación del talento humano en uso, interpretación y mantenimiento de sistemas inteligentes.
- Sostenibilidad operativa: actualización continua de algoritmos, soporte técnico y reposición tecnológica.

6.1.3.2 Costos de implementación de IA Beneficios esperados. La aplicación de IA genera beneficios multidimensionales:

- Eficiencia operativa: reducción significativa de costos frente a las inspecciones tradicionales, automatización de procesos y focalización de recursos.
- Mayor precisión y oportunidad: detección temprana de fallas con datos objetivos y análisis predictivo, lo que minimiza errores humanos y reduce tiempos de intervención.
- Prolongación del ciclo de vida vial: intervenciones preventivas y focalizadas que evitan deterioros estructurales mayores.
- Mejora en la seguridad vial: identificación de zonas críticas y reducción de siniestralidad mediante mantenimientos oportunos y mejor infraestructura (Sadeghian, 2023).

6.1.3.3 Costos de implementación de IA Evaluación costo-beneficio. Pese a los costos iniciales elevados, el análisis costo-beneficio (ACB) evidencia un balance positivo. La reducción en gastos operativos, el aumento en la eficacia de mantenimiento, la mejora en la asignación de recursos y el impacto social en seguridad vial justifican la inversión. Indicadores como el valor presente neto (VPN), el retorno sobre la inversión (ROI) y el análisis de sensibilidad son herramientas fundamentales para proyectar escenarios viables.

6.1.3.4 Costos de implementación de IA Lecciones internacionales. Una revisión sistemática de literatura (2010–2024), a partir de bases como IEEE Xplore, ScienceDirect y Scopus, evidencia que países como Japón, EE. UU., India y China han integrado IA con éxito en tareas de detección, clasificación y priorización de daños viales. Estas experiencias ofrecen metodologías replicables y aprendizajes valiosos para el caso colombiano, en términos técnicos, institucionales y presupuestales.

6.1.4 Casos internacionales de aplicación de inteligencia artificial en la identificación de daños en infraestructuras viales: Lecciones aprendidas

Caso de Estudio 1: Análisis de Gadsden, una Ciudad Localizada en el Condado de Gadsden, Alabama, Estados Unidos

En 2019, la ciudad de Gadsden (Alabama), con una red vial de aproximadamente 350 millas y una población de 35.000 habitantes, implementó un sistema inteligente para optimizar el mantenimiento vial. Este proceso fue liderado por el director de Ingeniería, Heath Williamson, y documentado por Michelin Mobility Intelligence en su informe técnico titulado Case Study: City of Gadsden, AL (s.f.). La ciudad enfrentaba una infraestructura vial altamente deteriorada, un modelo de mantenimiento reactivo y restricciones presupuestarias que dificultaban la inspección sistemática y la planificación a largo plazo.

La solución adoptada integró tecnologías de inteligencia artificial (IA), redes neuronales y dispositivos móviles. Utilizando smartphones montados en vehículos municipales, se recolectaron datos visuales sobre el estado de las vías, que fueron procesados mediante algoritmos de aprendizaje automático. Los resultados se visualizaron en un sistema de información geográfica (GIS), permitiendo diagnósticos automatizados, localización precisa de daños y priorización de intervenciones.

- Resultados principales
- Reducción del 79 % en los costos operativos, con un ahorro directo de USD 130.000 en comparación con métodos convencionales.
- Disminución del 40 % en el tiempo de evaluación, acelerando las decisiones técnicas.
- Mejora en la asignación de recursos a partir de datos georreferenciados y objetivos.
- Implementación de un sistema adaptable, con capacidad de actualización a partir de retroalimentación continua (Michelin Mobility Intelligence, s.f.a).

Limitaciones y barreras identificadas. El informe no detalla las barreras técnicas durante la implementación; sin embargo, se infiere que la integración con los sistemas institucionales existentes y la necesidad de capacitación del personal técnico representaron retos iniciales. Además, el escalamiento del modelo a ciudades con mayor densidad urbana o redes viales más

complejas podría requerir ajustes técnicos y operativos significativos. En términos de interoperabilidad, el éxito de la iniciativa dependió de la compatibilidad entre el sistema de detección, la base de datos urbana y las plataformas geoespaciales municipales. No se documentaron explícitamente consideraciones sobre privacidad de datos, aunque el uso de dispositivos móviles implica riesgos asociados al registro de imágenes en espacios públicos, lo que evidencia la necesidad de protocolos éticos claros.

Vinculación con la literatura especializada. Este caso empírico se alinea con la literatura sobre mantenimiento predictivo y gestión de activos viales basados en datos (Guo et al., 2024; Ragnoli et al., 2018), en la que se destaca la transición desde modelos reactivos hacia enfoques proactivos y optimizados por IA. Tal como lo plantea Drèze y Stern (1987), una adecuada valoración costo-beneficio, acompañada de tecnologías inteligentes, permite maximizar el retorno social de la inversión en infraestructura. Asimismo, estudios sobre adopción tecnológica en gobiernos locales (Jagatheesaperumal et al., 2023) evidencian que el liderazgo institucional y la viabilidad presupuestaria son factores determinantes para la sostenibilidad de estos modelos. En conjunto, la experiencia de Gadsden no solo constituye un referente técnico de implementación exitosa, sino también un modelo replicable para contextos con restricciones presupuestarias como Colombia, siempre que se acompañe de adecuadas políticas de integración institucional, formación técnica y gestión de datos sensibles.

Caso de estudio 2: La ciudad de South Bend se encuentra en el estado de Indiana, en los Estados Unidos

En 2017, la ciudad de South Bend (Indiana), con una red vial de aproximadamente 885 km y más de 100.000 habitantes, adoptó un sistema basado en inteligencia artificial para superar las limitaciones de sus métodos tradicionales de evaluación vial, los cuales requerían hasta tres meses y múltiples recursos humanos para completar diagnósticos visuales poco confiables. El proyecto fue liderado por el ingeniero Scott Kreeger y consistió en la integración de una plataforma de gestión inteligente del pavimento, suscrita por la ciudad, que automatiza la captura, análisis y visualización de datos a través de IA, integrándose con sistemas GIS como ArcGIS.

Entre los principales resultados destacan:

- Reducción del tiempo de evaluación a menos de un mes gracias a rutas optimizadas y recolección automatizada de datos.
- Ahorros operativos y reducción de personal requerido por unidad de recolección (una persona por vehículo).
- Centralización de datos y disponibilidad en la nube (plataforma RoadWay), mejorando la colaboración interinstitucional.
- Priorización eficiente de proyectos viales con criterios objetivos y verificables.
- Sostenibilidad y adaptabilidad, al integrarse fácilmente a otras plataformas tecnológicas de gestión urbana.

Sin embargo, el estudio no detalla limitaciones explícitas. Es posible suponer que desafíos como la escalabilidad del sistema, la capacitación técnica del personal y la interoperabilidad con otras plataformas municipales son aspectos a considerar. Además, la gestión ética de los datos, especialmente aquellos recolectados desde el espacio público, requiere protocolos claros para garantizar la privacidad y seguridad de la información.

Este caso se alinea con los enfoques de mantenimiento predictivo descritos en Guo et al. (2024) y la literatura sobre sistemas de gestión de activos viales basados en datos, como lo señalan Ranyal et al. (2022) y Ragnoli et al. (2018). Asimismo, la adopción de soluciones digitales en gobiernos locales responde a modelos de madurez tecnológica en la gestión pública, como plantea Jagatheesaperumal et al. (2023), donde la toma de decisiones basada en evidencia refuerza la legitimidad institucional y mejora la asignación de recursos (Michelin Mobility Intelligence, s.f.b).

Caso de estudio 3: El estudio se realizó en Plumstead Township, un municipio ubicado en el condado de Bucks, en el estado de Pensilvania, Estados Unidos

El municipio de Plumstead Township, ubicado en el condado de Bucks, Pensilvania (EE. UU.), emprendió un proceso de modernización tecnológica orientado a superar las limitaciones del modelo convencional de gestión vial, basado en inspecciones visuales y levantamiento manual de datos. Esta estrategia, liderada por McMahon Associates Inc. (actualmente parte de Bowman Company), se centró en la automatización de la evaluación de pavimentos mediante tecnologías basadas en inteligencia artificial, abarcando la totalidad de la red vial del municipio, compuesta

por 117 kilómetros. El objetivo principal fue mejorar la precisión, reducir los tiempos de diagnóstico y optimizar la asignación presupuestaria para las intervenciones viales, beneficiando a una población de 14.021 habitantes.

El sistema de inteligencia artificial implementado integró algoritmos de aprendizaje automático y redes neuronales profundas para la detección automatizada de deterioros, tales como grietas, fisuras o baches. Para ello, se utilizaron smartphones equipados con cámaras de alta resolución y GPS, lo cual permitió capturar imágenes georreferenciadas de las vías. Estos datos fueron procesados mediante la plataforma RoadWay, un sistema especializado en la evaluación y priorización de mantenimiento vial, que posibilitó el almacenamiento en la nube, el acceso centralizado a los resultados y la interoperabilidad con otras herramientas de planificación urbana.

Entre los resultados más relevantes del proyecto se destacan:

- Reducción significativa en el tiempo de evaluación, gracias a la automatización del proceso de inspección.
- Disminución de la dependencia de personal técnico, con un enfoque en análisis automatizados.
- Acceso centralizado y confiable a la información, mediante la plataforma RoadWay, lo que fortaleció la trazabilidad y la toma de decisiones.
- Optimización en la asignación de recursos públicos, al priorizar intervenciones con base en evidencia objetiva y en tiempo real.

Limitaciones y desafíos. Aunque el estudio no detalla exhaustivamente las barreras enfrentadas, es posible inferir desafíos comunes en este tipo de iniciativas, como la necesidad de capacitación del personal local, la adaptación institucional a herramientas digitales, y los retos relacionados con la interoperabilidad de plataformas existentes. Además, en contextos de menor escala o recursos, como municipios rurales, pueden surgir limitaciones para replicar el modelo debido a restricciones presupuestarias y capacidad técnica.

Vinculación con literatura académica. La experiencia de Plumstead Township se alinea con los enfoques contemporáneos sobre mantenimiento predictivo y gestión de activos basada en datos,

como señalan Guo et al. (2024) y Zhang & Wang (2022). La transición hacia sistemas inteligentes para la evaluación vial se inscribe en los marcos de madurez digital en gobiernos locales (OECD, 2023), y representa un caso ilustrativo de adopción tecnológica efectiva orientada a la eficiencia operativa y la sostenibilidad de la infraestructura pública (Michelin Mobility Intelligence, s.f.c).

Caso de estudio 4: El estudio se realizó en Dublin, (OH), una ciudad ubicada en el estado de Ohio, Estados Unidos

La ciudad de Dublin, Ohio (EE. UU.), emprendió en 2022 un proceso de modernización en la gestión de su red vial mediante tecnologías de inteligencia artificial (IA), orientadas a mejorar la eficiencia operativa, reducir costos y fortalecer la planificación basada en evidencia. El proyecto, liderado por Robert J. Taylor, PE, director de Gestión de Activos y Servicios de Soporte, abarcó 278 millas (aproximadamente 447,4 km) de vías pavimentadas, y se implementó mediante la solución Michelin Better Roads, basada en aprendizaje automático y dispositivos móviles para el levantamiento automatizado de datos (Michelin Mobility Intelligence, s.f.c).

Entre los principales logros del proyecto destacan la significativa reducción en el tiempo y costo del levantamiento de información, la visualización estandarizada del estado de las vías mediante una escala codificada por colores, la eliminación de intermediarios tecnológicos y la integración efectiva con plataformas institucionales como ArcGIS. La ciudad logró mayor autonomía en la captura, procesamiento y uso de los datos, lo cual se tradujo en decisiones de mantenimiento más oportunas, transparentes y eficientes.

Limitaciones y desafíos. Aunque la experiencia fue exitosa, el estudio no profundiza en las barreras asociadas a la adopción tecnológica, tales como la necesidad de capacitación interna, la gestión del cambio organizacional, ni en los mecanismos para garantizar la protección de datos en sistemas interoperables. Además, el grado de madurez institucional y presupuestario de Dublin puede dificultar la extrapolación directa del modelo a ciudades con menor capacidad técnica o financiera.

Vinculación con literatura académica. Este caso se alinea con los postulados sobre mantenimiento predictivo basados en big data (Guo et al., 2024; Ranyal et al., 2022) y con los marcos conceptuales de gobernanza digital en gobiernos locales (OECD, 2023). La experiencia

refuerza el enfoque de gestión de activos viales sustentado en evidencia objetiva y análisis automatizados, como mecanismo para optimizar la inversión pública y reducir el deterioro acumulado de las infraestructuras.

En conjunto, la experiencia de Dublin no solo constituye un referente técnico de implementación exitosa, sino también un modelo replicable para contextos con restricciones presupuestarias como Colombia, siempre que se acompañe de adecuadas políticas de integración institucional, formación técnica del personal y mecanismos sólidos de gestión de datos sensibles (Michelin Mobility Intelligence. (s.f.d).

Caso de Estudio 5: El estudio se realizó en Van Wert, OH, una ciudad ubicada en el estado de Ohio, Estados Unidos Van Wert, OH aprovechó el poder de las soluciones de IA

El municipio de Van Wert, ubicado en el estado de Ohio (Estados Unidos), emprendió en 2022 un proceso de modernización de su sistema de mantenimiento vial mediante la implementación de soluciones basadas en inteligencia artificial (IA). Esta iniciativa surgió en respuesta a los desafíos estructurales que enfrentaba la ciudad, como la ausencia de un inventario vial actualizado, evaluaciones técnicas con bajo nivel de estandarización, y limitaciones en la planificación estratégica de intervenciones. El proyecto fue liderado por Bill Lawson, Supervisor de Ingeniería local, y se orientó a fortalecer la toma de decisiones técnicas con base en datos objetivos. La cobertura del estudio abarcó 80 millas (aproximadamente 128,75 km) de red vial urbana, beneficiando directamente a los más de 11.000 habitantes y comerciantes de la ciudad (Vialytics, s.f.).

El sistema implementado consistió en una solución integral de evaluación automatizada, que combinó visión computacional, aprendizaje automático y algoritmos de análisis predictivo para diagnosticar de forma objetiva el estado del pavimento. Esta tecnología permitió realizar inspecciones precisas, eliminando la subjetividad de los métodos tradicionales, y facilitando la construcción de una base de datos confiable sobre el estado de la infraestructura vial.

Principales resultados: Se logró una mayor precisión diagnóstica, al reemplazar evaluaciones manuales por inspecciones automatizadas sustentadas en evidencia digital verificable.

- La plataforma tecnológica permitió identificar el 75% de las vías en mal estado y establecer un orden de prioridad para su intervención, mejorando la asignación de recursos públicos.
- Se registró una reducción significativa en los tiempos y costos operativos, al optimizar los procesos de recolección, análisis y planificación.
- El sistema incorporó también la detección de activos complementarios como señales de tránsito e hidrantes, ampliando el alcance de la gestión urbana.
- Se fortaleció la transparencia en la toma de decisiones públicas, gracias a datos consistentes y trazables que respaldan las inversiones en infraestructura.
- Limitaciones y desafíos

A pesar de los resultados positivos, el caso no documenta en detalle la interoperabilidad de la solución con sistemas institucionales preexistentes, ni las estrategias adoptadas para capacitar al personal técnico local. Asimismo, no se discute la gestión de posibles implicaciones éticas asociadas al manejo de datos georreferenciados. Estas limitaciones podrían afectar la escalabilidad del modelo a otras ciudades, particularmente en contextos institucionales más complejos o menos tecnificados.

Vinculación con literatura académica: El caso de Van Wert se alinea con los enfoques contemporáneos en gestión de activos viales basada en datos (asset management) y mantenimiento predictivo automatizado, discutidos por autores como Li et al. (2023), Zhang y Wang (2022). Asimismo, se enmarca dentro de los principios de la gobernanza digital en gobiernos locales, según los lineamientos de la OECD (2023), que promueven la adopción de tecnologías emergentes para mejorar la eficiencia y transparencia en la gestión pública. Este tipo de experiencias demuestra que incluso municipios con capacidades limitadas pueden acceder a soluciones inteligentes y escalables, siempre que exista voluntad institucional, enfoque estratégico y un marco de gestión adecuado (Mr. Manhole, 2017).

Caso 6. El estudio se realizó en Maribor está ubicado en el país de Eslovenia, en Europa Central.

El estudio realizado en Maribor, Eslovenia, tuvo como objetivo modernizar la gestión de su red vial mediante la implementación de un sistema automatizado basado en inteligencia artificial.

Esta solución tecnológica permitió optimizar la evaluación del estado de las vías, mejorar la planificación estratégica del mantenimiento y fortalecer la transparencia en las políticas públicas. Su aplicación abordó desafíos críticos, como la ausencia de inventarios precisos y la recopilación de datos inconsistentes, factores que dificultaban una gestión eficiente de la infraestructura vial. El proyecto fue liderado por Borut Hojnik, jefe del departamento técnico y administrativo del servicio público de infraestructura Nigrad. La iniciativa benefició a 110,000 residentes de Maribor, al proporcionar una red vial más segura y eficiente, y al Gobierno Local, que logró optimizar su gestión y reducir costos operativos. La evaluación cubrió 478 millas (aproximadamente 769 kilómetros) de la infraestructura vial urbana.

Sistema de IA implementado:

- El sistema utilizó visión artificial y algoritmos de aprendizaje automático para analizar y evaluar de manera objetiva las condiciones de las carreteras mientras los vehículos circulaban por la ciudad. Para la recopilación de datos en tiempo real, se emplearon cámaras de captura y smartphone.

Resultados:

- Mejora en la recopilación de datos: la implementación de un sistema digital, basado en inteligencia artificial proporcionó una base de datos confiable, permitiendo conocer de manera clara y real el estado de las vías de la ciudad.
- Incremento en la eficiencia, ahorro de tiempo y recursos ya que se requería menos personal y se obtenía una mayor calidad de información.
- La flexibilidad de los sistemas permitió realizar inspecciones adecuadas y planes de intervención de forma remota, sin necesidad de estar físicamente en obra. Asimismo, se logró una adecuada planificación de intervención, donde el sistema ayudó a priorizar los tramos a intervenir, como la reparación de parches, con datos objetivos.
- La representación visual que ofreció este sistema facilitó la toma de decisiones y la justificación de las intervenciones, incluyendo los costos de cada intervención.

La gráfica 7 ofrece un análisis detallado entre los métodos tradicionales y el sistema de inteligencia artificial implementado en la ciudad Maribor. Esta comparación facilita la evaluación

de las mejoras en términos de eficiencia, precisión y tiempos de respuesta en la gestión del mantenimiento vial, destacando las ventajas del sistema automatizado sobre los enfoques convencionales en cuanto a capacidad y optimización de recursos.

Caso 7. El estudio se realizó en Sonneberg, ubicado en Alemania, en agosto de 2022, específicamente en el estado de Turingia (Thüringen).

El estudio desarrollado en la ciudad de Sonneberg, ubicada en el estado federado de Turingia, Alemania, tuvo como propósito transformar la gestión del mantenimiento vial a través de una solución digital soportada por inteligencia artificial (IA). Esta iniciativa surgió como respuesta a múltiples restricciones estructurales, particularmente la limitada disponibilidad presupuestaria: la ciudad solo disponía del 10% de los recursos requeridos para mantener su red vial en condiciones óptimas. Además, se enfrentaban desafíos significativos relacionados con la priorización de intervenciones y la dependencia de métodos tradicionales basados en evaluaciones subjetivas. La implementación del sistema permitió modernizar estas prácticas, dotando al municipio de herramientas basadas en evidencia y datos objetivos.

El proyecto fue liderado por Holger Scheler, jefe del Departamento de Construcción Municipal (Stadtbauamt) de Sonneberg, y benefició directamente a una población de 23.000 habitantes. La cobertura del sistema abarcó aproximadamente 150 kilómetros de la red vial urbana. Desde una perspectiva de política pública, este avance significó una mejora sustancial en la seguridad vial, la eficiencia presupuestal y la sostenibilidad operativa de la infraestructura.

Sistema de inteligencia artificial implementad. La solución tecnológica se basó en una arquitectura de inteligencia artificial integrada por visión computacional y algoritmos de aprendizaje automático, los cuales permitieron el análisis automatizado de imágenes captadas mediante smartphones equipados con cámaras de alta resolución, sensores GPS y conectividad en tiempo real. Esta configuración tecnológica habilitó un sistema de evaluación dinámica y continua, eliminando la dependencia de inspecciones físicas tradicionales y reduciendo significativamente la subjetividad en la toma de decisiones.

Resultados obtenidos: Los principales impactos se observaron en tres dimensiones críticas de la gestión vial:

- Optimización del presupuesto: La implementación del sistema permitió priorizar intervenciones críticas, evitando inversiones innecesarias y mejorando la asignación de recursos escasos. Como resultado, se redujeron los costos operativos y se logró disminuir la frecuencia de reparaciones emergentes mediante un enfoque de mantenimiento predictivo.
- Fortalecimiento de la gobernanza: La consolidación de bases de datos objetivas facilitó la planificación de intervenciones a largo plazo y permitió sustentar las decisiones técnicas ante la ciudadanía y los entes de control, aumentando la transparencia y la legitimidad institucional.
- Planificación estratégica: A través de herramientas analíticas avanzadas, el sistema posibilitó la elaboración de un plan de mantenimiento sostenible, adaptado a la realidad financiera del municipio y alineado con criterios técnicos de urgencia y deterioro progresivo de la infraestructura.

Reflexión crítica y vinculación teórica: Este caso representa un ejemplo concreto de cómo la adopción tecnológica puede transformar la gestión de activos públicos en contextos municipales con limitaciones presupuestales. En línea con los enfoques teóricos de mantenimiento predictivo y gestión inteligente de infraestructuras (Marr, 2020; Love et al., 2019), la experiencia de Sonneberg demuestra que el valor estratégico de la IA no solo reside en la automatización, sino también en su capacidad para generar evidencia confiable y orientar la toma de decisiones en entornos de alta incertidumbre.

Limitaciones y desafíos: A pesar de los resultados favorables, el estudio también presenta ciertas limitaciones. El escalamiento del sistema a ciudades más grandes podría enfrentar desafíos asociados a la interoperabilidad con plataformas existentes, la protección de datos personales y la necesidad de capacitar al personal técnico en nuevas competencias digitales. Además, aunque la inversión inicial fue relativamente baja comparada con los beneficios generados, la sostenibilidad del sistema dependerá de actualizaciones periódicas, soporte técnico continuo y la evolución de las capacidades institucionales (Vialytics s.f.).

6.1.5 Síntesis comparativa de casos internacionales sobre la implementación de inteligencia artificial en el mantenimiento vial: Aplicabilidad al contexto colombiano.

Los siete casos internacionales analizados Gadsden (Alabama), South Bend (Indiana), Van Wert (Ohio), Maribor (Eslovenia), Sonneberg (Alemania), y otros ofrecen evidencia empírica valiosa sobre cómo la inteligencia artificial (IA) ha sido implementada para modernizar la gestión del mantenimiento vial, mejorar la eficiencia en la toma de decisiones y optimizar la asignación de recursos públicos. Cada uno, desde su propio entorno institucional y operativo, aporta lecciones que resultan de alta relevancia para Colombia.

Tabla 6. *Principales hallazgos transversales en la implementación de inteligencia artificial para el mantenimiento vial en contextos internacionales*

Dimensión analizada	Lecciones internacionales comunes	Implicaciones para Colombia
Diagnóstico de vías	Uso de visión artificial y machine learning para detectar daños con mayor precisión	Permitiría superar la baja calidad de diagnósticos en vías terciarias y secundarias
Reducción de costos	Ahorros entre 40% y 79% respecto a métodos tradicionales (Gadsden, Van Wert)	Viable frente a restricciones presupuestales en gobiernos locales
Gestión del tiempo	Evaluaciones completadas en semanas o días frente a procesos manuales de meses	Acelera diagnósticos en redes viales rurales dispersas
Toma de decisiones basada en datos	Plataformas como RoadWay o GIS integradas con IA mejoran planificación y priorización	Se podrían articular con INVÍAS, SICEP o SIG municipales
Sostenibilidad y escalabilidad	Sistemas sostenibles en ciudades pequeñas y medianas incluso con bajo presupuesto (Sonneberg)	Altamente replicables en municipios intermedios colombianos
Transparencia y gobernanza	Mejora de rendición de cuentas gracias a la objetividad de los datos (Sonneberg, Maribor)	Útil para fortalecer legitimidad institucional, especialmente en zonas con baja confianza

Fuente: Elaboración propia a partir del análisis comparativo de estudios de caso internacionales (2024-2025), con base en datos de Michelin Mobility Intelligence, Vialytics, publicaciones técnicas de gobiernos locales y literatura científica revisada.

6.1.5.1. Principales factores críticos de éxito

- **Infraestructura tecnológica básica:** Todos los casos partieron de plataformas asequibles con smartphones, cámaras y software en la nube, lo que permite su replicabilidad sin requerir inversiones excesivas en hardware.

- Capacitación del personal: La transición al uso de IA requiere entrenamiento básico en uso de plataformas digitales y análisis de datos, algo factible mediante alianzas con universidades o programas del SENA en Colombia.
- Voluntad política local: Las ciudades líderes contaron con funcionarios comprometidos que entendieron el potencial de la IA para mejorar la gestión urbana. Esto profundiza la necesidad de liderazgo institucional en los municipios colombianos.

Tabla 7. *Limitaciones identificadas*

Categoría	Limitación internacional	Riesgo en Colombia
Escalabilidad	Algunos sistemas no han sido probados en ciudades de gran tamaño.	Las ciudades capitales en Colombia podrían requerir arquitecturas tecnológicas más robustas.
Privacidad de datos	El uso de cámaras plantea preguntas sobre protección de la información.	Deben establecerse protocolos en línea con la Ley 1581 de 2012 y la normatividad de datos personales.
Adaptabilidad institucional	Requiere cambios culturales y técnicos en la administración pública.	Algunos municipios colombianos presentan rezagos digitales importantes.
Conectividad y acceso	Dependencia de plataformas en la nube puede generar problemas en áreas sin cobertura.	Riesgo importante en zonas rurales con limitada infraestructura digital.

Fuente: Elaboración propia a partir del análisis comparativo de estudios de caso internacionales (2024-2025), con base en datos de Michelin Mobility Intelligence, Vialytics, publicaciones técnicas de gobiernos locales y literatura científica revisada.


6.1.5.2 Aplicabilidad al contexto colombiano. Colombia enfrenta una red vial fragmentada, con más de 140.000 km de vías terciarias, muchas de las cuales no cuentan con inventarios actualizados ni gestión técnica moderna. En este sentido:

- En municipios intermedios (ej. Tunja, Popayán, Yopal), el modelo de Sonneberg o Van Wert es directamente aplicable por su bajo costo, uso de smartphones y sistemas flexibles.
- En áreas rurales dispersas, la experiencia de Maribor o Gadsden es útil para mejorar la cobertura sin necesidad de inspecciones presenciales, mediante tecnologías remotas y visión computacional.
- En ciudades grandes, como Bogotá o Medellín, se podría escalar hacia sistemas más complejos, integrando IA con big data, sensores IoT y plataformas integradas de movilidad.

Finalmente, los casos internacionales revisados muestran que la inteligencia artificial aplicada al mantenimiento vial no es solo una opción tecnológica, sino una estrategia de transformación institucional. Para Colombia, su adopción debe estar guiada por principios de eficiencia, equidad territorial y sostenibilidad. A partir de los aprendizajes de estas ciudades, es posible diseñar una hoja de ruta nacional que combine políticas públicas, innovación tecnológica y fortalecimiento institucional para enfrentar el rezago estructural en la infraestructura vial del país.


6.1.5 Análisis comparativo de casos internacionales sobre implementación de sistemas de inteligencia artificial en la investigación científica

Figura 5. Caso 1 ciudad de Gadsden




Fuente: Elaboración del autor a partir de los datos tomados del caso 1

Figura 6. Caso 2 ciudad de South Bend




Fuente: Elaboración del autor a partir de los datos tomados del caso 2

Figura 7. Caso 3 ciudad de Plumstead Township.




Fuente: Elaboración del autor a partir de los datos tomados del caso 3

Figura 8. Caso 4 Dublin, OH.




Fuente: Elaboración del autor a partir de los datos tomados del caso 4

Figura 9. Caso 5 ciudad de Van Wert




Fuente: Elaboración a partir de los datos tomados del caso 5 vialytics.

Figura 10. Caso 6 ciudad de Maribor.



Fuente: Elaboración a partir de los datos tomados del caso 6.

Figura 11 . Caso 7 ciudad de Sonneberg



Fuente: Elaboración del autor a partir de los datos tomados del caso 7.

De acuerdo con los casos de estudio, las ciudades que implementan sistemas de IA para detectar daños en la infraestructura vial muestran impactos económicos y operativos destacados. Sonneberg experimentó un aumento del 20% en la inversión inicial, mientras que South Bend logró una reducción de costos del 70%. Plumstead alcanzó un ahorro del 50% en costos operativos anuales. Todos los casos presentaron mejoras significativas en la precisión de los datos, con incrementos que oscilan entre el 65% y el 95%. Los beneficios comunes incluyen eficiencia operativa, optimización de recursos humanos, sostenibilidad económica con ahorros de entre el 50% y el 79%, y mejoras en la planificación y políticas públicas basadas en datos.

Las metodologías varían, con ciudades como Dublin implementando tecnologías avanzadas, mientras que Sonneberg optó por una automatización básica. Las desventajas incluyen altos costos iniciales, que se compensan con los beneficios a largo plazo, dependencia tecnológica, necesidad de capacitación y resistencia al cambio. Sin embargo, las ventajas predominan, destacando la precisión, optimización de recursos y sostenibilidad. Todos los casos coinciden en mejorar la eficiencia operativa, reducir el personal necesario, lograr ahorros económicos y promover mejoras sistémicas. Los principales desafíos incluyen la financiación inicial, la compatibilidad tecnológica, la capacitación y el mantenimiento. En conclusión, la inteligencia artificial ha demostrado ser una solución eficiente y replicable para la gestión vial, transformando la administración pública hacia un modelo más sostenible. Su implementación redefine los paradigmas gubernamentales, posicionando a las entidades como líderes en tecnología avanzada y promoviendo la eficiencia, la resiliencia operativa y la equidad social, lo que impulsa el progreso global.

A continuación, la tabla 7 presenta un análisis comparativo de estudios de caso internacionales sobre la implementación de sistemas de IA en la gestión vial. Este análisis incluye detalles sobre el año y el sistema utilizado, la cobertura, los líderes del proyecto, los beneficiarios, los desafíos identificados y los resultados obtenidos, lo que permite observar las estrategias adoptadas y los impactos económicos y operativos derivados de la aplicación de soluciones inteligentes en la gestión vial.

Tabla 8. Modelos de Implementación de Inteligencia Artificial en Gestión Vial: Análisis Comparativo Internacional

Aspecto	Caso 1	Caso 2	Caso 3	Caso 4	Caso 5	Caso 6	Caso 7
Objetivo del Proyecto	Mejorar gestión y mantenimiento de carreteras con sistemas inteligentes.	Actualizar evaluación y planificación de vías mediante sistemas avanzados.	Modernizar evaluaciones y crear un plan de pavimentos a 10 años con IA.	Optimizar mantenimiento de vías reduciendo tiempos en análisis y conversión de datos.	Gestionar proactivamente infraestructura vial con IA; crear plan de mejora a 10 años.	Modernizar gestión vial con IA para optimizar evaluación y planificación estratégica.	Gestionar presupuesto limitado mejorando planificación y evaluación con IA.
Año y Sistema Utilizado	2019, sistema de automatización basado en IA.	2017, software de gestión y evaluación de pavimentos basado en IA.	Tecnología Michelin Better Roads (basada en smartphones).	RoadBotics by Michelin (Plataforma RoadWay); IA integrada con ArcGIS.	Sistema de Gestión Vial de vialytics (basado en IA y visión artificial).	Febrero 2022, sistema web basado en IA de vialytics.	2022, sistema de IA con cámaras, GPS y smartphones.
Cobertura	563 km (350 millas).	885 km (550 millas).	117 km (73 millas).	447.4 km (278 millas).	128.75 km (80 millas).	769 km (478 millas).	150 km.
Líder del Proyecto	Heath Williamson, director de Ingeniería.	Scott Kreeger, Ingeniero de Proyectos.	McMahon Associates, Inc. (parte de Bowman).	No especificado en el texto.	Bill Lawson, Supervisor de Ingeniería.	Borut Hojnik, jefe del servicio de infraestructura.	Holger Scheler, jefe del Departamento de Construcción.
Beneficiarios	Residentes	Ciudadanos de South Bend	14,021 residentes.	50,000 residentes y 4,300 negocios locales.	11,040 residentes y comercios locales.	110,000 residentes y el gobierno local.	23,000 residentes y gestores de infraestructura.
Desafíos Identificados	Métodos tradicionales manuales. Restricciones financieras. Ineficiencia en evaluación.	Métodos tradicionales lentos. Alto consumo de recursos. Sistemas complicados.	Métodos manuales informales; Falta de conocimiento histórico y datos; Necesidad de plan integral.	Demora en análisis y conversión de datos; Falta de interoperabilidad; Dependencia de proveedor externo.	Enfoque reactivo. Escasez de personal. Ausencia de sistema integral.	Registro manual y subjetivo de daños; Falta de datos consistentes y objetivos; Planificación a corto plazo.	Presupuesto limitado. Evaluaciones subjetivas. Falta de seguimiento.
Resultados Obtenidos	Reducción del 79% en costos. Evaluaciones 40% más rápidas. Sistema sostenible.	Recolección de datos más rápida y eficiente; Datos precisos y accesibles; Mejora de planificación y comunicación.	Tiempo y esfuerzo reducidos en evaluaciones; Datos objetivos y consistentes; Programa de gestión de pavimentos con conocimiento histórico.	Ahorro de horas-hombre; Integración fluida con ArcGIS; Eliminación de software de terceros; Base para programa anual de mantenimiento.	Ahorro de más de 20 horas/semana de mano de obra; Mayor precisión en detección de defectos; Visión objetiva y base para plan de mejora (75% de vías en mal estado).	Datos objetivos y consistentes; Mayor flexibilidad y eficiencia operativa (ahorro de mano de obra); Planificación y monitoreo de rehabilitaciones; Mejora en justificación de financiamiento.	Reducción de costos. Base de datos consolidada. Planificación estratégica.
Fuente	Michelin Mobility Intelligence. (s.f.). Case Study: City of Gadsden, AL.	Michelin Better Roads. (s.f.). Case Study: South Bend, IN.	McMahon, a Bowman Company. (s.f.). Better Roads Enterprise Partner Case Study — Plumstead Township, PA.	RoadBotics by Michelin. (s.f.). Dublin, OH - Road Assessments.	Vialytics. (s.f.). City of Van Wert Case Study: How Artificial Intelligence Saves Time & Money on Road Assessments.	Vialytics. (s.f.). Maribor Case Study: Saving Money by Digitizing Road Assessments.	Vialytics. (s.f.). Sonneberg Case Study: Transparent Road Planning at a Glance.

Fuente: Elaboración del autor a partir de estudios de caso internacionales revisados entre 2020 y 2024.

Nota: Los datos presentados han sido sintetizados e interpretados por el autor basándose en la información cualitativa y cuantitativa disponible en cada estudio de caso.

6.2 Contexto colombiano de infraestructura vial y tecnologías de inteligencia artificial: desafíos, oportunidades y marco regulatorio

El presente capítulo tiene como objetivo investigar las particularidades y condiciones del contexto colombiano en relación con la infraestructura vial y la disponibilidad de sistemas de inteligencia artificial. Se identificarán los desafíos y oportunidades presentes de estos sistemas, y se analizará el marco jurídico que influye en su adopción y adaptación. A través de este análisis, se

busca ofrecer una visión integral que permita comprender las potencialidades y limitaciones de la inteligencia artificial IA en el ámbito de la infraestructura vial en Colombia.

De acuerdo con el Departamento Nacional de Planeación (DNP), el Ministerio de Transporte, la Financiera de Desarrollo Nacional (FDN) y la Unidad de Planeación de Infraestructura de Transporte (UPIT), en Colombia las vías terrestres reciben la mayor parte de la inversión pública, con un 82.3% del total, y se espera que esta cifra aumente en el futuro. Según el Plan Maestro de Transporte Intermodal (PMTI), para el año 2030 se estima que el potencial de carga movilizada por vías terrestres alcanzará aproximadamente 505 millones de toneladas. Sin embargo, aunque existen otros modos de transporte, el carretero sigue siendo fundamental para garantizar un transporte eficiente. Por lo tanto, es fundamental que la red vial reciba una inversión adecuada, enfocada en mantenerla en condiciones óptimas para asegurar un transporte eficiente del país.

Por lo tanto, la red vial requiere una inversión adecuada para su conservación en óptimas condiciones, garantizando un transporte eficiente y equitativo en Colombia. Sin embargo, el panorama de financiamiento destinado es muy limitado, lo que dificulta su mantenimiento y restringe el desarrollo económico y logístico del país (Ramírez-Giraldo et al., 2021). En contraste, otros países han enfrentado desafíos similares y han implementado soluciones innovadoras mediante sistemas de inteligencia artificial (IA). Estas tecnologías permiten monitorear en tiempo real el estado de las vías, optimizar priorizar inversiones y focalizar recursos en los puntos más críticos.

6.2.1 Desafíos, oportunidades y marco regulatorio

Desafíos en la Implementación de IA. Se identifican los desafíos técnicos, económicos y sociales en la implementación de estas tecnologías, incluyendo la calidad de los datos, la interoperabilidad de los sistemas y la necesidad de infraestructura tecnológica adecuada para la red vial en Colombia.

Desafíos y oportunidades de la Inteligencia Artificial en Colombia. Colombia enfrenta múltiples desafíos en la adopción de la inteligencia artificial (IA) debido a las limitaciones estructurales y condiciones particulares del país. La baja conectividad en amplias regiones

dificulta el acceso equitativo a estas tecnologías, restringiendo su implementación. Asimismo, la integración de la IA con procesos estratégicos, como la transformación energética, exige no solo avances tecnológicos, sino también un enfoque coordinado que supere restricciones de infraestructura y financiamiento. Además, el desarrollo y uso de la IA por grandes corporaciones podría generar monopolios, afectando los principios de equidad e inclusión. Sumado a esto, se identifican factores económicos, sociales y técnicos que influyen en su implementación como:

6.2.2 Desafíos técnicos en la implementación de la Inteligencia Artificial en Colombia

Baja Conectividad. Colombia enfrenta grandes brechas en conectividad digital, especialmente en áreas rurales y apartadas. Según “*La Silla Vacía (2023)*”, existen regiones que no tienen acceso a internet, mientras que otras disponen de conexiones muy limitadas de baja velocidad, lo que limita la integración de los sistemas de inteligencia artificial (IA) de manera ecuánime. Esta diferencia impide que sectores como la agricultura, la educación y la salud puedan beneficiarse con estas tecnologías, generando desigualdades y limitando el desarrollo socioeconómico. Para enfrentar este desafío, se requiere de grandes inversiones en infraestructura digital, así como la actualización política públicas que garanticen un acceso inclusivo y eficiente de las herramientas tecnológicas.

Falta de Infraestructura Especializada. La infraestructura de Tecnologías de la Información (TI) en Colombia no cumple con los requerimientos para implementar sistemas de IA de forma eficiente. Según el *Repositorio CDI Medellín (2023)*, el país carece de centros de datos avanzados y estas herramientas de alto rendimiento para gestionar y administrar grandes volúmenes de información de forma eficiente y segura. Esta insuficiencia no solo obstaculiza el desarrollo de soluciones locales y aumenta la dependencia de sistemas internacionales, generando grandes costos y riesgos en la protección de datos. Superar este desafío requiere la creación de sedes especializadas en almacenamiento de datos, junto con el fortalecimiento de tecnologías y sistemas para procesar, almacenar y transmitir datos, así como el fortalecimiento de hardware, software y algoritmos que optimicen la eficiencia en diversos sectores (Repositorio CDI Medellín, 2023).

Escasez de talento capacitado. La formación de profesionales en inteligencia artificial representa un desafío estructural en Colombia. Informes recientes de ManpowerGroup y

Fedesoft (2025) evidencian que muchas instituciones de educación superior no han adaptado sus planes de estudio a las demandas de la economía digital, lo que ha generado una desalineación con el mercado laboral. Esta situación ha llevado a que el 68 % de las empresas del sector TI reporten dificultades para encontrar personal calificado.

El Programa de las Naciones Unidas para el Desarrollo (PNUD, 2024) respalda este diagnóstico al señalar la baja disponibilidad de programas especializados en informática y tecnologías emergentes, con apenas cinco programas de pregrado y diecisiete de posgrado orientados específicamente a inteligencia artificial. Esta brecha educativa se agrava con un déficit proyectado de entre 68.000 y 112.000 desarrolladores de software para el año 2025 (MinTIC, 2025), lo cual limita significativamente la competitividad, la innovación y la capacidad del país para afrontar los retos de la transformación digital.

Además, esta carencia de profesionales capacitados afecta directamente la capacidad de las pequeñas y medianas empresas (PYMES) para adoptar tecnologías de inteligencia artificial, al no contar con el conocimiento técnico necesario para integrarlas ni con personal calificado para operarlas. Frente a este escenario, se requiere una reforma curricular profunda, el fortalecimiento de alianzas público-privadas para el desarrollo de talento especializado y la implementación de programas de reentrenamiento en habilidades digitales avanzadas (Impacto TIC, 2023).

6.2.3 Desafíos económicos en la implementación de la IA en Colombia

Colombia avanza rápidamente en la adaptación y adopción de sistemas de inteligencia artificial (IA), con un 59% de las organizaciones implementando esta tecnología en menos de seis meses, superando el promedio global del 48% (Microsoft, 2024). No obstante, la implementación se enfrena a retos económicos, como las limitaciones financieras, distribución equitativa y la dependencia tecnológica.

limitaciones financieras. Una encuesta realizada por Microsoft en marzo de 2024, revela que el 77% de las micro, pequeñas y medianas empresas (MiPymes) colombianas han adoptado inteligencia artificial (IA) en sus actividades. No obstante, enfrentan varios desafíos como el 55% de las empresas señalan que los costos representan una barrera significativa, el 38% expresa preocupaciones por la ciberseguridad, y el 37% no dispone de personal cualificado en IA.

Distribución inequitativa de recursos. La distribución inequitativa de los recursos destinados a la implementación de la IA es otro desafío importante. Según el Departamento Nacional de Planeación (DNP, 2023), la mayoría de los fondos para proyectos de IA están concentrados en áreas urbanas como Bogotá, excluyendo regiones rurales y a las comunidades menos favorecidas. Este desequilibrio limita el acceso de ciertas poblaciones a las tecnologías de vanguardia, lo que contribuye a la perpetuación de las desigualdades sociales y económicas en el país. Aunque el 44% de las empresas colombianas han reajustado sus presupuestos para reasignar recursos hacia iniciativas de IA, este proceso no ha logrado extenderse de manera equitativa a todas las regiones, limitando el acceso a las tecnologías en las áreas periféricas.

Dependencia tecnológica. La dependencia de tecnología extranjera es otro desafío económico significativo para Colombia. Según MinTIC (2023), el país no produce tecnología inteligente localmente, lo que obliga a importar equipos y soluciones de IA. Este gasto adicional, representa una carga económica considerable, no solo por los costos de adquisición, sino también por los costos asociados con la importación, el mantenimiento y la capacitación de personal. Además, reduce la capacidad del país para crear soluciones personalizadas, afectando su autonomía tecnológica.

6.2.4 Desafíos sociales en la implementación de la IA en Colombia

Brechas sociales y digitales. La desigualdad en el acceso a tecnologías de la información y comunicación (TIC) en Colombia agrava las desigualdades entre regiones. Según el Ministerio de Tecnologías de la información y las comunicaciones (2023), aunque índice de brecha digital disminuyó en 2022, persisten grandes diferencias en habilidades digitales, acceso a dispositivos y aprovechamiento de las TIC entre sectores sociales. Dejando en evidencia la necesidad de políticas públicas inclusivas que reduzcan estas brechas.

Ética y regulación. La adopción de la inteligencia artificial (IA) en Colombia enfrenta desafíos éticos, como la privacidad de los datos, la discriminación algorítmica y la protección de derechos fundamentales. Frente a estos desasosiegos, el Ministerio de Ciencia, Tecnología e Innovación (MinCiencias) desarrolló el "*Marco Ético para la Inteligencia Artificial en Colombia*", subrayando principios como la transparencia, privacidad, seguridad y uso responsable de los sistemas de IA (MinCiencias, 2021).

Resistencia cultural. La falta de confianza de los sistemas inteligentes puede obstaculizar su adopción, procedente, especialmente en sectores cotidianos. Según el Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC), es fundamental fomentar una cultura digital desde la academia para facilitar la aceptación y el uso ético de la IA, considerándola como una herramienta de liderazgo dentro de las estrategias de adopción tecnológica (MinCiencias, 2024).

6.2.5 Marco regulatorio vigente en la implementación de la IA en Colombia

La implementación de la Inteligencia Artificial (IA) en Colombia requiere un marco jurídico amplio que garantice su desarrollo, integración y uso ético, responsable y transparente, tanto en el ámbito público como privado. Este marco debe abordar desafíos en términos de ética, privacidad, ciberseguridad y gobernanza, protegiendo los derechos de los ciudadanos y la seguridad nacional mientras se fomenta la innovación tecnológica.

No obstante, en Colombia se han logrado avances significativos en la creación de este marco, lo que facilita abordar los desafíos y promover el uso responsable y seguro. En la Tabla 8 se detallan las secciones jurídicas relevantes, las entidades competentes, las contribuciones regulatorias y la legislación aplicable a la implementación de la IA en el país.

Tabla 9. *Marco Normativo para la Implementación de la IA en Colombia*

Categoría	Actores Posibles	Aportes Jurídicos	Normativa Relevante
Entorno IA	Gobierno Nacional, Gobiernos Territoriales, Gobiernos Municipales	Diseño de normativas para la adopción de IA en infraestructura pública, Promoción de estándares éticos y de interoperabilidad, Asignación de recursos basados en el desarrollo de proyectos IA, Incorporación de lineamientos sobre privacidad y transparencia en procesos relacionados con IA	Conpes 3975 de 2019: Política Nacional para la Transformación Digital e Inteligencia Artificial, Decreto 1839 de 2022: Reglamenta el Programa de Transformación Digital e Inteligencia Artificial del Gobierno Nacional, Decreto 1263 de 2022: Política de Gobierno Digital, Conpes 4024 de 2022: Estrategia de Desarrollo de la Inteligencia Artificial en Colombia
	Comités de Ética, Organizaciones de Derechos Humanos, Reguladores, Bancos de desarrollo nacionales e internacionales, Centros de innovación y tecnología, Academia	Garantizar el uso responsable y ético de IA, Supervisar el cumplimiento de normativas sobre equidad y derechos humanos, Promover la inclusión y el respeto a la diversidad en los sistemas de IA, Financiar proyectos que incluyan tecnologías de IA para infraestructura crítica, Emitir lineamientos sobre gobernanza y ciberseguridad	Ley 1581 de 2012: Disposiciones generales para la protección de datos personales, Resolución 2022-000022 de 2022 (SIC): Guía para la protección de datos personales en IA, Conpes 3920 de 2018: Política Nacional de Explotación de Datos (Big Data), Resolución 460 de 2022: Plan Nacional de Infraestructura de Datos, Resolución 003 de 2023: Reglamento de la Ley 2069 de 2020 sobre emprendimiento e IA
Autoridades Gubernamentales y de Políticas Pública	DAPRE, DANE, DIAN, Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC), Congreso de la República, Gobiernos municipales y departamentales, Corte Constitucional y Corte Suprema	Regulación de estándares técnicos para IA en servicios públicos, Desarrollo de cláusulas para fomentar la transparencia en licitaciones públicas, Supervisión del cumplimiento de la normativa sobre protección de datos y ciberseguridad, Promoción de alianzas público-privadas para fomentar la investigación y el desarrollo en IA, Fortalecimiento de la estructura legal para procesos relacionados con IA	Decreto 1078 de 2015: Decreto Único Reglamentario del Sector TIC, Directiva Presidencial 03 de 2021: Lineamientos para uso de servicios en nube y gestión de datos en entidades públicas, Conpes 4024 de 2022: Estrategia de Desarrollo de la Inteligencia Artificial, Resolución 460 de 2022: Plan Nacional de Infraestructura de Datos, Ley 1581 de 2012: Protección de datos personales
Ética y Gobernanza	Comités de Ética, Organizaciones de Derechos Humanos, Gobiernos Nacionales y Territoriales, Reguladores del sector público y privado, Organismos internacionales de gobernanza	Desarrollo de códigos de conducta obligatorios para IA, Regulación de procesos para auditar sistemas de IA en infraestructura pública, Inclusión de la trazabilidad como criterio obligatorio para sistemas automatizados, Supervisión ética en el diseño e implementación de modelos IA, Normativa de acceso justo y equitativo a estas tecnologías	Conpes 3975 de 2019: Política Nacional para la Transformación Digital, Ley 1581 de 2012: Protección de datos personales, Decreto 1839 de 2022: Transformación Digital e IA del Gobierno Nacional, Resolución 2022-000022 de 2022 (SIC): Guía de Protección de Datos para IA, Resolución 003 de 2023: Inclusión de IA en el reglamento de emprendimiento de la Ley 2069, Acuerdo PCSJA24-12243 de 2024: Lineamientos para el uso y

Privacidad, Ciberseguridad y Defensa	Ministerio de Defensa Nacional, Fuerzas Armadas, Empresas de tecnología de seguridad, DANE, Ministerio del Interior, Superintendencia de Industria y Comercio (SIC)	Creación de normativas de ciberseguridad específicas para entornos de IA, Regulación de responsabilidades legales por fallos de IA en infraestructura crítica, Establecimiento de protocolos para proteger datos personales recolectados por sistemas de IA, Normativa que regule el uso de IA en contextos de defensa y seguridad nacional	aprovechamiento respetuoso, responsable, seguro y ético de la IA en la Rama Judicial
			Resolución 2022-000022 de 2022 (SIC): Guía de Protección de Datos para IA, Decreto 1263 de 2022: Política de Gobierno Digital, Conpes 3920 de 2018: Política Nacional de Explotación de Datos (Big Data), Ley 1581 de 2012: Protección de datos personales, Conpes 4024 de 2022: Estrategia Nacional de Desarrollo de IA

Fuente: Elaboración del autor a partir de la normativa colombiana vigente (2024).

La implementación de la inteligencia artificial en Colombia enfrenta barreras y desafíos significativos, limitaciones presupuestarias, falta de infraestructura tecnológica y escasez de profesionales capacitados. No obstante, el marco normativo actual como el Conpes 3975 de 2019 y el Decreto 1839 de 2022, establece una base sólida para el desarrollo ético y responsable. Es esencial fortalecer alianzas público-privadas, la capacitación de profesionales y la inversión en infraestructura. Además, la vigilancia ética y la protección de datos son aspectos críticos que requieren atención constante para garantizar que el desarrollo tecnológico y proteger los derechos y la privacidad de los colombianos. Finalmente, aunque Colombia ha dado pasos importantes en la adopción y uso de la transformación digital e inteligencia artificial, aún hace falta superar las barreras existentes y aprovechar plenamente el potencial de estas tecnologías para el desarrollo económico y social del país.

6.3 Inspección del estado del pavimento mediante la norma INVIAS y aplicaciones de Inteligencia Artificial sectores prueba piloto

El estado del pavimento es un elemento fundamental en la planificación, el mantenimiento y la gestión de la infraestructura vial, ya que incide directamente en la seguridad, la movilidad y la operatividad del sistema de transporte. Una red vial en condiciones óptimas contribuye a la reducción de los costos de operación vehicular, minimiza los riesgos de accidentes y mejora la eficiencia del tráfico. Por ello, la inspección y la evaluación del pavimento resultan esenciales para determinar su estado actual y definir estrategias de conservación y rehabilitación.

En este contexto, el presente estudio llevó a cabo una evaluación exhaustiva del estado estructural y funcional de los corredores viales Transversal 19, Carrera 14, Carrera 15, Calle 7, Carrera 11, Carrera 13, Calle 24 y Transversal 20 en Tunja, Boyacá, Colombia. Estos ocho tramos fueron seleccionados estratégicamente por ser vías principales, de alto flujo vehicular y con un avanzado estado de deterioro. Esta elección no solo asegura la representatividad de la problemática vial crítica de la ciudad, sino que también proporciona un escenario ideal para la

validación robusta del software Roadly Pro en condiciones desafiantes, ya que el estudio se focaliza en las vías más afectadas para probar la efectividad del sistema. El análisis comprendió un recorrido total de 8.715 metros y una superficie aproximada de 101.637 m², lo que permitió obtener una caracterización detallada de las condiciones del pavimento en los tramos evaluados, facilitando una base de comparación con las evaluaciones tradicionales conforme a la norma INVIAS.

6.3.1 Inspección visual conforme a la norma INVIAS

La metodología tradicional establecida por el Instituto Nacional de Vías (INVIAS) se basa en la realización de inspecciones visuales para la identificación y clasificación de patologías del pavimento. Este procedimiento es llevado a cabo por personal técnico especializado, quien recorre los tramos viales y registra los diferentes tipos de deterioro según los criterios definidos en la normativa vigente. Si bien este método ha sido ampliamente utilizado y estandarizado, presenta ciertas limitaciones. Entre ellas, se encuentra la posibilidad de errores humanos en la identificación de fallas, la subjetividad en la clasificación de los deterioros y el tiempo considerable requerido tanto para el levantamiento de la información como para su posterior análisis. Estas restricciones pueden afectar la precisión de la evaluación y, en consecuencia, la toma de decisiones en cuanto al mantenimiento y rehabilitación de la infraestructura vial.

6.3.2 Evaluación automatizada mediante inteligencia artificial (Roadly PRO)

La inspección automatizada implementada con Roadly PRO utilizó visión computacional e inteligencia artificial para la detección superficial de daños en pavimentos. Las capturas se realizaron mediante un smartphone de gama alta montado en el parabrisas, configurado bajo los siguientes parámetros técnicos:

- Resolución de captura: 1920 × 1080 píxeles (Full HD).
- Frecuencia de muestreo: 30 FPS (fotogramas por segundo).
- Velocidad del vehículo: 30-40 km/h, conforme a recomendaciones del desarrollador.
- Montaje del dispositivo: centrado en el parabrisas, con inclinación de ~30° hacia la calzada.

Las características de este sistema permiten la cobertura visual estable y de alta calidad, reduciendo distorsiones y mejorando la precisión de detección. La calidad del dataset resultante se vio reforzada por las capacidades de procesamiento del dispositivo móvil, lo que permitió una clasificación eficiente de patologías como grietas, baches y desprendimientos.

6.3.3 Comparación de metodologías


El análisis comparativo entre ambas metodologías permite evaluar sus ventajas y limitaciones según los siguientes criterios:

- **Precisión:** Mientras que la inspección visual depende de la experiencia del evaluador, la IA reduce la subjetividad y estandariza la clasificación de patologías.
- **Eficiencia:** La IA permite analizar grandes extensiones de pavimento en menor tiempo, mientras que la inspección manual requiere mayor dedicación de recursos humanos.
- **Aplicabilidad:** La inspección visual sigue siendo necesaria en casos donde se requiere verificación en sitio, mientras que la IA facilita evaluaciones preliminares y de gran escala.

Si bien ambos enfoques presentan ventajas y limitaciones, su combinación puede optimizar la identificación temprana de deterioros, mejorando la planificación del mantenimiento vial y reduciendo costos de rehabilitación a largo plazo.

A continuación, se presenta la localización del área de estudio:

Figura 12. Localización del área de estudio en Tunja, Boyacá, Colombia



Fuente: Elaboración propia basada en el análisis de datos obtenidos de Roadly.

6.3.4 Implementación de la metodología de inspección del pavimento según la norma INVIAS y aplicaciones de Inteligencia Artificial Roadly

La inspección del pavimento se realizó conforme a los lineamientos del Instituto Nacional de Vías (INVIAS) y mediante la aplicación Roadly PRO, permitiendo obtener un diagnóstico preciso del estado del pavimento en los tramos evaluados.

Planificación de la inspección. Se seleccionaron ocho tramos viales para su evaluación: Transversal 19, Carrera 14, Carrera 15, Calle 7, Carrera 11, Carrera 13, Calle 24 y Transversal 20. En total, se inspeccionaron 8.715 metros, abarcando un área de 101.637 m². Además, se

recopiló información complementaria sobre condiciones climáticas y tráfico vehicular, factores determinantes en la progresión del deterioro del pavimento.

Inspección y registro de daños. La evaluación del pavimento se realizó conforme a la metodología INVIAS, utilizando formatos estandarizados para garantizar uniformidad y trazabilidad de los datos. Se identificaron y clasificaron las principales patologías viales según su severidad y extensión, destacándose:

- Fisuras longitudinales y transversales: grietas que afectan la continuidad del pavimento.
- Baches: depresiones en la superficie.
- Desprendimientos: pérdida de material superficial del pavimento.
- Deformaciones plásticas: hundimientos por carga vehicular.
- Craquelado o piel de cocodrilo: grietas interconectadas que indican fatiga estructural del pavimento.

Inspección del pavimento mediante Inteligencia Artificial. El uso de Inteligencia Artificial (IA) optimiza la detección de patologías en pavimentos, agilizando el análisis y reduciendo la subjetividad en la evaluación. En este estudio se empleó Roadly PRO, una plataforma basada en visión artificial y aprendizaje automático para la clasificación de deterioros.

Configuración y captura de datos con Roadly PRO. La inspección se realizó con dispositivos compatibles, garantizando la captura precisa de imágenes georreferenciadas. Para una recolección óptima de datos, el dispositivo móvil se instaló en el vehículo utilizando un soporte estable que permitió una grabación continua de la superficie vial.


Proceso de grabación y análisis de datos:

- Captura de video: Roadly PRO registró visualmente los tramos inspeccionados.
- Procesamiento en la nube: Los videos fueron analizados por algoritmos de IA para detectar y clasificar patologías.
- Generación de informes: Se obtuvieron reportes detallados sobre localización, severidad y extensión de los daños.

Evaluación piloto del estado del pavimento mediante Inteligencia Artificial. Se realizó una evaluación piloto utilizando metodologías estandarizadas conforme a ASTM D6433-20, asegurando objetividad en la cuantificación del deterioro. La clasificación de los tramos se realizó con base en el Índice de Condición del Pavimento (PCI), segmentando las vías en seis niveles: Good (bueno), satisfactory (satisfactorio), fair (regular), poor (deficiente), serious (grave) y very poor (muy deficiente).

Análisis de resultados. Los datos recopilados permitieron generar un mapa de georreferenciación (Figura 12), representando la condición del pavimento con una escala cromática. Este sistema de análisis optimiza la planificación de intervenciones al identificar con precisión los sectores más deteriorados.

Figura 13. Mapa de georreferenciación y evaluación del estado de las vías



Fuente: Tomado del sistema inteligente Roadly.

La Tabla 10 presenta la clasificación estructural de los segmentos viales según el Índice de Condición del Pavimento (Pavement Condition Index, PCI) y su calificación convencional. Este esquema permite analizar la distribución del deterioro en la red vial e identificar las zonas que requieren intervenciones prioritarias

Tabla 10. Estado de la infraestructura vial según Índice PCI y calificación convencional

Frame Segment ID	Road Name	Conventional Rating	PCI Rating	Length (m)	Area (m²)
1	Calle 24	Good	97.33	285.09	1938.82
2	Calle 24	Satisfactory	80.51	20	127.58
3	Calle 7	Good	96.89	60	192.89
4	Calle 7	Satisfactory	81.92	10	44.44
5	Carrera 11	Fair	63.47	30	249.57
6	Carrera 11	Good	90.65	287.72	2645.15
7	Carrera 11	Satisfactory	78.06	130.02	871.50
8	Carrera 13	Good	99.71	302.64	1901.98
9	Carrera 13	Satisfactory	83.89	10	79.35
10	Carrera 14	Fair	62.77	350.98	3341.89
11	Carrera 14	Good	94.83	1453.94	13332.13
12	Carrera 14	Poor	47.55	220.72	2128.63
13	Carrera 14	Satisfactory	79.29	561.40	5345.17
14	Carrera 14	Serious	23.50	20.02	180.29
15	Carrera 14	Very Poor	33.76	10.01	83.26
16	Transversal 19	Fair	61.84	458.61	7790.50
17	Transversal 19	Good	95.82	1988.05	31232.64
18	Transversal 19	Poor	48.35	337.52	6295.09
19	Transversal 19	Satisfactory	78.55	635.11	10976.08
20	Transversal 19	Serious	21.12	11.11	226.29
21	Transversal 19	Very Poor	34.85	181.78	3227.95
22	Carrera 15	Fair	65.13	10.02	66.96
23	Carrera 15	Good	97.89	1264.96	7705.77
24	Carrera 15	Satisfactory	233.71	30.07	212.51


Fuente: Datos obtenidos del sistema de evaluación inteligente.

El Índice de Condición del Pavimento (PCI, Pavement Condition Index) permite evaluar el estado de la infraestructura vial y determinar la distribución del deterioro en la red. El análisis de los valores obtenidos indica que la mayoría de los segmentos viales presentan valores entre 70 y 90, lo que evidencia un estado de conservación aceptable a bueno en una proporción significativa de la red. Sin embargo, se identifican segmentos con PCI inferior a 50, reflejando un deterioro estructural avanzado que compromete la funcionalidad y la capacidad portante del pavimento.

Las vías en mejor estado corresponden a las calles 24 y 7, mientras que algunos tramos de la Transversal 19 y la Carrera 14 presentan PCI inferior a 50, evidenciando deterioro severo que requiere intervención prioritaria para mitigar el deterioro progresivo.

Distribución de calificaciones PCI. La figura 13 muestra la distribución de los valores del PCI en la red vial. Se observa una concentración de valores entre 70 y 90, lo que confirma que la mayor parte de la infraestructura evaluada se encuentra en condiciones aceptables. No obstante, se identifican tramos con PCI entre 20 y 50, los cuales requieren atención prioritaria para evitar un mayor deterioro.

Figura 14. *Distribución de Calificaciones PCI*




C

Fuente: Elaboración propia basada en la información consignada en la tabla 10 del presente documento.

Relación entre PCI y área deteriorada. Para complementar el análisis, la gráfica 10 presenta la extensión del área deteriorada en metros cuadrados (m^2) para cada tramo evaluado, permitiendo correlacionar la condición del pavimento con la magnitud del deterioro. Se evidencia que la transversal 19 es la vía más afectada, con más de 9,500 m^2 en estado deficiente o muy deficiente. Más del 20% de su superficie presenta defectos superficiales, fisuras moderadas, baches y un incipiente desarrollo de piel de cocodrilo, lo que indica deterioro estructural progresivo.

De manera similar, la carrera 14 acumula más de 2,300 m^2 en condiciones críticas, con fisuras de magnitud moderada a severa que afectan su capacidad estructural. En contraste, las calles 24 y 7 presentan niveles mínimos de deterioro, con la mayor parte de su superficie en estado bueno o satisfactorio, reduciendo la necesidad de intervención inmediata. La correlación entre el PCI y el área deteriorada permite establecer prioridades en la planificación de mantenimiento vial, enfocando los recursos en los tramos con mayor deterioro estructural.

Figura 15. *Análisis de área deteriorada en infraestructura vial según nivel de conservación*




Fuente: Elaboración propia basada en la información consignada en la Tabla 10 del presente documento.

Análisis de fallas en pavimentos en las vías piloto distribución de grietas daños superficiales y estructurales. El análisis de fallas en pavimentos de las vías piloto permite identificar los principales defectos que afectan la infraestructura vial, proporcionando una base técnica para la planificación de intervenciones de mantenimiento y rehabilitación. Este proceso se sustenta en la evaluación detallada de las patologías presentes en la superficie del pavimento, con un enfoque en la clasificación y cuantificación de grietas, daños superficiales y estructurales dentro del contexto específico de las vías estudiadas.

Distribución de fallas en el pavimento. La figura 16 presenta la distribución espacial de las fallas identificadas en las vías piloto, diferenciadas según el tipo y la magnitud del deterioro. Se evidencia la concentración de defectos como grietas tipo piel de cocodrilo, fisuras longitudinales, baches y daños estructurales. Las tonalidades más intensas en la representación indican zonas con mayor nivel de afectación, permitiendo una visualización clara de los sectores con mayor deterioro.

Figura 16. Distribución de grietas, daños superficiales y estructurales en las vías piloto.



Fuente: Elaboración propia basada en la información consignada en la tabla 9 del presente documento.

Para cuantificar el impacto de las fallas, la tabla 11 presenta el porcentaje de afectación promedio por vía. Se observa que la transversal 19 (35.71%) y la carrera 14 (30.36%) presentan los mayores niveles de deterioro, combinando afectaciones superficiales y estructurales. En contraste, la calle 7 y la calle 24 exhiben la menor afectación.

Tabla 11. Porcentaje de afectación promedio por vía


Vía	% Defectos Superficiales	% Baches (Parches)	% Total de Afectación
Transversal 19	28.57%	7.14%	35.71% (Mayor afectación)
Carrera 14	25.00%	5.36%	30.36%
Carrera 13	13.39%	2.68%	16.07%
Carrera 11	8.93%	1.79%	10.71%

Carrera 15	4.46%	0.89%	5.36%
Calle 24	1.79%	0.00%	1.79% (Menor afectación)
Calle 7	0.00%	0.00%	0.00% (Menor afectación)

Fuente: Elaboración propia basada en la información contenida en la gráfica 15 del presente documento.

En coherencia con este análisis, la figura 17 presenta un mapa de daños de las vías en estudio, donde, mediante una codificación cromática, se identifican los segmentos viales con condiciones críticas. La segmentación de daños ofrece una representación clara del estado de la infraestructura vial, facilitando la identificación de los sectores con mayor afectación.

Figura 17. Mapa de daños – identificación y clasificación de segmentos viales en very poor y serious



Fuente: Datos procesados obtenidos de Roadly para el análisis de las vías en estudio

Las figuras 18(a) y 18(b) presentan registros visuales de los segmentos viales con mayor afectación. La figura 18(a) muestra un tramo con signos evidentes de deterioro sin una categorización específica de su severidad. En contraste, la figura 18(b) resalta los daños en color rojo, lo que facilita la interpretación del grado de afectación del pavimento y la planificación de intervenciones de mantenimiento y rehabilitación.

Figura 18. Registros visuales de los segmentos viales con mayor afectación




Fuente: Datos procesados obtenidos de Roadly para el análisis de las vías en estudio.

Como complemento, la figura 20 muestra los resultados del análisis automatizado, el cual no solo identifica el deterioro del pavimento, sino que también proporciona métricas cuantificables para evaluar su magnitud. En este caso, se observa un segmento vial con un índice de condición del pavimento (PCI) de 21.12, clasificado en la categoría Serious, lo que indica un estado crítico con alto riesgo de falla estructural.

Adicionalmente, la tabla 12 resume la clasificación de los segmentos evaluados con base en el índice de condición del pavimento (PCI). Se incluyen identificadores únicos (segment stats id y frame segment id), el nombre de la vía analizada y su clasificación según el sistema de evaluación. además, se proporcionan enlaces interactivos que permiten acceder a imágenes de los daños identificados.

Figura 19. Evaluación inteligente del estado del pavimento e identificación de daños críticos en la infraestructura vial clasificados como Very Poor y Serious



Fuente: Información obtenida a partir de los resultados generados por el sistema de evaluación automatizada Roadly.

Tabla 12. Resultados del análisis automatizado del deterioro pavimento: clasificación por índice de condición y enlaces interactivos


Segment Stats Id	Frame Segment Id	Road Name	Conventional Rating	Frame Frontal	Frame Bev
67d9e3f23bfd3e5fafcc3e	67d9dcb23294bb86157113a2	Transversal 19	Serious	https://storage.googleapis.com/roadly-stable-rda/test-1/7a9be4ef-e59c-4d89-a39a-2975f3b511cb/track_estimation_out/frame/input/image/frame/compressed/353.jpg	https://storage.googleapis.com/roadly-stable-rda/test-1/7a9be4ef-e59c-4d89-a39a-2975f3b511cb/generate_rda_out/segment/bev/image/frame/353.jpg

Fuente: Fuente: Información obtenida a partir de los resultados generados por el sistema de evaluación automatizada Roadly.

En línea con la evaluación realizada, la figura 20 presenta la georreferenciación de la infraestructura vial evaluada, utilizando una clasificación cromática que segmenta el estado del pavimento. Se distinguen categorías como Fair (regular o aceptable), que indica una condición

intermedia con riesgo de deterioro, y Poor (deficiente o malo), que refleja un desgaste progresivo con afectaciones estructurales y funcionales.

Figura 20. Georreferenciación y evaluación del estado del pavimento: Categorías Fair y Poor



Fuente: Información obtenida a partir de los resultados generados por el sistema de evaluación automatizada Roadly.


Las figuras 21(a) y 21(b) presentan registros visuales obtenidos mediante análisis automatizado. En la figura 21(a), el sistema clasifica el pavimento en estado Fair (amarillo), lo que indica un nivel de deterioro moderado con riesgo de progresión. En contraste, la figura 21(b) categoriza el daño como Poor (naranja), reflejando un desgaste más avanzado que compromete la funcionalidad estructural de la vía.

Figura 21. Registros visuales obtenidos mediante análisis automatizado

(a)




(b)



Fuente: Información obtenida a partir de los resultados generados por el sistema de evaluación automatizada Roadly.

Para ampliar este análisis, la Figura 25 muestra la distribución de los daños en las vías clasificadas como Fair, evidenciando variaciones en el nivel de deterioro del pavimento y su impacto en la infraestructura vial. Se destaca que la Carrera 14 presenta el mayor porcentaje de afectación, superando el 30%, lo que indica una condición crítica. La Transversal 19 también exhibe un nivel significativo de daño, aunque en menor proporción. En contraste, las Carreras 11 y 15 registran un deterioro menos severo, con mejores condiciones de conservación y menor exposición a factores de deterioro.

Figura 22. Análisis técnico del estado del pavimento en vías clasificadas como 'fair' en Tunja (Boyacá).



Fuente: Elaboración propia basada en datos procesados por el sistema inteligente de análisis vial Roadly PRO.

El análisis del estado de la infraestructura vial indica que las vías clasificadas como fair presentan un deterioro intermedio, caracterizado por defectos superficiales, fisuras longitudinales y transversales, así como la presencia de baches. La Tabla 13 sintetiza la distribución de estos daños en las principales vías de Tunja.

Tabla 13. Distribución de daños fair en las vías de estudio en Tunja (Boyacá) según tipo de deterioro

Vía	Defectos Superficiales (%)	Fisuras Longitudinales y Transversales (%)	Baches (%)	Grietas tipo Alligator (Piel de Cocodrilo) (%)
Carrera 11	Bajo (<1%)	Bajo (<1%)	No presenta	No presentes
Carrera 14	Alto (>15%)	Moderado a alto	Moderado	Presente en baja proporción (<1%)
Carrera 15	Mínimo (<1%)	Aislado (<1%)	No presenta	No presentes
Transversal 19	Moderado a alto (>15%)	Moderado	Moderado	Presente en baja proporción (<1.5%)

Fuente: Elaboración del autor con base en los datos visualizados en la figura 25 del presente trabajo.


Los resultados reflejan que la carrera 14 y la transversal 19 presentan los mayores niveles de deterioro, con defectos superficiales superiores al 15%, fisuras moderadas a altas y presencia

Para complementar este análisis, la figura 26 presenta el mapa de las vías en buen estado, identificando los sectores con bajo nivel de deterioro y ausencia de daños significativos. La evaluación muestra que la mayoría de los segmentos viales analizados se encuentran en categorías good o satisfactory, reflejando condiciones estructurales favorables y ausencia de necesidad de intervención inmediata.

[illegible]

El análisis del pavement condition index (pci) indica que el 48,75% de la infraestructura vial evaluada se encuentra en estado satisfactory o good, con un PCI promedio de 84,30. En contraste, el 1,27% de la longitud total analizada presenta un estado very poor o serious (PCI = 33,06), concentrándose principalmente en la transversal 19 y la carrera 14.

Figura 24. Relación entre la longitud total de las vías evaluadas y su PCI Rating



Fuente: Elaboración del autor con base en los datos proporcionados por el sistema inteligente Roadly PRO.

La figura 24 representa la relación entre la longitud total de las vías evaluadas y su clasificación PCI, permitiendo una mejor visualización de la distribución del estado del pavimento. Paralelamente, la tabla 12 sintetiza la clasificación de las vías según su estado estructural.

Tabla 14. Estado de la infraestructura vial evaluada y vías en peor condición

Estado de la vía	PCI promedio	Longitud total (m)	% Longitud total	Área Total (m²)	% Área total	Vías en peor estado
Very Poor y Serious	33,06	222,92	1,27%	3.717,79	1,83%	Transversal 19, Carrera 14
Fair y Poor	56,68	1.407,85	8,02%	19.872,64	9,80%	Transversal 19, Carrera 14, Carrera 11, Carrera 15
Satisfactory y Good	84,30	8.550,46	48,75%	141.637,73	69,80%	Calle 24, Calle 7, Carrera 11, Carrera 13, Carrera 14, Carrera 15, Transversal 19, Transversal 20
Total, Evaluado	85,44	17.542,19	100%	202.924,21	100%	-

Fuente: Elaboración del autor con base en los datos obtenidos a través del sistema inteligente Roadly.

Con base en estos resultados, se han definido estrategias de intervención para optimizar la durabilidad y funcionalidad de la infraestructura vial.

Tabla 15. Intervención y mantenimiento vial

Estrategia	Acciones recomendadas	Vías afectadas
Intervención prioritaria en vías con PCI Muy Bajo	- Rehabilitación urgente de tramos con PCI < 40. - Especial atención a los sectores con mayor deterioro.	Transversal 19, Carrera 14
Mantenimiento preventivo en sectores con PCI Fair y Poor	- Implementación de un plan de mantenimiento correctivo. - Aplicación de bacheo, sellado de grietas y rehabilitación superficial.	Carrera 11, Carrera 14, Carrera 15
Conservación y gestión de vías en buen estado	- Mantenimiento rutinario para prolongar la vida útil. - Limpieza de drenajes, mejora de señalización y refuerzo de capas de rodadura.	Calle 24, Carrera 13, Transversal 20
Monitoreo continuo y uso de inteligencia artificial	- Seguimiento periódico del estado de la infraestructura vial. - Identificación de sectores críticos mediante IA. - Ajuste de estrategias de intervención según evolución del PCI.	Todas las vías evaluadas
Planificación de recursos e inversión estratégica	- Asignación de presupuesto prioritaria en vías más deterioradas. - Evaluación de financiamiento público-privado para rehabilitación y modernización.	General

Fuente: Elaboración del autor con base en los datos obtenidos a través del sistema inteligente Roadly.

El análisis confirma la necesidad de intervenciones prioritarias en los tramos con PCI más bajo, mientras que la infraestructura en buen estado requiere estrategias de mantenimiento preventivo para preservar su funcionalidad y prolongar su vida útil.

6.3.5 Evaluación piloto del estado del pavimento basada en el análisis de resultados con la metodología INVIAS

Esta prueba piloto evalúa el estado de la infraestructura vial en la ciudad de Tunja mediante la metodología de inspección visual en pavimentos flexibles, establecida por el Instituto Nacional de Vías (INVÍAS), con el fin de diagnosticar el estado funcional de las carreteras urbanas seleccionadas a partir de la observación y clasificación sistemática de los daños superficiales presentes en el pavimento.

La inspección se llevó a cabo sobre las vías transversal 19, carrera 14, carrera 15, calle 7, carrera 11, carrera 13, calle 24 y transversal 20, que abarcan aproximadamente 8,715 km lineales. Para

garantizar la rigurosidad del levantamiento de campo y reducir el riesgo de sesgos, la actividad fue realizada por cuatro evaluadores técnicos, organizados en dos parejas de trabajo, cada una asignada a tramos específicos.

Durante el recorrido, cada pareja de evaluadores aplicó los formatos oficiales de recolección INVÍAS, registrando de manera detallada el tipo, severidad, localización y extensión de los deterioros superficiales observados, conforme a los criterios establecidos por el manual de evaluación visual del instituto. Se procuró mantener una cobertura sistemática de toda la superficie de rodadura, garantizando que la información recolectada permitiera cuantificar con precisión las áreas afectadas y caracterizar las patologías predominantes.

A partir del procesamiento de estos datos, se logró establecer un diagnóstico funcional por tramo, identificar los sectores con mayor deterioro y representar gráficamente los resultados. En la Tabla 14 se presentan los resultados sistematizados de la inspección visual, incluyendo la tipología de los daños, su severidad, área afectada y el porcentaje de deterioro correspondiente a cada tramo. Esta información permite realizar una evaluación cuantitativa del estado del pavimento en los sectores analizados, con base en datos confiables y estructurados bajo una metodología reconocida a nivel nacional.

Tabla 16. *Evaluación del estado del pavimento en las vías principales de la ciudad de Tunja mediante inspección visual*


PR (Vía)	PATOLOGÍA	Largo (m)	Ancho (m)	Área (m ²)	% Afectación	Aclaraciones
PR00+500 (Transversal 19)	I PC	11.11	1.2	1.33	0.11%	Fisuras longitudinales medias con propagación lateral.
PR01+250 (Transversal 19)	D AHU	10.14	1.4	1.42	0.12%	Hundimiento con material suelto visible.
PR02+000 (Transversal 19)	E PA	10.14	2.5	3.33	0.29%	Bombeo de finos con alta humedad en la superficie.
PR02+500 (Transversal 19)	I PA, AHU	10.14	2.0	2.5	0.22%	Bombeo de finos y deformación lateral con pérdida de adherencia.
PR03+100 (Carrera 14)	D CDPCH	10.35	1.8	1.35	0.12%	Desgaste de pintura y deterioro superficial debido a ataque químico.
PR03+750 (Transversal 19)	I AHU	10.01	1.3	1.95	0.17%	Ahuellamiento leve con desgaste superficial.
PR04+300 (Transversal 19)	E AHU	11.57	2.3	5.3	0.46%	Ahuellamiento moderado con pérdida de drenaje adecuado.
PR04+900 (Carrera 14)	D PCH	11.15	1.6	1.78	0.16%	Sello de grietas fallado con filtración de agua evidente.
PR05+400 (Carrera 14)	D PA	10.01	2.2	6.6	0.58%	Defecto superficial con irregularidad en la capa asfáltica.
PR06+000 (Transversal 19)	I FL	11.01	1.4	2.8	0.25%	Grietas longitudinales leves sin mayor propagación.
PR06+600 (Transversal 19)	E PC	10.93	1.1	1.21	0.11%	Fisuración en patrón de piel de cocodrilo, con microfracturas visibles.

PR06+600 (Transversal 19)	E PC	11.17	1.3	1.7	0.15%	Fisuración severa en patrón de piel de cocodrilo, con progresión visible.
PR06+600 (Transversal 19)	I PA	11.11	2.0	2.5	0.22%	Defecto superficial sin fisuración visible, pero con desgaste evidente.
PR06+200 (Transversal 19)	D PC	10.14	1.4	1.96	0.17%	Grieta en piel de cocodrilo con leves signos de desintegración.
PR06+200 (Transversal 19)	E PC	10.18	1.5	2.27	0.20%	Grieta en piel de cocodrilo avanzada con deterioro en la superficie.
Transversal 19 - PR03+150	D AHU	11.11	1.8	19.99	1.75%	Bombeo de finos avanzado
Transversal 19 - PR04+050	I PA	11.05	1.6	17.68	1.55%	Bombeo de finos y deformación lateral moderada
Carrera 13 - PR05+310	E PA, AHU	11.08	1.2	13.33	1.17%	Ataque químico en pintura
Carrera 13 - PR05+920	I CDPCH	10	1.7	17	1.49%	Ahuellamiento leve
Carrera 14 - PR07+005	D AHU	11.11	1.4	15.55	1.37%	Deformaciones graves
Carrera 14 - PR07+250	E AHU	11.11	1.6	17.78	1.55%	Sello de grietas fallado
Carrera 14 - PR07+111	D PCH	10	1.5	15	1.31%	Desgaste superficial grave
Calle 24 - PR7+430	I PA	11.13	1.4	15.6	1.36%	Grietas longitudinales avanzadas
Calle 24 - PR7+890	I FL	11.24	1.3	14.62	1.27%	Fisuración extensa
Calle 24 - PR8+070	D PC	11.38	1.5	17.07	1.49%	Superficie irregular moderada
Calle 24 - PR8+090	I PC	11.57	1.7	19.69	1.72%	Deformaciones severas
Carrera 11 - PR8+150	D PA	11.18	1.4	15.63	1.35%	Grietas en piel de cocodrilo avanzadas
Carrera 11 - PR8+325	I PC	10.01	1.6	16.02	1.41%	Reparación recomendada para ahuellamiento
Carrera 11 - PR8+425	E PC	10.01	1.5	15.21	1.32%	Deformación avanzada
Transversal 19 - PR8+650	D PA	10	1.6	16	1.41%	Desgaste superficial
Transversal 19 - PR8+655	I PC	10.11	1.3	13.01	1.14%	Grietas menores
Transversal 19 - PR8+700	E PC	10	1.4	14	1.22%	Grietas superficiales
Carrera 14 - PR8+725	I PA	11.11	1.5	16.67	1.46%	Fisuras menores
PR02+500 (Transversal 19)	I PA, AHU	10.14	2.0	2.5	0.22%	Bombeo de finos y deformación lateral con pérdida de adherencia.

Fuente: Elaboración del autor con base en los datos obtenidos en las vías objeto de estudio.

Distribución del daño en las vías por área afectada. A partir de los datos de la Tabla 16, se elaboró la figura 25, que muestra la magnitud del daño en cada tramo inspeccionado. En el eje de las abscisas se encuentran los tramos evaluados y en el eje de las ordenadas se representa el área afectada en cada uno. Esta representación gráfica facilita la identificación de las zonas más deterioradas y permite comparar la afectación entre distintos sectores.

Figura 25. Distribución del daño en las vías por área afectada.



Fuente: Elaboración del autor con base en los datos procesados provenientes de las vías en estudio.


La figura 29 permite identificar los tramos con mayor área afectada por patologías en la superficie del pavimento. Se observa que los sectores más deteriorados corresponden a las siguientes ubicaciones:

- Transversal 19 - PR03+150: Presenta la mayor área afectada, lo que indica una falla estructural significativa.
- Calle 24 - PR08+090: Predominan fisuras en patrón de piel de cocodrilo (PCH), indicando fatiga del material.
- Carrera 14 - PR07+005: Se observan deformaciones graves, posiblemente por un sello de grietas fallido.

Para complementar este análisis, la figura 29 presenta la distribución del daño según su severidad (baja, media y alta), permitiendo diferenciar los sectores donde el deterioro aún es leve de aquellos donde las fallas son críticas y requieren intervenciones urgentes.

Distribución del daño en las vías por severidad. La gráfica 30 detalla la distribución del daño según su severidad (baja, media y alta) y el tipo de patología identificada en la superficie del pavimento. Este análisis permite diferenciar los sectores donde el deterioro aún es incipiente de aquellos donde las fallas han evolucionado a niveles críticos, requiriendo intervenciones prioritarias.

Figura 26. *Distribución del área afectada por patologías según su severidad.*



Fuente: Elaboración del autor con base en los datos procesados obtenidos de las vías en estudio. Registro fotográfico de los daños más representativos identificados en la inspección visual en campo.

- Severidad baja: La patología PA (pulverización asfáltica) tiene la mayor área afectada, lo que indica desgaste superficial sin un impacto estructural inmediato. AHU (ahuellamiento), PCH (fisuración en piel de cocodrilo) y FL (fisuración longitudinal) presentan menor afectación, sugiriendo daños incipientes que pueden corregirse con mantenimiento preventivo.
- Severidad media: AHU (ahuellamiento) es la patología dominante, reflejando deformaciones progresivas que afectan la capacidad estructural del pavimento. PC

(fisuración por carga) también tiene un impacto significativo, indicando fallas por tránsito repetitivo y fatiga del material.

- Severidad alta: Las patologías más críticas son PA (pulverización asfáltica) y PA-AHU (pulverización combinada con ahuellamiento), evidenciando pérdida de material y deterioro estructural severo. CDPCH (desprendimiento de piel de cocodrilo con pérdida de cohesión), aunque con menor área afectada, representa un riesgo alto por su rápida progresión.

En general, PA y AHU son los daños más recurrentes, con el ahuellamiento como un factor fundamental en la degradación del pavimento. Estos resultados permiten priorizar intervenciones:

- Áreas con severidad alta requieren atención inmediata para evitar la falla total del pavimento.
- Sectores con severidad media necesitan medidas correctivas para frenar la progresión del daño y prolongar la vida útil de la vía.

Evidencia fotográfica de la inspección en campo. Para complementar el análisis cuantitativo de las patologías identificadas en las gráficas 10 y 11, se presentan imágenes obtenidas durante la inspección en campo. Estas fotografías ilustran los principales tipos de deterioro observados y permiten una mejor comprensión del estado actual del pavimento.

Tabla 17. Registro fotográfico de los daños más representativos en la inspección visual en campo

		
Fisuración en piel de cocodrilo (PCH) y Baches (BCH)→ Calle 24 - PR08+090	Baches (BCH), PC (fisuración por carga), FL (fisuración longitudinal) → Carrera 14 - PR07+005	Baches (BCH) y Deformaciones plásticas y sellos fallidos (FL y PC) → Calle 18 - PR04+310

		
Fisuración longitudinal y transversal (PC), Descascaramiento y deterioro superficial (CDPCH), Baches (BCH) → Carrera 21 - PR05+230	Descascaramiento y deterioro superficial (CDPCH), Baches (BCH) → Avenida 5 - PR06+410	Fisuración en piel de cocodrilo (PCH), CDPCH (desprendimiento de piel de cocodrilo) → Calle 30 - PR02+175
		
Descascaramiento y deterioro superficial (CDPCH), Baches (BCH), FL (Fisuración Longitudinal) y FT (Fisuración Transversal) → Carrera 8 - PR07+09),	FL, Baches (BCH), PA-AHU (pulverización combinada con ahuellamiento), FL (Fisuración Longitudinal) y FT (Fisuración Transversal) → Transversal 19 - PR03+150	CDPCH (desprendimiento de piel de cocodrilo con pérdida de cohesión), Baches (BCH) → Transversal 25 - PR09+320

Fuente: Inspección en campo – Elaboración propia del autor.

El piloto realizado con Roadly PRO permitió evaluar el estado del pavimento en un tiempo significativamente menor en comparación con la inspección visual tradicional. La recolección de datos e inspección se efectuó en aproximadamente una hora, mediante un recorrido en vehículo con un celular, y el análisis de la información tomó alrededor de dos días, con un solo profesional a cargo. Además, el software identificó automáticamente las vías en peor estado, aquellas que requerían mantenimiento prioritario y las que necesitaban intervenciones preventivas o periódicas, optimizando la gestión vial y reduciendo costos operativos. Cabe destacar que las condiciones climáticas fueron óptimas durante la prueba piloto, lo que permitió realizar la inspección sin interrupciones y con alta precisión en la captura de datos.

En contraste, la inspección visual realizada bajo la metodología INVIAS para el mismo tramo requirió aproximadamente 15 días de trabajo en campo, más otros 15 días para el análisis de datos, con un equipo de cuatro profesionales. Este proceso implicó jornadas diarias de dos a tres horas en campo, limitadas por factores como movilidad y condiciones climáticas adversas, lo que dificultó la continuidad de la inspección. Adicionalmente, la transcripción manual de la información en Excel presentó inconsistencias, dado que algunos evaluadores registraron datos erróneos o aplicaron criterios dispares en la clasificación de los daños.

Con base en lo anterior, se concluye que la inspección de las vías mediante inteligencia artificial resultó más eficiente y precisa. Esta tecnología permitió una clasificación objetiva y cuantificable de los daños, optimizando la toma de decisiones sobre mantenimiento y rehabilitación vial con menos personal, en menor tiempo y sin necesidad de transcripción manual de datos.

La inteligencia artificial agiliza la evaluación vial, mejora la precisión en la clasificación de daños y optimiza la gestión de recursos, garantizando intervenciones eficientes y sostenibles.

El diagnóstico generado por el sistema inteligente facilita la priorización de intervenciones críticas, permitiendo actuar de manera oportuna para evitar el agravamiento de las fallas estructurales y optimizar el uso de recursos. Además, este enfoque representa un avance significativo en la gestión de infraestructura vial, ya que proporciona datos precisos y reproducibles, mejorando la planificación estratégica y asegurando una asignación eficiente del presupuesto destinado al mantenimiento vial.

6.4 Análisis de costo financiero y costo-beneficio de la implementación de IA en la infraestructura vial en Colombia

El mantenimiento de la infraestructura vial en Colombia enfrenta grandes desafíos debido a las diversas condiciones geográficas, climáticas y logísticas, así como a la falta de planeación, transparencia y mejorar la planificación del presupuesto anual e informar las necesidades financieras. Aunque cada administración local destina recursos considerables para la inspección e intervención de las vías con el fin de mejorar el transporte, reducir los costos operativos, incrementar la seguridad vial y peatonal, estimular el desarrollo económico, fomentar el turismo, mejorar la competitividad tanto nacional como internacional, y promover el desarrollo regional y

la estabilidad económica, los métodos tradicionales utilizados para el registro de las vías en Colombia siguen siendo obsoletos. Este método implica la asignación de varios profesionales para identificar daños en las vías y elaborar informes y presupuestos de intervención que, según algunos investigadores citados en este estudio, a menudo resultan costosos, carecen de objetividad y, en algunos casos, no reflejan adecuadamente la realidad de los daños, complicando así la atención y resolución de las complejas necesidades viales.

En este capítulo, analiza la viabilidad de adquirir e implementar un sistema de inteligencia artificial (IA) para automatizar la inspección y el análisis de daños de sus vías en Colombia. El objeto principal de este análisis financiero detallado de los gastos y beneficios asociados a la compra e implementación de dicha tecnología. Para ello, se llevará a cabo un análisis de costo-beneficio basado en cálculos financieros que consideran los costos asociados a la adquisición del sistema de IA, la infraestructura tecnológica necesaria, la contratación de personal para su operación y mantenimiento, así como los costos de retroalimentación anual del sistema.

A través de este enfoque financiero, se desea determinar si la compra e implementación de un sistema de IA representa una alternativa más rentable y sostenible a largo plazo, en comparación con los métodos tradicionales. También se evaluarán los beneficios adicionales que este sistema podría ofrecer, tales como la reducción de costos operativos, la mejora en la toma de decisiones y la optimización del mantenimiento preventivo de la infraestructura vial. Este análisis se apoyará en datos reales, costos de inversión que hace este municipio para la atención de inventarios y estado de la malla vial de la ciudad mediante los métodos tradicionales, por otro lado, se obtuvieron cotizaciones de proveedores y programadores en sistemas de inteligencia artificial diseñados para la toma de daños viales, lo que proporcionará una visión precisa sobre la viabilidad financiera del proyecto.

Finalmente, el presente análisis de costo-beneficio tiene como objetivo evaluar la viabilidad económica y financiera del proyecto de implementación de un sistema de Inteligencia Artificial (IA) para la inspección y el mantenimiento de la red nacional. Este estudio es crucial para determinar, evaluar la viabilidad económica y financiera del proyecto. Como resolver los problemas de costos, imprecisión, limitaciones. Presenta la IA como una solución que ofrece mejoras en eficiencia, precisión y seguridad. Si la inversión propuesta representa una decisión

estratégica que optimice el uso de los recursos públicos, mejore la eficiencia en la gestión de la infraestructura vial, y genere un valor agregado para la comunidad.

Expuesto lo anterior, la alcaldía destina aproximadamente 150 millones anuales al pago de personal para inspecciones manuales, para hacer informes, sacar presupuesto y toma de decisiones informadas sobre las estrategias de rehabilitación y mantenimiento de la red vial, un proceso que resulta costoso, impreciso y limitado. La adopción de un sistema de IA promete transformar esta realidad, ofreciendo una inspección más eficiente, precisa y segura como la toma de decisiones en las vías críticas a intervenir, además de un mantenimiento proactivo que puede reducir significativamente los costos a largo plazo.

En este análisis se examinarán detalladamente tanto los costos asociados al desarrollo e implementación del sistema de IA (incluyendo la inversión inicial, el desarrollo de software, la infraestructura tecnológica, la recopilación de datos, los costos de personal y los gastos de mantenimiento) como las ventajas que se esperan obtener (ahorros en costos de inspección y reparación, mejora en la seguridad vial, optimización de la gestión financiera, generación de ingresos adicionales, e impactos sociales y ambientales positivos).

Este análisis proporciona una visión clara y objetiva de los costos y beneficios del proyecto, tomando en cuenta las particularidades del municipio, integrándolo a las tendencias internacionales, y buenas prácticas en la gestión de infraestructura vial como sostenibles. Este estudio busca brindar una base sólida para la toma de decisiones de este municipio cualquier otro del país, apoyando una gestión responsable y eficiente de los recursos públicos.

6.5 Análisis financiero de la inversión en la implementación de sistemas de inteligencia artificial en Colombia

Se presenta una propuesta para optimizar la gestión y el mantenimiento de la infraestructura vial en Colombia, una iniciativa que podría ser adoptada por otras ciudades del país interesadas en mejorar su red vial. La propuesta consiste en la implementar un sistema de inteligencia artificial (IA) para la inspección de las vías. De acuerdo con la información de la Secretaría de Infraestructura de la alcaldía de Tunja, actualmente se destinan 150 millones de pesos anuales al pago de personal encargado de llevar a cabo las inspecciones viales.

Al comparar los costos de adquirir un sistema de IA, con una inversión inicial de 350 millones de pesos (según cotizaciones de empresas especializadas), y gastos anuales de 25 millones de pesos para el salario de un profesional, además de 25 millones anuales para mantenimiento y retroalimentación del sistema, se realizará un análisis financiero. Este análisis evaluará los beneficios a largo plazo de la tecnología, incluyendo mejoras en la evaluación de daños en las vías, y la optimización de los recursos financieros en términos de eficiencia, precisión, seguridad y calidad del mantenimiento.

6.5.1 Principales problemas en la inspección de daños de la infra estructura vial

Actualmente, la inspección de vías en la alcaldía se realiza de manera tradicional, lo que implica:

- Altos costos de personal: 150 millones anuales destinado a personal de inspección vial.
- Limitaciones en la precisión: La detección de daños es subjetiva y menos exacta.
- Tiempo de respuesta lento: La inspección tradicional demora la identificación de daños y la programación de intervenciones.
- Acceso limitado a áreas difíciles: La inspección tradicional tiene dificultades en zonas de difícil acceso, como son de vandalismo y otros factores sociales.

Con la implementación de un sistema de IA para la inspección de vías, se espera:

Automatización de la inspección: El sistema de IA podrá realizar la inspección de forma automática, reduciendo la dependencia de profesionales.

- Mayor precisión: La IA detectara daños como grietas, baches, deformaciones y otras patologías con mayor precisión y detalle.
- Mayor rapidez: El sistema de IA podrá arrojar resultados de inspección de forma rápida, activando la toma de decisiones y la programación de intervenciones.
- Acceso a áreas difíciles: El sistema de IA logrará realizar inspecciones en zonas de difícil acceso social, lo que no es posible con la inspección tradicional.
- Mantenimiento preventivo: La detección temprana de daños permitirá realizar una adecuada gestión, optimizando costos a largo plazo y mejorando la movilidad como la seguridad vial.

6.5.2 Componentes del sistema de inteligencia artificial

El Sistema integra redes neuronales profundas (CNN) y visión artificial para la inspección y mantenimiento de infraestructuras viales.

Componentes del Sistema:

- **Redes Neuronales Convolucionales (CNN):** Procesan y analizan imágenes de alta resolución capturadas por cámaras instaladas en vehículos. Permiten la detección y clasificación de daños en las vías, como grietas, baches y deformaciones entre otras patologías.
- **Visión Artificial:** Analiza e interpreta imágenes y detectar elementos específicos como señales de tráfico defectuosas, tapas de alcantarillado y otros objetos relevantes para el mantenimiento vial.
- **Software y Hardware Especializado:** Comprende de algoritmos avanzados de IA para el análisis de datos y la generación de informes detallados. Incluye cámaras de alta resolución, sensores y dispositivos de almacenamiento de datos.
- **Operación del Sistema:** Un profesional especializado supervisa la ejecución del sistema (salario anual: 25 millones) inversión a cargo de la entidad
- **Optimización del Sistema:** proceso de retroalimentación anual para mejorar la precisión y el rendimiento del sistema inteligente, con inversión a cargo de la entidad.

6.5.3 Análisis de costo-beneficio

Este análisis evaluar la viabilidad de la adquirir e implementación de un sistema de inteligencia artificial que permita identificar objetivamente los daños en la infraestructura vial, facilitando la toma de decisiones y las intervenciones durante un periodo de siete años. Asimismo, determina si el sistema es rentable, sostenible, beneficioso, así como la optimización de costos asociados a su implementación.

6.5.4 Estrategias financieras para la optimización de costos

A partir del análisis comparado de soluciones tecnológicas disponibles a nivel internacional para la inspección de infraestructura vial mediante inteligencia artificial, se identifican dos enfoques estratégicos diferenciados desde la perspectiva financiera:

(i) el modelo de gasto operativo (OpEx), basado en el alquiler o suscripción a servicios especializados, y (ii) el modelo de gasto de capital (CapEx), orientado a la adquisición directa de equipos, software y capacidades técnicas propias (ver Tabla 2).

La evaluación de ambas estrategias se fundamenta en fuentes técnicas internacionales, estudios de mercado recientes y estimaciones asociadas al ciclo de vida operativo de cada solución. El propósito es brindar a las entidades públicas herramientas analíticas para tomar decisiones sostenibles desde el punto de vista técnico, presupuestal y operativo.

6.5.4.1 Modelo OpEx: Alquiler o Suscripción Tecnológica. El enfoque OpEx permite externalizar la operación tecnológica, accediendo a sistemas avanzados bajo esquemas de pago recurrente (por informe, mensual o anual). Esta modalidad ofrece ventajas en términos de flexibilidad, actualización tecnológica constante, y eliminación de la inversión inicial significativa, a cambio de una dependencia operativa del proveedor. La Tabla 1 sintetiza los costos estimados para sistemas inteligentes bajo modelos de alquiler, considerando plataformas basadas en inteligencia artificial, sensores ópticos, drones y soluciones tipo SaaS. Las cifras están expresadas en valores de mercado recientes (2023–2024), convertidas a pesos colombianos con tasas de cambio de referencia.

Tabla 18. Costos de alquiler de sistemas inteligentes para inspección vial

Categoría de Servicio / Empresa	Enfoque Tecnológico	Modalidad de Servicio	Costo Promedio por Kilómetro (USD / COP)	Observaciones
Vialytics	Diagnóstico vial con IA y smartphones	Servicio integral por suscripción	€150 / km ≈ 658.250 COP/km	Diagnóstico de 15 tipos de daño; escalable
SRCC / UAVLatam (Colombia)	Drones con LiDAR / sensores RGB + IA	Alquiler por captura	\$300–\$600 USD / km ≈ 1,3M–2,6M COP/km	Incluye datos 3D; análisis IA no siempre incluido
FlyPix AI	Visión artificial satelital / drones	SaaS (solo software)	\$660 – \$32.000 USD / año	Requiere hardware adicional propio

Soluciones con Smartphone	IA con teléfonos móviles (Pluto, RoadMetrics)	Suscripción mensual	No aplica por km	Bajo costo, menor resolución técnica
---------------------------	---	---------------------	------------------	--------------------------------------

Fuente: Elaboración propia con base en Vialytics (2020), UAVLatam (2024), SRCC (2023), Sistemas Sostenibles SAS (2020), FlyPix AI (2023), e informes técnicos de licitaciones LATAM.

A modo de análisis, si una entidad distrital como el Instituto de Desarrollo Urbano (IDU) en Bogotá optara por inspeccionar su red vial (14.587,85 km-carril) con una plataforma tipo Vialytics, cuyo costo estimado por kilómetro es de €150 EUR/km, equivalente a aproximadamente 658.250 COP/km (según tasa de cambio promedio de 2024), la inversión por un solo ciclo de monitoreo superaría los 9.600 millones de pesos colombianos. En caso de proyectarse inspecciones de forma trimestral o semestral, el gasto anual podría duplicarse o triplicarse, lo que haría financieramente inviable su implementación sin mecanismos de cofinanciación o alianzas interinstitucionales.

6.5.4.2 Modelo CapEx: Adquisición Directa del Sistema. Este modelo propone la adquisición integral y definitiva del sistema tecnológico para la inspección de infraestructura vial, abarcando desde el hardware y el software hasta las licencias y el personal técnico necesario para su operación. La inversión inicial se clasifica como gasto de capital (CapEx), lo cual habilita el uso autónomo y continuo del sistema bajo condiciones de soberanía tecnológica, independencia operativa y reducción progresiva de los costos unitarios por kilómetro inspeccionado.

Existen diversas alternativas de adquisición disponibles en el mercado nacional e internacional, ofrecidas por fabricantes con presencia en América, Europa y Asia. Estas opciones varían en complejidad técnica, escalabilidad y rango de precios, lo cual demuestra que la implementación del modelo CapEx no se limita a soluciones de alto costo o difícil acceso. Por el contrario, las entidades públicas pueden acceder a sistemas adaptables a diferentes niveles de inversión, con opciones que van desde drones básicos hasta vehículos instrumentados de última generación. Esta diversidad tecnológica permite realizar una selección alineada con la capacidad presupuestal, los requerimientos operativos y los objetivos estratégicos de cada institución.

Tabla 19. Costos de adquisición de sistemas inteligentes para inspección vial

Empresa	Ubicación	Tipo de Sistema / Componente	Venta / Alquiler	Costo Estimado (USD)	Observaciones
Vialytics	Alemania / Global	Plataforma IA (software + app móvil)	Alquiler / suscripción	\$11,520 – \$32,710 / año	Escalable; requiere solo smartphones

FlyPix AI	EE. UU. / Global	Plataforma SaaS de análisis por IA	Alquiler (software)	\$660 – \$32,000 / año	Requiere drones o imágenes satelitales
ARRB Systems	Australia	Vehículo Hawkeye (LiDAR, GPR, cámaras)	Venta	\$500,000 – \$2,000,000	Sistema completo con soporte
Dynatest	Dinamarca	Falling Weight Deflectometer (FWD)	Venta	\$200,000 – \$500,000	Para análisis estructural
Pavemetrics (Trimble)	Canadá	Sistema LCMS (láser para grietas)	Venta	\$150,000 – \$1,500,000	Visión artificial avanzada
IDS GeoRadar	Italia	RoadScanner (GPR + LiDAR + cámaras)	Venta	\$100,000 – \$500,000	Integración geotécnica profunda
DJI Enterprise	China	Drones RTK + Zenmuse L1	Venta	\$6,000 – \$15,000 (solo dron)	Solo hardware de captura
Sistemas Sostenibles SAS	Colombia	Representación local de Vialytics	Suscripción / soporte	Según licenciamiento local	Soporte técnico y adaptación nacional

Fuente: Elaboración propia con base en Pavemetrics (2023), ARRB Systems (2024), Dynatest (2023), IDS GeoRadar (2024), DJI Enterprise (2023), Sistemas Sostenibles SAS (2024), cotizaciones de mercado en LATAM.

Además del análisis internacional, durante el desarrollo de esta investigación se realizaron cotizaciones directas con proveedores locales, a fin de estimar la viabilidad económica de adquirir y operar un sistema de inspección vial dentro del contexto colombiano. Con base en promedios regionales, se estima una inversión total cercana a \$350 millones COP (aprox. \$89.743 USD) para un sistema compuesto por dron RTK, sensor LiDAR, licencias de software de análisis y hardware básico. A ello se adiciona un costo anual de operación de aproximadamente \$50 a \$55 millones COP, que incluye mantenimiento y personal especializado.

Tabla 20. *Costos operativos anuales estimados tras adquisición*

Concepto	Rango Estimado COP	Equivalente USD (aprox.)
Mantenimiento del sistema	\$25.000.000	\$6.410
Personal técnico especializado	\$25.000.000 - \$30.000.000	\$6.410 - \$7.692
Total anual aproximado	\$50.000.000 - \$55.000.000	\$12.820 - \$14.102

Fuente: Elaboración propia con base las cotizaciones realizadas colombianos (2024).

La evidencia técnica y económica analizada indica que existen múltiples alternativas viables para la adquisición directa de sistemas inteligentes de inspección vial, tanto en el ámbito internacional como nacional. Esta diversidad permite adaptar la estrategia CapEx a los marcos presupuestales de distintas entidades públicas sin sacrificar calidad, escalabilidad o soporte técnico.

El modelo de adquisición directa se consolida como una estrategia que no solo garantiza autonomía operativa y soberanía tecnológica, sino que también optimiza el costo por kilómetro inspeccionado a lo largo del tiempo. Su implementación contribuye a la construcción de capacidades institucionales permanentes, favorece la interoperabilidad entre sistemas y abre posibilidades para el desarrollo de economías de escala mediante esquemas de colaboración interinstitucional y generación de servicios públicos especializados. Por tanto, se recomienda a las entidades públicas con competencias en infraestructura vial priorizar la evaluación del modelo CapEx como una solución técnica, presupuestal y operativamente sostenible en el mediano y largo plazo.

6.5.5 Estrategias de optimización para la gestión de infraestructura vial

La retroalimentación dirigida se enfocará en el mantenimiento y reentrenamiento del sistema de inteligencia artificial, especialmente en áreas de bajo rendimiento y en la mejora de su capacidad para identificar nuevos tipos de daños, garantizando una actualización constante y eficiente. Además, se optimizará la eficiencia en el uso de información mediante la complementación de los inventarios reales con datos sintéticos, lo que permitirá un uso más eficiente y preciso de la información disponible, reduciendo recursos profesionales y costos.

La automatización de actividades posibilitará la elaboración automática de informes, alertas y la reprogramación de intervenciones, reduciendo la carga de trabajo tradicional y los gastos asociados, mientras mejora la respuesta ante incidencias. El sistema de inteligencia artificial se integrará con los sistemas de gestión de infraestructura, el sistema de información geográfica (GIS), los sistemas de mantenimiento de activos (CMMS) y análisis, entre otros, creando un entorno integrado que optimizará la gestión general. La redistribución del personal implicará la reasignación de actividades de inspección de las vías a tareas más críticas que demanden mayor dedicación y profesionalismo, optimizando recursos profesionales y permitiendo que el sistema automatizado se encargue de las tareas de inspección y revisión de daños. Las estrategias de generación de ingresos abarcan la comercialización de la información obtenida por el sistema a otras entidades, así como el alquiler del sistema de inteligencia artificial y la oferta de servicios especializados de consultoría y capacitación.

6.5.6 Balance financiero proyectado (7 años).

A continuación, se presenta un balance financiero proyectado para la toma de decisiones, donde se evalúa la factibilidad de adquirir un Sistema de Inteligencia Artificial (IA) para la inspección de daños en vías nacionales. Este balance se ha llevado a cabo para un periodo de 7 años y tiene como objetivo de exponer a las partes interesadas, en especial entidades públicas, los beneficios y riesgos asociados en la puesta en marcha de este sistema.

A continuación, se presenta la proyección de un balance financiero para evaluar la viabilidad de adquirir un sistema de inteligencia artificial (IA) para la inspección de daños en vías nacionales. Este análisis se realiza para un periodo de 7 años y tiene como propósito exponer a las partes interesadas, en particular a las entidades públicas, una visión clara de los beneficios y riesgos asociados con la implementación de dicho sistema.

Tabla 21. Análisis de viabilidad financiera para la implementación de un sistema de inteligencia artificial en la inspección de daños viales (proyección a 7 años)).

Concepto	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Total / Valor Final
EGRESOS E INVERSIONES									
Inversión Inicial (Sistemas IA y Otros)	-350	0	0	0	0	0	0	0	-350
Costos Operativos (Con IA)	0	-50	-50	-50	-50	-50	-50	-50	-350
Salario Profesional (Capacitación / Mantenimiento)	0	-25	-25	-25	-25	-25	-25	-25	-175
Retroalimentación de la IA (Optimización)	0	0	-25	-25	-25	-25	-25	-25	-150
TOTAL, EGRESOS (A)	-350	-75	-100	-100	-100	-100	-100	-100	-1025
INGRESOS Y AHORROS									
Ahorros por Reducción de Gastos Operativos	0	100	100	100	100	100	100	100	700
Ahorros por Reducción de Gastos de Personal	0	100	100	100	100	100	100	100	700
Venta de Datos e Informes	0	0	3	6	9	12	15	20	65
Servicios de Consultoría	0	0	2	4	6	8	10	15	45
Ingresos por Alquiler del Sistema	0	0	5	10	15	20	25	30	105
Ingresos por Nuevos Servicios y Productos	0	0	0	0	0	0	10	15	25
TOTAL INGRESOS Y AHORROS (B)	0	200	210	220	230	240	310	340	1750
FLUJO DE CAJA NETO ANUAL (B - A)	-350	125	120	140	160	180	210	240	825

FLUJO DE CAJA									
ACUMULADO (del Proyecto Total)	-350	-225	-105	35	195	375	585	825	825
AHORRO ACUMULADO	-350								
NETO ATRIBUIBLE A LA IA (Considerando Inversión) ¹		-225	-125	-25	75	175	275	375	375
MÉTRICAS DE EVALUACIÓN FINANCIERA									
Valor Presente Neto (VPN) @ 8%									392.23
Tasa Interna de Retorno (TIR)									24.89%
Retorno de Inversión (ROI) Simple									235.71%
Retorno de Inversión (ROI) (VPN Anualizado)									16.01%

Fuente: Elaboración del autor con base en los datos suministrados por la Alcaldía de Tunja sobre salarios profesionales y cotizaciones para el desarrollo de IA.

Notas El Ahorro Acumulado Neto Atribuible a la IA se calcula como la acumulación de los (Ahorros Brutos Anuales por IA - Costos Operativos Directos de la IA Anuales), compensado por la Inversión Inicial específica de la IA.

Nota: Todos los valores están expresados en millones de pesos colombianos (COP).

El balance financiero proyectado presenta los costos y ahorros estimados anualmente, destacando la optimización de recursos y los beneficios a largo plazo. Incluye la inversión inicial, los gastos operativos y los ahorros derivados de la implementación de un sistema de inteligencia artificial (IA). Sin embargo, este análisis por sí solo no es suficiente. Es fundamental realizar una evaluación detallada de la viabilidad financiera del proyecto, considerando la tasa de descuento aplicada a los flujos de caja proyectados, así como el cálculo del Valor Presente Neto (VPN) y el Retorno de la Inversión (ROI). Además, se debe realizar un análisis de sensibilidad para evaluar cómo las variaciones en los supuestos, como los costos de implementación o los beneficios esperados, pueden afectar la rentabilidad del proyecto. A continuación, se presentan los cálculos del Valor Presente Neto (VPN) y el Retorno de la Inversión (ROI), junto con el análisis de sensibilidad, que constituyen indicadores fundamentales para evaluar con mayor precisión la viabilidad financiera del proyecto.

Cálculo del Valor Presente Neto (VPN)

- Para calcular el valor presente neto (VPN), se empleará la tasa de descuento que refleje el costo de oportunidad del país. Para este estudio, se aplicará una tasa de descuento del 8% anual, conforme a las políticas financieras del país.
- VPN (Valor Presente Neto): Indicador que se pretende evaluar.

$$VPN = \sum_{t=0}^n \frac{C_t}{(1+r)^t} - C_0$$

Donde:

Datos del proyecto:

- Inversión inicial: 350 millones de pesos.
- Descripción: El desembolso lo realizará la entidad interesada en el año 0 para la adquisición del sistema de IA y los gastos iniciales de implementación.
- Número de años del proyecto (n): 7 años. Es el período durante el cual se evaluará el proyecto.
- Tasa de descuento (r): 8% o (0.08 en forma decimal). La tasa de descuento representa el costo de oportunidad del país.
- Flujos de caja netos (FC1, FC2, ..., FCn), que representan los ingresos y egresos esperados durante el proyecto.

A continuación, se presentan los flujos de caja netos (ingresos menos egresos) para para los siete años del proyecto.

Tabla 22. *Flujo de caja neto por año*

Año (n)	FCn (Millones COP)	Factor de Descuento (8%)	FC Descontado (Millones COP)
0	-350.00	1.000	-350.00
1	125.00	0.9259	115.74
2	120.00	0.8573	102.88
3	140.00	0.7938	111.14
4	160.00	0.7350	117.60
5	180.00	0.6806	122.50
6	210.00	0.6302	132.33

7	240.00	0.5835	140.04
Suma Flujos Descontados (años 1–7)	—	—	742.23
Cálculo VPN	—	—	VPN = -350.00 + 742.23 = 392.23 millones COP

Fuente: Elaboración del autor con base en el análisis financiero incluido en el presente estudio.

Nota: Todas las cifras corresponden a Millones COP.

Cálculo del valor presente neto (VPN):

$$VPN = \frac{-350}{(1 + 0.08)^0} + \frac{125}{(1 + 0.08)^1} + \frac{120}{(1 + 0.08)^2} + \frac{140}{(1 + 0.08)^3} + \frac{160}{(1 + 0.08)^4} + \frac{180}{(1 + 0.08)^5} + \frac{210}{(1 + 0.08)^6} + \frac{240}{(1 + 0.08)^7}$$

$$VPN = 350.00 + 115.74 + 102.88 + 111.14 + 117.60 + 122.50 + 132.33 + 140.04$$

$$VPN = 392.23 \text{ millones COP}$$

Estos valores resultan de considerar los ahorros operativos generados por la IA, los ingresos adicionales provenientes del alquiler del sistema, la comercialización de servicios y venta de datos, descontando los costos operativos asociados al funcionamiento del sistema.

Interpretación del VPN. Aunque el VPN obtenido es adecuado, Meza Orozco (2013) señala que las variables consideradas en el análisis financiero pueden experimentar variaciones que afecten la rentabilidad del proyecto a largo plazo. Por ello, antes de tomar una decisión definitiva sobre la aceptación o rechazo de una inversión, es esencial realizar un análisis de sensibilidad. Este análisis permite evaluar cómo las fluctuaciones en variables, tales como ingresos, costos, precios y la tasa de oportunidad del inversionista, impactan la rentabilidad del proyecto, facilitando la identificación de riesgos y la formulación de estrategias de inversión más precisas y ajustadas.

Retorno de Inversión (ROI) (Simple): El ROI Simple es una medida básica de la eficiencia de una inversión. Calcula la ganancia neta total generada por la inversión en relación con el costo inicial de la inversión, sin considerar el valor del dinero en el tiempo.

$$ROI_{Simple} = \frac{Ganancia\ Neta\ Total\ del\ Proyecto}{Inversión\ inicial\ total\ (Valor\ Absoluto)} * 100\%$$

Dónde:

- Ganancia Neta Total del Proyecto: En el contexto de un Flujo de Caja Acumulado, esta es la suma de todos los Flujos de Caja Neto Anuales del proyecto (desde el Año 0 hasta el final de la vida del proyecto). En otras palabras, es el Flujo de Caja Acumulado al final del proyecto (Año 7).
- Flujo de Caja Acumulado al Año 7 = 825 millones COP
- Inversión Inicial Total (Valor Absoluto): La magnitud de la inversión inicial en el Año 0.
- Inversión Inicial = 350 millones COP

Cálculo:

$$ROI_{Simple} = \frac{825\text{ millones COP}}{350\text{ millones COP}} * 100\%$$

$$ROI_{Simple} = 2.3571 \times 100\%$$

$$ROI_{Simple} = 235.71\%$$

Interpretación: Por cada peso invertido en este proyecto, se espera recuperar la inversión inicial y obtener una ganancia adicional de 2.3571 pesos al final de la vida del proyecto, sin descontar el valor del dinero en el tiempo.

Retorno de Inversión (ROI) (VPN Anualizado), no es una métrica financiera estándar y su interpretación puede variar. Sin embargo, puedo ofrecerte las métricas estándar que se relacionan con la rentabilidad anualizada y el valor presente, las cuales son cruciales en el análisis de proyectos:

Ecuación 2: Calcular del Retorno de la Inversión (ROI) en función del valor presente neto (VPN):

$$ROI_{VPN\ Anualizado} = \left(\frac{VPN}{Inversión\ Inicial\ Total\ (Valor\ Absoluto)} \right) \times \frac{1}{7} \times 100\%$$

Donde:

- VPN: VPN (calculado con mis FCn) = 392.23 millones COP
- Inversión Inicial = 350 millones COP
- Tiempo: Vida del Proyecto = 7 años

$$ROI_{VPN \text{ Anualizado}} = \left(\frac{392.23 \text{ millones COP}}{350 \text{ millones COP}} \right) \times \frac{1}{7} \times 100\%$$

$$ROI_{VPN \text{ Anualizado}} = \frac{1.120657}{7} \times 100\%$$

$$ROI_{VPN \text{ Anualizado}} = 0.16009 \times 100\% = 16.01\%$$

De acuerdo con el resultado obtenido, el ROI de la inversión en la adquisición de un sistema inteligente muestra una rentabilidad significativa durante el periodo de vida útil del sistema, considerando el valor temporal del dinero a lo largo de los 7 años.

Por otro lado, la Tasa Interna de Retorno (TIR) es un indicador en la evaluación de proyectos de inversión, mostrando la rentabilidad anual esperada al ser definida como la tasa que iguala el Valor Presente Neto (VPN) a cero. Su utilidad principal radica en la capacidad de comparar esta rentabilidad intrínseca con el costo de capital del proyecto o con la tasa de retorno mínima requerida por la organización.

Dado que su cálculo implica la resolución de ecuaciones no lineales, se emplean comúnmente herramientas de software financiero como Microsoft Excel, cuya función TIR (o IRR) es reconocida y utilizada globalmente por su precisión y confiabilidad en el ámbito profesional y académico.

En el presente análisis, la TIR calculada asciende a 24.89%. Este valor se sitúa muy por encima del 8% de tasa de descuento considerada, lo cual evidencia que el proyecto es altamente rentable y supera ampliamente el costo de oportunidad del capital invertido, lo que lo convierte en una opción financiera atractiva.

Análisis de Sensibilidad variables y su impacto. El análisis de sensibilidad es una técnica fundamental en la evaluación financiera de proyectos. Permite identificar cómo las variaciones en variables que afectan indicadores críticos de rentabilidad como el Valor Presente Neto (VPN) y el Retorno sobre la Inversión (ROI). Su objetivo es evaluar la robustez financiera del proyecto ante posibles fluctuaciones económicas, técnicas o de gestión, proporcionando información para la toma de decisiones estratégicas fundamentadas.

Para este estudio, se identificaron cinco variables estratégicas por su impacto potencial en los flujos de caja del proyecto:

- Tasa de descuento: representa el costo de oportunidad del capital.
- Costos de retroalimentación de la IA: corresponde a gastos técnicos de mantenimiento y actualización.
- Ahorros en gastos de personal: derivados de la sustitución de procesos tradicionales por automatización con IA.
- Ingresos adicionales: provenientes de venta de informes, consultorías y alquiler del sistema.
- Inversión inicial: asociada a la implementación del sistema de inteligencia artificial.
-

Estas variables fueron seleccionadas por su relación directa con los ingresos y egresos más relevantes del proyecto, y por representar puntos de incertidumbre financiera crítica.

Definición de escenarios y variable evaluada bajo tres escenarios:

- Escenario base: valores definidos en el plan financiero inicial.
- Escenario pesimista: deterioro del 20 % en ingresos o aumento del 20 % en costos.
- Escenario optimista: mejora del 20 % en ingresos o reducción del 20 % en costos.

Para la tasa de descuento, se aplicó una variación de ± 2 puntos porcentuales respecto al valor base del 8 %, el cual está establecido por el Departamento Nacional de Planeación (DNP) en su Guía General para la Formulación y Evaluación de Proyectos de Inversión Pública en Colombia (DNP, 2020). Esta tasa representa el costo de oportunidad del capital público y constituye un estándar de referencia en evaluaciones del sector estatal.

Como resultado, se utilizaron tasas del 6 % (escenario optimista) y 10 % (escenario pesimista), lo que permite simular entornos macroeconómicos alternativos. Este rango sigue una práctica ampliamente aceptada en análisis de sensibilidad financiera, recomendada por Brealey, Myers y Allen (2022) en *Principles of Corporate Finance*, donde se propone probar el efecto de variaciones razonables en el costo del capital para evaluar la robustez del Valor Presente Neto (VPN) y facilitar la toma de decisiones bajo incertidumbre.


Estos escenarios, junto con las demás variables evaluadas (ahorros en personal, ingresos adicionales, costos de retroalimentación de IA e inversión inicial), se resumen en la Tabla 15, donde se presentan los valores del VPN y el ROI anualizado bajo cada escenario.

Tabla 23. Análisis de sensibilidad para cada variable (VPN y ROI Anualizado)

Variable	Escenario	VPN (Millones)	ROI Anual (VPN)
Tasa de Descuento	Base (8 %)	392.23	16.01 %
	Pesimista (10 %)	333.40	13.61 %
	Optimista (6 %)	431.45	17.61 %
Costos de Retroalimentación de IA	Base	392.23	16.01 %
	Pesimista (+20 %)	360.85	14.73 %
	Optimista (−20 %)	423.61	17.29 %
Ahorros en Gastos de Personal	Base	392.23	16.01 %
	Pesimista (−20 %)	345.16	14.09 %
	Optimista (+20 %)	439.30	17.93 %
Ingresos Adicionales	Base	392.23	16.01 %
	Pesimista (−20 %)	353.01	14.41 %
	Optimista (+20 %)	431.45	17.61 %
Inversión Inicial	Base	392.23	16.01 %
	Pesimista (+20 %)	353.01	14.41 %
	Optimista (−20 %)	431.45	17.61 %

Fuente: Fuente: Elaboración propia a partir del análisis financiero del proyecto.

Figura 27. Impacto de escenarios pesimistas y optimistas sobre el VPN



Fuente: Elaboración propia con base en el análisis financiero del proyecto, construido a partir de los escenarios simulados para el Valor Presente Neto (VPN) bajo variaciones en las variables. La Tabla 20 y la Figura 31 evidencian el impacto relativo de cinco variables estratégicas sobre el Valor Presente Neto (VPN) y el Retorno sobre la Inversión (ROI) anualizado, bajo escenarios base, pesimista y optimista.

Entre las variables analizadas, el ahorro en gastos de personal se destaca como el factor de mayor sensibilidad: una variación del $\pm 20\%$ genera cambios de hasta ± 47 millones en el VPN, resultado de su efecto acumulativo durante todo el horizonte del proyecto.

La tasa de descuento también presenta un impacto crítico. Su variación entre 6% y 10% modifica el VPN en casi 100 millones, lo cual refleja la sensibilidad del proyecto a cambios en el costo del capital, en línea con los principios del descuento compuesto.

Los ingresos adicionales y la inversión inicial muestran una sensibilidad media, con variaciones de aproximadamente ± 39 millones. Estas cifras resaltan la importancia de optimizar la estrategia comercial y negociar condiciones favorables de financiación e implementación.

En contraste, los costos de retroalimentación de la IA generan el menor impacto (± 31 millones), aunque su carácter recurrente los convierte en un componente relevante para la eficiencia operativa.

La Figura 27, tipo tornado, jerarquiza gráficamente estas variables según su efecto en el VPN, destacando el ahorro en personal y la tasa de descuento como los principales determinantes de la rentabilidad.


En síntesis, el proyecto mantiene un VPN positivo en todos los escenarios simulados, lo que demuestra su robustez financiera. Además, las variables más sensibles son gestionables internamente, lo que refuerza la viabilidad técnica y estratégica de la inversión.

Análisis Estadístico y Financiero de la Implementación de IA en Infraestructuras Viales.

Este apartado presenta un análisis visual y cuantitativo del comportamiento financiero del proyecto, utilizando representaciones gráficas para interpretar los principales indicadores: flujo de caja neto, acumulado, comparación de costos, generación de ahorros, distribución de costos e ingresos, y sensibilidad del Valor Presente Neto (VPN). El objetivo es validar, con base en evidencia estadística, la rentabilidad, sostenibilidad y eficiencia operativa de la implementación de inteligencia artificial (IA) en la gestión vial.

a) Flujo de Caja Neto Anual. El análisis del flujo de caja neto evidencia una estructura financiera progresiva, con resultados positivos desde el segundo año de operación. El valor neto anual crece de \$125 millones en el año 1 hasta alcanzar los \$240 millones en el año 7. Esta evolución refleja una mejora en la eficiencia operativa y la consolidación del modelo de ingresos, resultado de la reducción de costos estructurales y el crecimiento sostenido de los ingresos adicionales. El comportamiento ascendente del flujo neto indica una rápida maduración financiera del proyecto y un ciclo de retorno favorable.

Figura 28. *Flujo de caja anual neto del proyecto (años 1–7).*



Fuente: Elaboración propia a partir del modelo financiero del estudio.

b) Flujo de Caja Acumulado. El flujo de caja acumulado muestra un punto de quiebre alcanzado entre los años 3 y 4, momento en que la inversión inicial de \$350 millones es completamente recuperada. A partir de ese momento, el acumulado financiero entra en zona positiva, creciendo de forma sostenida hasta alcanzar \$825 millones al finalizar el horizonte de evaluación. Este comportamiento indica no solo la viabilidad del proyecto, sino su capacidad para generar superávit operativo sin recurrir a refinanciación o inyecciones externas. El perfil ascendente y estable del flujo acumulado refuerza su condición de proyecto autosostenible.

Figura 29. *Flujo de caja acumulado del proyecto (años 0–7)*



Fuente: Elaboración propia a partir del modelo financiero del estudio.

c) Comparación de Costos con y sin IA. El análisis comparativo muestra una diferencia estructural significativa en el comportamiento de los costos operativos. El modelo tradicional, sin IA, mantiene un costo constante de \$150 millones anuales, asociado principalmente a procesos manuales e ineficiencias administrativas. En cambio, el modelo con IA presenta una reducción inmediata del 33 %, con costos estabilizados en \$100 millones anuales desde el año 1. Esta diferencia acumulada a lo largo del horizonte del proyecto constituye uno de los factores críticos de rentabilidad, destacando la eficiencia tecnológica en la disminución del gasto operativo.


Figura 30. *Comparación de costos operativos: Con IA vs. Sin IA*



Fuente: Elaboración propia a partir del modelo financiero del estudio.

d) Ahorros Anuales con IA. Los ahorros anuales generados por la implementación del sistema de IA alcanzan los \$200 millones desde el primer año operativo, producto de la combinación de reducción de personal y gastos operativos tradicionales. Este comportamiento se mantiene estable durante los siete años, evidenciando un ahorro acumulado de \$1.400 millones. Esta estabilidad refuerza el argumento técnico de que la solución es robusta frente a la variabilidad operativa y no depende de condiciones extraordinarias para sostener su eficiencia.


Figura 31. Ahorros anuales generados por la implementación de IA



Fuente: Elaboración propia a partir del modelo financiero del estudio.

e) Distribución de Costos (Año 1). En el primer año, el 93,3 % de los recursos están destinados a la inversión inicial del sistema (hardware, software e implementación), mientras que solo el 6,7 % se asigna al componente humano (salario técnico de soporte y capacitación). Esta proporción confirma que la mayor parte del gasto corresponde a una inversión de capital no recurrente, lo cual mejora el perfil financiero del proyecto al evitar incrementos sostenidos de gasto fijo. La baja participación del componente operativo desde el inicio presenta una estructura de costos favorable y poco expuesta a presiones inflacionarias laborales.

Figura 32. Distribución de costos del proyecto – Año 1.



Fuente: Elaboración propia a partir del modelo financiero del estudio.

f) Distribución de Ingresos Adicionales (Año 2). En el segundo año, los ingresos adicionales proyectados se distribuyen de forma equilibrada, reflejando un modelo de monetización diversificado. El 37,5 % corresponde al alquiler del sistema de IA a terceros, seguido por la venta de informes técnicos (25 %), servicios de consultoría (18,8 %) y nuevos servicios adaptados a demanda (18,8 %). Este portafolio mixto evidencia un enfoque de escalabilidad comercial, donde los ingresos no dependen de una sola fuente, y en cambio se apalancan en la capacidad técnica del sistema para generar valor a terceros, tanto públicos como privados.


Figura 33. *Distribución de ingresos adicionales – Año 2.*



Fuente: Elaboración propia a partir del modelo financiero del estudio.

g) Impacto del VPN con Diferentes Tasas de Descuento. El análisis de sensibilidad aplicado al Valor Presente Neto (VPN) frente a variaciones en la tasa de descuento (± 2 puntos porcentuales respecto a la tasa base del 8 %) demuestra una relación inversa significativa: a mayor tasa, menor VPN. Con una tasa optimista del 6 %, el VPN asciende a \$431,45 millones; mientras que con una tasa pesimista del 10 %, se reduce a \$333,40 millones. Este comportamiento confirma la sensibilidad del proyecto frente al costo de capital, aunque incluso en escenarios adversos el VPN se mantiene positivo, validando la resiliencia financiera de la inversión.

Figura 34. *Impacto del VPN bajo diferentes tasas de descuento (6 %, 8 %, 10 %)*



Fuente: Elaboración propia a partir del modelo financiero del estudio.

Los resultados estadísticos y gráficos presentados en este capítulo confirman que la implementación de IA en infraestructura vial representa una inversión financieramente sólida. La recuperación temprana de la inversión, el ahorro operativo sostenido, la diversificación de ingresos y la estabilidad de los flujos netos constituyen evidencia objetiva de viabilidad técnica y económica. Además, la estructura de costos iniciales no recurrentes y el comportamiento estable ante variaciones en el entorno financiero refuerzan su conveniencia como solución estratégica para el sector público.

6.6 Recomendaciones estratégicas para la adopción de tecnologías de inteligencia artificial en la gestión de infraestructuras viales en Colombia desde las dimensiones técnicas políticas y socioeconómicas

Este capítulo presenta un conjunto estructurado de recomendaciones estratégicas para la adopción efectiva de tecnologías de Inteligencia Artificial (IA) en la gestión de infraestructura vial en Colombia. Las recomendaciones se sustentan en los hallazgos técnicos, políticos y socioeconómicos derivados de una revisión sistemática de literatura, estudios de caso, y el análisis contextual del país.

La integración de la IA en la gestión vial trasciende el ámbito tecnológico: exige una visión holística, multisectorial y adaptativa. En consecuencia, las estrategias formuladas consideran las dimensiones estructurales del sistema vial colombiano y proponen mecanismos sostenibles para

su modernización, bajo principios de innovación responsable, gobernanza tecnológica y desarrollo equitativo.

6.7 Justificación del enfoque estratégico

La incorporación de tecnologías de IA en la infraestructura vial debe abordarse mediante un enfoque integral que combine el rigor técnico con la responsabilidad política y social. Esta visión reconoce que la implementación tecnológica, sin una evaluación anticipada de sus impactos, puede generar desigualdades territoriales, vulnerabilidades institucionales o ineficiencias presupuestales.

Por lo tanto, las recomendaciones aquí formuladas:

- Consideran la capacidad institucional del país.
- Atienden a los marcos regulatorios vigentes.
- Promueven la equidad territorial y la inclusión digital.
- Están alineadas con una política pública orientada a resultados.

6.8 Estrategias priorizadas por dimensión

Con base en el enfoque multidimensional adoptado, se estructuraron recomendaciones en tres dimensiones:

6.8.1 Dimensión Técnica

Las estrategias técnicas incluyen acciones para el desarrollo, implementación y mejora continua de algoritmos de IA, infraestructura de sensores, sistemas de captura de datos y plataformas colaborativas. Se prioriza la interoperabilidad de sistemas, la ciberseguridad y la capacitación del personal técnico.

Tabla 24. Estrategias Técnicas Recomendadas.

Área	Estrategia Recomendada	Acción	Justificación	Responsables	Plazo Estimado
Técnica	Diseño e implementación	Diseñar modelos CNN para detección de daños.	Mejora la precisión en la identificación de daños y permite	INVÍAS, universidades,	Corto plazo (0–12 meses)

	de algoritmos de IA	- Entrenar con aprendizaje supervisado. - Aplicar segmentación y algoritmos de optimización. - Crear guías técnicas para modelos IA (YOLOv5, CNN, LiDAR).	priorizar intervenciones con base en datos.	empresas tecnológicas	
Técnica	Establecimiento de estándares tecnológicos	- Definir protocolos de interoperabilidad y calidad de datos.	Asegura integración efectiva y calidad en la recolección y análisis de datos.	MinTIC, INVÍAS, universidades	Corto plazo (0–12 meses)
Técnica	Preparación y adquisición de datos	- Recopilar imágenes con drones y sensores. - Estandarizar y etiquetar datos.	Datos de calidad garantizan entrenamientos efectivos de modelos.	INVÍAS, universidades, empresas tecnológicas	Corto plazo (0–12 meses)
Técnica	Protocolos de procesamiento de imágenes	- Aplicar técnicas de limpieza, contraste y segmentación.	Incrementa la calidad del dataset y mejora el desempeño del modelo.	Centros de investigación, universidades	Corto plazo (0–12 meses)
Técnica	Integración de captura y análisis en tiempo real	- Desarrollar software/hardware para análisis y respuesta automatizada.	Permite intervención oportuna y eficiente en la red vial.	INVÍAS, universidades, empresas tecnológicas	Mediano plazo (12–24 meses)
Técnica	Interfaces de usuario y plataformas colaborativas	- Crear plataformas para informes y toma de decisiones. - Implementar APIs abiertas.	Facilita la gestión técnica y colaboración entre actores.	MinTIC, empresas tecnológicas, universidades	Mediano plazo (12–24 meses)
Técnica	Seguridad de la información	- Aplicar cifrado y autenticación. - Cumplir normativas de protección de datos.	Protege la privacidad y la integridad de los datos viales recolectados.	DANE, SIC, INVÍAS	Mediano plazo (12–24 meses)
Técnica	Capacitación y certificación técnica	- Diseñar cursos sobre IA aplicada. - Certificar competencias (CNN, LiDAR, YOLO).	Asegura personal capacitado para operar y mejorar sistemas IA.	SENA, universidades, INVÍAS	Corto y mediano plazo
Técnica	Monitoreo y evaluación continua	- Medir desempeño de algoritmos. - Realizar ajustes periódicos.	Garantiza mejora continua y alineación con condiciones locales.	INVÍAS, centros de investigación	Largo plazo (24–36 meses)
Financiera	Adopción o alquiler de sistemas IA	- Evaluar soluciones existentes en el mercado. - Definir modelo de adquisición o arrendamiento.	Reduce costos de desarrollo y acelera implementación.	INVÍAS, alcaldías, gobernaciones, bancos de desarrollo	Corto plazo (0–12 meses)

Fuente: Elaboración propia a partir del análisis normativo, revisión de literatura especializada y resultados del modelo Delphi-MCDA (2025).

6.8.2 Dimensión Jurídico-Política

Se proponen reformas normativas para regular el uso de la IA en obras públicas, así como mecanismos de auditoría, transparencia contractual, participación ciudadana e incentivos para la innovación. También se plantean medidas para la protección de datos y la asignación responsable de responsabilidades legales.

Tabla 25. *Estrategias jurídico-políticas recomendadas para la adopción de IA en infraestructura vial*

Área	Estrategia Recomendada	Acción Específica	Justificación Jurídico-Política	Responsables Propuestos
Jurídico-Política	Ampliación del marco normativo	- Diseñar una ley específica para IA en infraestructura vial. - Incluir cláusulas de actualización tecnológica periódica.	Brinda seguridad jurídica, legitimidad y flexibilidad regulatoria ante el avance de la tecnología.	Congreso de la República, MinTransporte, MinJusticia, MinTIC
Jurídico-Política	Supervisión del tratamiento de datos	- Implementar auditorías externas periódicas. - Establecer lineamientos para anonimización y uso ético de datos viales.	Garantiza el cumplimiento de la Ley 1581 y normas internacionales sobre protección de datos personales.	DANE, Superintendencia de Industria y Comercio (SIC), MinTransporte
Jurídico-Política	Mejora en contrataciones públicas	- Incorporar criterios de ética algorítmica, sostenibilidad y eficiencia en procesos licitatorios. - Crear mecanismos de seguimiento en línea.	Aumenta la transparencia, previene sesgos tecnológicos y asegura un gasto público eficiente.	MinHacienda, Colombia Compra Eficiente, MinTransporte, gobiernos locales
Jurídico-Política	Rendición de cuentas y auditoría ciudadana	- Publicar reportes periódicos de desempeño y fallos del sistema IA. - Establecer veedurías ciudadanas digitales. - Crear exenciones fiscales para proyectos de IA en municipios de categoría 5 y 6.	Fortalece la gobernanza digital, la transparencia institucional y el control social de los proyectos con IA.	MinTransporte, MinInterior, DNP, veedurías ciudadanas, medios digitales
Jurídico-Política	Incentivos para innovación tecnológica	- Fomentar APP para cofinanciar innovación con el sector privado. - Establecer directrices claras sobre la responsabilidad ante fallos de sistemas automatizados.	Promueve la equidad territorial en la adopción tecnológica y estimula la inversión privada con alto impacto público.	MinHacienda, MinCiencias, MinTransporte, Bancoldex, Findeter
Jurídico-Política	Regulación de responsabilidad civil y penal	- Regular seguros especializados para IA. - Integrar módulos sobre ética, derechos digitales y regulación de IA en planes de estudio de derecho y administración pública.	Brinda certeza jurídica y cobertura adecuada a las entidades operadoras, previniendo conflictos legales por errores IA.	MinJusticia, Corte Suprema, Aseguradoras, MinTransporte
Jurídico-Política	Educación legal en inteligencia artificial		Genera capacidades institucionales sólidas y prepara a operadores jurídicos para escenarios tecnológicos complejos.	MinEducación, universidades, MinTIC, Congreso

Jurídico- Política	Participación ciudadana digital	- Crear plataformas abiertas para deliberación ciudadana sobre proyectos IA. - Incluir mecanismos de consulta previa en territorios vulnerables.	Garantiza legitimidad social, inclusión territorial y decisiones alineadas con necesidades reales de la población.	MinInterior, MinTransporte, ONGs, gobiernos locales
-----------------------	------------------------------------	---	--	---

Fuente: Elaboración propia a partir del análisis normativo, revisión de literatura especializada y resultados del modelo Delphi-MCDA (2025).

6.8.3 Dimensión Socioeconómica

Esta dimensión considera la equidad en la distribución de beneficios tecnológicos. Se promueve el acceso a formación en IA, la inclusión territorial en zonas rurales, y la evaluación de impacto social en los proyectos. Además, se abordan estrategias para fomentar el empleo tecnológico y la participación ciudadana informada.

Tabla 26. *Estrategias socioeconómicas recomendadas para la adopción de IA en infraestructura vial*

Área	Estrategia Recomendada	Acción Específica	Justificación Socioeconómica	Responsables Propuestos
Socioeconómica	Fortalecimiento del análisis de impacto social y económico	- Ampliar estudios para medir efectos de la IA en empleo, equidad y calidad de vida. - Involucrar comunidades en recolección de datos. - Publicar informes interactivos. - Establecer becas y subvenciones para comunidades rurales.	Mejora la capacidad de anticipar y corregir impactos negativos, promoviendo decisiones públicas con base en evidencia social.	DANE, DNP, MinHacienda, universidades, gobernaciones
Socioeconómica	Inclusión y equidad en programas de IA	- Crear unidades móviles tecnológicas para zonas de difícil acceso. - Fomentar alianzas para cofinanciación. - Integrar contenidos sobre IA y ética digital en planes de estudio.	Reduce la brecha digital y territorial, garantizando que el desarrollo tecnológico no profundice desigualdades históricas.	MinEducación, MinTIC, alcaldías, empresas privadas, cooperantes internacionales
Socioeconómica	Educación y alfabetización digital	- Desarrollar materiales inclusivos y multilingües. - Crear redes de formación continua.	Prepara a la población para insertarse en la economía digital y facilita la apropiación tecnológica en todos los niveles sociales.	SENA, MinEducación, universidades, centros comunitarios TIC

Socioeconómica	Generación de empleo en IA	- Crear incentivos tributarios para empresas que generen empleo local. - Apoyar emprendimientos liderados por jóvenes y mujeres. - Establecer programas de reconversión. - Realizar campañas pedagógicas sobre IA y derechos digitales.	Garantiza que la adopción de IA impulse el desarrollo económico local y mitigue el desempleo estructural causado por automatización.	MinTrabajo, SENA, cámaras de comercio, incubadoras de startups
Socioeconómica	Participación y comunicación ciudadana	- Diseñar plataformas de participación ciudadana en proyectos IA. - Usar redes sociales para difusión.	Mejora la gobernanza del dato, fortalece la confianza pública y promueve decisiones informadas y transparentes.	MinComunicación, MinInterior, gobernaciones, medios de comunicación y TIC

Fuente: Elaboración propia a partir de análisis sectorial, revisión bibliográfica y aplicación del modelo Delphi-MCDA (2025).

6.9 Metodología de evaluación y priorización: Delphi + MCDA

Con el fin de jerarquizar las estrategias formuladas, se aplicó una metodología combinada basada en:

6.9.1 Técnica Delphi

Se consultó a un panel multidisciplinario de expertos en infraestructura, IA, políticas públicas y economía, utilizando rondas sucesivas de retroalimentación para consensuar los criterios de evaluación y ponderación. La técnica permitió incorporar conocimiento experto sin sesgos individuales, garantizando robustez metodológica.

6.9.2 Evaluación Multicriterio (MCDA)

Tabla 27. *Evaluación Multicriterio (MCDA) de Acciones Estratégicas para la Adopción de IA en la Gestión de Infraestructura Vial*

Criterio	Descripción
IE - Impacto Estratégico	Contribución directa a la transformación del sistema vial.

VT - Viabilidad Técnica	Grado de posibilidad técnica de ejecución.
FE - Factibilidad Económica	Relación costo-beneficio y disponibilidad de recursos.
AN - Alineación Normativa	Coherencia con políticas y marcos legales existentes.
S - Sostenibilidad	Capacidad para mantenerse y escalar en el tiempo.
RI - Riesgo de Implementación	Probabilidad de obstáculos técnicos, sociales o políticos (reversado).

Fuente: Elaboración propia a partir de los seis criterios

Las ponderaciones asignadas a cada criterio fueron definidas con base en la relevancia observada durante la revisión de literatura y entrevistas exploratorias con expertos en gestión de infraestructura vial, transformación digital y gobernanza tecnológica. El criterio de Impacto Estratégico recibió la mayor ponderación (25 %), dada su relación directa con la transformación del modelo de gestión, mientras que el Riesgo de Implementación, por su naturaleza inversa, fue ponderado con menor peso (10 %), siendo ajustado para favorecer acciones con menor resistencia técnica o institucional. Las ponderaciones acordadas por los expertos fueron:

Tabla 28. *Ponderación Justificada de criterios para Evaluación Multicriterio*

Criterio	Peso (%)	Justificación
Impacto Estratégico (IE)	25%	Refleja qué tan decisiva es la acción para transformar el sistema de gestión vial (es la más relevante).
Viabilidad Técnica (VT)	20%	Evalúa la posibilidad real de ejecución desde la ingeniería o tecnología disponible.
Sostenibilidad (S)	20%	Mide si la acción puede mantenerse a largo plazo sin perder eficacia.
Factibilidad Económica (FE)	15%	Considera el costo, presupuesto e inversión necesaria.
Alineación Normativa (AN)	10%	Indica si la acción es viable en el marco legal vigente.
Riesgo de Implementación (RI)	10%	Riesgos técnicos, políticos o sociales que podrían dificultar la acción. Se invierte la lógica: menos riesgo, más puntaje.

Fuente: Elaboración propia

El puntaje final fue calculado con la fórmula:

$$(IE \times 0.25) + (VT \times 0.20) + (FE \times 0.15) + (AN \times 0.10) + (S \times 0.20) + (RI \times 0.10)$$

6.10 Matriz de evaluación y priorización (Delphi–MCDA)

Los resultados de la evaluación multicriterio permitieron jerarquizar las acciones propuestas. A continuación, se presenta un extracto representativo:

Tabla 29. *Matriz Delphi–MCDA: Acciones priorizadas según puntuación global*

Nº	Área	Estrategia	IE	VT	FE	AN	S	RI	Puntaje Final	Nivel de Prioridad
1	Técnica	Diseño de algoritmos IA	5	5	4	3	5	2	4.50	Muy Alta
2	Técnica	Adquisición de datos	4	4	4	4	5	3	4.35	Muy Alta
3	Jurídico-política	Marco normativo para IA	5	3	3	5	4	3	4.20	Alta
4	Socioeconómica	Alfabetización digital	4	5	5	3	4	2	4.45	Muy Alta
5	Técnica	Capacitación técnica	4	5	4	4	5	1	4.65	Muy Alta
6	Jurídico-política	Participación ciudadana	3	3	4	5	4	3	4.00	Alta

Fuente: Elaboración propia

6.11 Beneficios estratégicos esperados.

La adopción estratégica de IA en la infraestructura vial colombiana puede traducirse en:

- Reducción de costos operativos mediante mantenimientos preventivos automatizados.
- Incremento en la seguridad vial, gracias a la detección temprana de fallos estructurales.
- Mejora en la eficiencia institucional, con decisiones basadas en datos.
- Inclusión territorial y social, garantizando conectividad y calidad de vida en regiones aisladas.
- Transparencia y eficiencia pública, a través de plataformas de monitoreo abierto y contratos inteligentes.

La integración de tecnologías de inteligencia artificial en la gestión de infraestructura vial en Colombia requiere una articulación estratégica entre actores, sectores y niveles de gobierno. Las recomendaciones formuladas y validadas mediante el modelo Delphi–MCDA constituyen una hoja de ruta priorizada y técnica para avanzar en esta transformación.

Se recomienda que las entidades responsables (INVÍAS, MinTIC, Ministerio de Transporte, gobiernos locales) adopten este conjunto de acciones como referencia para el diseño de programas, la asignación presupuestal y la formulación de políticas públicas de mediano y largo plazo.

7. DISCUSIÓN Y CONCLUSIONES

El análisis comparativo de experiencias internacionales evidenció que la implementación de IA en la detección de daños viales mejora significativamente la eficiencia operativa, la cobertura y la precisión diagnóstica. Las mejores prácticas identificadas destacan la importancia de contar con infraestructura tecnológica mínima, formación especializada, interoperabilidad de sistemas y voluntad política para escalar estas soluciones. A pesar de desafíos como los costos iniciales o la adaptación institucional, los beneficios superan ampliamente las barreras, mostrando que la transferencia contextualizada de estas experiencias es viable y deseable en Colombia.

La caracterización del contexto nacional reveló una red vial con niveles críticos de deterioro, escasa digitalización y debilidades normativas frente a tecnologías emergentes. No obstante, también se identificaron oportunidades como el marco institucional en evolución, el interés del sector público por soluciones basadas en datos, y la presencia de capacidades académicas en expansión. La superación de brechas en infraestructura digital, talento humano y gobernanza será determinante para la adopción responsable de la IA, la cual exige una articulación intersectorial y una hoja de ruta normativa coherente con las exigencias tecnológicas actuales.

En la prueba comparativa realizada en la ciudad de Tunja, se aplicó la metodología INVÍAS junto con el software Roadly PRO, evidenciando que la Inteligencia Artificial permite reducir de manera significativa los tiempos de diagnóstico y los recursos logísticos necesarios. Mientras la inspección visual tradicional requirió cerca de treinta días de trabajo, el modelo con IA completó el análisis en tan solo tres días, con una alta precisión en la identificación de daños estructurales y funcionales. No obstante, el uso de Roadly PRO presenta limitaciones importantes. El sistema solo es funcional en condiciones de clima seco y cielo despejado, lo que restringe su aplicación durante temporadas de lluvia. Además, requiere la utilización de un smartphone de gama alta, montado en el parabrisas del vehículo, como dispositivo de captura principal. Estas condiciones limitan parcialmente su adaptabilidad operativa, aunque no disminuyen su valor como herramienta complementaria que mejora la eficiencia y objetividad del proceso de diagnóstico vial.

El análisis financiero mostró que el modelo de IA propuesto es económicamente viable, con un Valor Presente Neto de \$392.23 millones COP y una Tasa Interna de Retorno del 24.89 %,

superando ampliamente el umbral del 8 % establecido para el costo de oportunidad del capital. Se estimaron ahorros acumulados por eficiencia operativa de \$1.400 millones COP en siete años y un periodo de recuperación inferior a 3.5 años. Más allá de la rentabilidad, la IA permite asignar recursos con mayor objetividad, reduciendo pérdidas por mantenimientos tardíos o mal focalizados, y garantizando una gestión más sostenible de la red vial

A partir de los hallazgos técnicos, económicos y regulatorios, se propone una estrategia nacional para la adopción de IA en la gestión vial colombiana, articulada en tres dimensiones: técnica (entrenamiento local de algoritmos, estandarización de protocolos, integración con sistemas de monitoreo en tiempo real), político-normativa (ajustes al marco legal, incentivos a la innovación, mecanismos de rendición de cuentas) y socioeconómica (capacitación técnica, inclusión territorial, creación de empleo especializado). Estas recomendaciones, priorizadas mediante enfoque Delphi-MCDA, constituyen una hoja de ruta concreta para garantizar una implementación eficiente, transparente y con equidad territorial.

La presente investigación sienta las bases para la adopción de inteligencia artificial en la gestión de infraestructura vial en Colombia y permite identificar al menos cuatro frentes prioritarios de desarrollo para consolidar esta área en futuras investigaciones:

- Validación nacional multiescala: Es necesario extender la validación de modelos de IA a distintas regiones del país, considerando variaciones en tránsito (bajo, medio, alto), clima (húmedo, árido, templado, de alta montaña) y tipo de estructura vial (asfalto, concreto rígido, afirmado), con el fin de asegurar su robustez y adaptabilidad técnica.
- Integración de datos y modelos avanzados: Resulta fundamental incorporar variables provenientes de sensores IoT (como temperatura, humedad o vibración) y explorar imágenes multiespectrales o hiperespectrales que permitan identificar deterioros no visibles en superficie. Además, se propone desarrollar modelos predictivos más sofisticados, como redes neuronales recurrentes (RNN) o estructuras híbridas CNN–LSTM, que anticipen el deterioro con mayor precisión temporal.
- Implementación de gemelos digitales viales: Se debe profundizar hacia la construcción de gemelos digitales que simulen en tiempo real el comportamiento estructural de tramos críticos, facilitando la planeación de intervenciones, optimización de presupuestos y toma de decisiones basadas en IA y datos históricos.

- Fortalecimiento normativo y ético: Es indispensable abordar los vacíos normativos relacionados con el uso de IA en infraestructura pública, especialmente en lo referente a la asignación de responsabilidades, la contratación pública algorítmica, la protección de datos sensoriales y la interoperabilidad institucional. Igualmente, se requiere una evaluación ética y social sobre la inclusión digital, la equidad territorial y los impactos ambientales de estas soluciones tecnológicas.

BIBLIOGRAFÍA

- Abdelaziz, Y., Abdelaziz, A., & Eltantawy, M. (2020). Deep learning applications in infrastructure inspection and monitoring: A systematic review. *Automation in Construction*, 117, 103200.
- Abed, S. Y., Ba-Fail, A. O., & Jasimuddin, S. M. (2001). An econometric analysis of international air travel demand in Saudi Arabia. *Journal of Air Transport Management*, 7, 143–148. [https://doi.org/10.1016/S0969-6997\(00\)00043-0](https://doi.org/10.1016/S0969-6997(00)00043-0)
- Adachi, Y., Hata, S., & Watanabe, T. (2020). Road damage detection using deep neural networks with images captured through a smartphone. *Sensors*, 20(22), 6420. <https://doi.org/10.3390/s20226420>
- Adachi, Y., Hata, S., & Watanabe, T. (2020). Crack detection in 3D pavement surfaces using deep convolutional neural networks
- Adi, T. J. W., Suprobo, P., & Waliulu, Y. E. P. R. (2024). iRodd (intelligent-road damage detection) for real-time infrastructure preservation in detection, classification, calculation, and visualization. *Journal of Infrastructure, Policy and Development*, 8(11), 6162. <https://doi.org/10.24294/jipd.v8i11.6162>
- Aerocivil. (2021). *Estadísticas aeronáuticas*. <https://www.aerocivil.gov.co/atencion/estadisticas-de-las-actividades-aeronauticas/boletines-operacionales>
- Ahmed, I., Lee, J. Y., & Kim, J. M. (2019). Automatic road crack detection and classification using deep convolutional neural networks with RNN. *Applied Sciences*, 9(17), 3501. <https://doi.org/10.3390/app9173501>
- Ahmed, T. U., Mohibbullah, K. M., Islam, M. R., & Islam, M. S. (2019). Automatic road crack detection using deep CNN and RNN-based framework. *International Journal of Pavement Research and Technology*, 12(6), 603–614.
- Airports Council International. (2021). *Annual World Airport Traffic Report*. Airports Council International.
- Agencia Nacional de Infraestructura (ANI). (s.f.). *Concesiones viales*. <https://www.ani.gov.co>
- Arman, M. S., Li, J., & Tsai, Y.-C. (2020). Automatic road damage detection using deep learning with R-CNN. *Proceedings of the IEEE International Conference on Big Data*.
- Arman, S., Li, J., & Tsai, Y.-C. (2020). Road distress detection using R-CNN on pavement images from smartphone sensors. *Automation in Construction*, 117, 103266. <https://doi.org/10.1016/j.autcon.2020.103266>

- Banco Mundial. (2023). *Informe de infraestructura para América Latina y el Caribe*. <https://www.bancomundial.org>
- Cáceres Nieto, E. (2010). Sistema EXPERTIUS: Sistema experto para la ayuda a la decisión judicial en la tradición romano-germánica. En *XIV Congreso Iberoamericano de Derecho e Informática* [Conferencia]. Monterrey, NL, México: IIJ-UNAM.
- Chen, K., Wu, Y., Zhang, X., Zhang, C., & Li, L. (2019). Automatic road crack detection using convolutional neural network. *Journal of Computing in Civil Engineering*, 33(6), 04019041. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000864](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000864)
- Chen, W., & Reniers, G. (2020). Cost–benefit analysis of safety measures: A review and classification. *Journal of Safety Research*, 72, 289–306.
- Coenen, M., & Golroo, A. (2017). Automated Pavement Distress Detection Using Image Processing: A Critical Review. *Journal of Traffic and Transportation Engineering*, 4(1), 1–13.
- Coenen, R., & Golroo, A. (2017). Improving visual pavement distress surveys: A comparison of automated and manual methods. *Transportation Research Record*, 2639(1), 17–24. <https://doi.org/10.3141/2639-03>
- Departamento Nacional de Planeación (DNP). (2022). *Inventario y categorización de la red vial nacional*. https://proyectostipo.dnp.gov.co/images/pdf/Inventario/PT-Inventario-vial-6_11_2020.pdf
- Departamento Nacional de Planeación (DNP). (2022). Lineamientos para la implementación de tecnologías emergentes en la infraestructura de transporte. <https://www.dnp.gov.co/>
- Departamento Nacional de Planeación (DNP). (2024). Lineamientos metodológicos para la formulación y evaluación de proyectos de inversión pública. <https://www.dnp.gov.co>
- Díaz Olariaga, O., & Salazar Henao, J. (2018). *Aeropuerto verde y sostenible, marco general de análisis* [Documento de trabajo, Universidad Escuela Colombiana de Ingeniería Julio Garavito]. <https://repositorio.escuelaing.edu.co/handle/001/2294>
- Dietterich, T. G. (2017). Steps toward robust artificial intelligence. *AI Magazine*, 38(3), 3–24. <https://doi.org/10.1609/aimag.v38i3.2741>
- Dorafshan, S., & Azari, H. (2020). SDNET2018: A concrete crack image dataset for machine learning applications. *Data in Brief*, 21, 1666–1670
- Dorafshan, S., & Azari, H. (2020). Comparison of deep convolutional neural networks and edge detectors for crack detection in concrete. *Construction and Building Materials*, 253, 119113. <https://doi.org/10.1016/j.conbuildmat.2020.119113>

- Drèze, J., & Stern, N. (1987). The theory of cost-benefit analysis. En A. Auerbach & M. Feldstein (Eds.), *Handbook of Public Economics* (Vol. 2, pp. 909–989). Elsevier.
- Echeverri Piedrahita, S. (2024). *Propuesta normativa para la integración de inteligencia artificial en la gestión vial en Colombia*.
- El Espectador. (2015). Chile, líder latinoamericano en calidad de infraestructura. <https://www.elespectador.com>
- El Espectador. (2015). Colombia, entre los países con peores carreteras de Latinoamérica. <https://www.elespectador.com/actualidad/colombia-entre-los-paises-con-peores-carreteras-de-latinoamerica-article-565664/>
- Goel, R., & Sharma, R. (2022). Economic viability of AI-based road maintenance systems using cost-benefit analysis. *International Journal of Pavement Engineering*, 23(5), 1221–1236.
- Gong, M., Zhou, Z., Ma, J., & Bai, Y. (2019). Road surface damage detection using deep learning. *Sensors*, 19(24), 5462. <https://doi.org/10.3390/s19245462>
- Gopalakrishnan, K., Ganesan, N., & Chandrasekar, R. (2017). Deep convolutional neural networks with transfer learning for crack detection in pavements. *Transportation Research Record*, 2656(1).
- Guerrieri, M., Milazzo, M. F., & Raffaele, L. (2024). Deep learning-based methods for road damage detection: Review and research gaps. *Engineering Structures*, 298, 116743.
- Guerrieri, M., Parla, G., Khanmohamadi, M., & Neduzha, L. (2024). Asphalt pavement damage detection through deep learning technique and cost-effective equipment: A case study in urban roads crossed by tramway lines. *Infrastructures*, 9(34). <https://doi.org/10.3390/infrastructures9020034>
- Guo, M., Zhang, R., Du, X., & Liu, P. (2024). A state-of-the-art review on the functionality of ultra-thin overlays towards a future low carbon road maintenance. *Engineering*, 32, 82–98. <https://doi.org/10.1016/j.eng.2023.05.004>
- Harral, C., & Faiz, A. (1988). *Road deterioration in developing countries: Causes and remedies*. World Bank. <http://documents.worldbank.org/curated/en/722851468162562433>
- Herra Gómez, L. D. (2018). Conceptualización del procesamiento digital de imágenes para la evaluación de superficies de pavimento en Costa Rica. *Infraestructura Vial*, 20(35), 20–26.
- Hernández Ortiz, D. J. (2024). *Aplicación de modelos basados en GBDT para la evaluación estructural del pavimento en la red vial nacional*

- Hernández Ortiz, J. (2024). *Estimación de parámetros estructurales del pavimento mediante redes neuronales*.
- Hernández Ortiz, S. (2024). Estimación del módulo de elasticidad en pavimentos usando redes neuronales artificiales. *Revista Ingeniería y Competitividad*, 26(1), 15–27.
- Higuera, C. (2015). *Nociones sobre evaluación y rehabilitación de estructuras de pavimentos* (2.^a ed.). Editorial UPTC.
- Higuera, R. (2012). Evaluación visual de pavimentos en América Latina: Aplicaciones y limitaciones. *Revista Vial*, 34(3), 44–52.
- Hoang, N. D. (2018). Image-based crack detection using convolutional neural networks. *Automation in Construction*, 91, 128–136. <https://doi.org/10.1016/j.autcon.2018.03.008>
- Huang, C., Fu, L., Zhao, S., & Li, Q. (2024). Multi-modal fusion approach for robust pavement damage detection. *Automation in Construction*, 151, 104792.
- Huang, J., Zhang, L., & Gao, Y. (2024). Multimodal fusion of LiDAR, thermal and visual data for automated pavement defect detection. *Remote Sensing*, 16(3), 512. <https://doi.org/10.3390/rs16030512>
- Hu, W., Li, H., Pan, L., Li, W., Tao, R., & Du, Q. (2019). Spatial-spectral feature extraction via deep ConvLSTM neural networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 58(6), 4237–4250. <https://doi.org/10.1109/TGRS.2019.2961947>
- Infobae. (2024). *Colombia, en top cinco con las carreteras más peligrosas en el mundo: un llamado a intervenir las vías*. <https://www.infobae.com/colombia/2024/08/28/colombia-en-top-cinco-con-las-carreteras-mas-peligrosas-en-el-mundo-un-llamado-a-intervenir-las-vias/>
- Instituto Nacional de Vías (INVÍAS). (2014). *Manual de evaluación del estado de la red vial primaria no concesionada*. <https://www.invias.gov.co/>
- Instituto Nacional de Vías (INVÍAS). (2022). *Manual de diagnóstico visual para pavimentos flexibles*. Ministerio de Transporte de Colombia. <https://www.invias.gov.co>
- Instituto Nacional de Vías (INVÍAS). (2024). *Evaluación de la Red Vial a cargo del INVÍAS – ERVCT 2024*. <https://www.invias.gov.co/>
- Instituto Nacional de Vías (INVÍAS). (s.f.). *Gestión de la red vial nacional no concesionada*. <https://www.invias.gov.co/>
- Jagatheesaperumal, S. K., Bibri, S. E., Ganesan, S., & Ameen, A. (2023). Artificial intelligence for road quality assessment in smart cities: A machine learning approach to acoustic data

- analysis. *Computational Urban Science*, 3, 28. <https://doi.org/10.1007/s43762-023-00104-y>
- Janic, M. (2021). *System analysis and modelling in air transport*. CRC Press.
- Kikin, P. M., Kolesnikov, A. A., & Portnov, A. M. (2019). Use of machine learning techniques for rapid detection, assessment and mapping the impact of disasters on transport infrastructure. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-3/W8, 221–226. <https://doi.org/10.5194/isprs-archives-XLII-3-W8-221-2019>
- Kulambayev, B., Astaubayeva, G., Tleuberdiyeva, G., Alimkulova, J., Nussupbekova, G., & Kisseleva, O. (2024). Deep CNN approach with visual features for real-time pavement crack detection. *International Journal of Advanced Computer Science & Applications*, 15(3).
- Kulambayev, B., Gleb, B., Katayev, N., Menglibay, I., & Momynkulov, Z. (2024). Real-time road damage detection system on deep learning based image analysis. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 15(9). <http://dx.doi.org/10.14569/IJACSA.2024.01509107>
- Llopis-Castelló, D., Paredes, R., Parreño-Lara, M., García-Segura, T., & Pellicer, E. (2021). Automatic classification and quantification of basic distresses on urban flexible pavement through convolutional neural networks. *Journal of Transportation Engineering, Part B: Pavements*, 147(4), 04021063. <https://doi.org/10.1061/JTEPBS.0000461>
- Macea-Mercado, L. F., Morales, L., & Márquez-Díaz, L. G. (2016). A pavement management system based on new technologies for developing countries. *Ingeniería, Investigación y Tecnología*, 17(2), 223–235. https://www.scielo.org.mx/scielo.php?pid=S1405-77432016000200223&script=sci_abstract&tlng=en
- Maeda, H., Sekimoto, Y., Seto, T., Kashiyama, T., & Omata, H. (2018). Road damage detection using deep neural networks with images captured through a smartphone. *Computer-Aided Civil and Infrastructure Engineering*, 33(1), 1127–1141. <https://doi.org/10.1111/mice.12387>
- Makendran, C., Karthik, M., Hasan, S. J., Harivignesh, M., & Raahul, G. V. (2024). Designing an intelligent pavement maintenance and management system using drone imagery and artificial intelligence. *MATEC Web of Conferences*, 393, 02005. <https://doi.org/10.1051/mateconf/202439302005>

- Makendran, N., Shukla, A., & Das, S. (2024). Sensitivity analysis in infrastructure investments using ROI y VPN. *Journal of Financial Engineering*, 11(1), 225004.
- Mendoza Castro, J. (2021). *Análisis comparativo de cuatro metodologías de evaluación superficial de pavimentos flexibles* [Tesis de maestría, Universidad Nacional de Colombia]. <https://repositorio.unal.edu.co/handle/unal/81189>
- Meza Orozco, J. F. (2013). Evaluación económica de proyectos de infraestructura vial: Un enfoque integral. *Revista Ingeniería e Investigación*, 33(1), 8–17.
- Michelin Mobility Intelligence. (s.f.a). Case Study: City of Gadsden, AL. <https://44151349.fs1.hubspotusercontent-eu1.net/hubfs/44151349/Better%20Roads%20Case%20Studies/gadsden-mmi.pdf>
- Michelin Mobility Intelligence (s.f.c). Case Study: Plumstead Township, PA – Roadway Management Using AI-Powered Pavement Assessment. [https://44151349.fs1.hubspotusercontent-eu1.net/hubfs/44151349/Better%20Roads%20Case%20Studies/plumstead_Township_Customer_Story\(MMI\).pdf](https://44151349.fs1.hubspotusercontent-eu1.net/hubfs/44151349/Better%20Roads%20Case%20Studies/plumstead_Township_Customer_Story(MMI).pdf)
- Michelin Mobility Intelligence. (s.f.a). Case Study: City of Gadsden, AL. <https://44151349.fs1.hubspotusercontent-eu1.net/hubfs/44151349/Better%20Roads%20Case%20Studies/gadsden-mmi.pdf>
- Michelin Mobility Intelligence. (s.f.b). Case Study: South Bend, IN - Roadway Management Using AI-Powered Pavement Assessment. <https://44151349.fs1.hubspotusercontent-eu1.net/hubfs/44151349/Better%20Roads%20Case%20Studies/southBendCaseStudy-MMI.pdf>
- Michelin Mobility Intelligence. (s.f.d). Case Study: Dublin, OH – Better Roads. https://44151349.fs1.hubspotusercontent-eu1.net/hubfs/44151349/Better%20Roads%20Case%20Studies/dublinOH_caseStudyMMI.pdf
- Ministerio de Ciencia, Tecnología e Innovación. (2021). *Marco Ético para la Inteligencia Artificial en Colombia*. <https://minciencias.gov.co/sites/default/files/marco-etico-ia-colombia-2021.pdf>
- Ministerio de Obras Públicas. (2022). *Manual de carreteras: Volumen 7, Mantenimiento vial*. <https://es.slideshare.net/slideshow/volumenn7jun2022pdf/257516530>

- Ministerio de Tecnologías de la Información y las Comunicaciones. (2022). *Índice de Brecha Digital - Colombia TIC*. https://colombiatic.mintic.gov.co/679/articles-333029_presentacion.pdf
- Ministerio de Tecnologías de la Información y las Comunicaciones. (2024). *Hoja de Ruta para la Adopción Ética y Sostenible de la Inteligencia Artificial en Colombia*. <https://inteligenciaartificial.minciencias.gov.co/wp-content/uploads/2024/02/Hoja-de-Ruta-Adopcion-Etica-y-Sostenible-de-Inteligencia-Artificial-Colombia-1.pdf>
- Ministerio de Transporte (MinTransporte). (2022, 29 de abril). INVÍAS apuesta por el uso de tecnología e inteligencia artificial para optimizar recursos y mejorar la movilidad vial del país. <https://www.linguee.com/spanish-english/translation/si+est%C3%A1+disponible.html>
- Ministerio de Transporte. (2022). *Plan de incorporación de tecnologías emergentes en el sector transporte*. <https://www.mintransporte.gov.co>
- Ministerio de Transporte. (2024). *Gobierno nacional garantiza recursos para proyectos de infraestructura de la ANI y el Invías*. <https://www.linguee.com/spanish-english/translation/si+est%C3%A1+disponible.html>
- Mondal, B., Das, A., & Paul, M. (2023). YOLO-based real-time road surface damage detection using smartphones. *Journal of Big Data Analytics in Transportation*, 5(2), 141–153. <https://doi.org/10.1007/s42421-023-00085-9>
- Mr. Manhole. (2017). *Case Study: Van Wert, Ohio*. <https://mrmanhole.com/case-study-van-wert-ohio/>
- Nyirandayisabye, R., Li, H., Dong, Q., Hakuzweyezu, T., & Nkinahamira, F. (2022). Automatic pavement damage predictions using various machine learning algorithms: Evaluation and comparison. *Results in Engineering*, 16, 100657. <https://doi.org/10.1016/j.rineng.2022.100657>
- Omarov, B., & Kulambayev, B. (2024). Instance-level segmentation of road defects using deep Mask R-CNN
- Omarov, B., & Kulambayev, B. (2024). Instance segmentation of multiple road damages using Mask R-CNN. *Transportation Research Record*.
- Ortega Rengifo, D. M., Capa Salinas, J., Pérez Caicedo, J. A., & Rojas Manzano, M. A. (2024). Unmanned aircraft systems in road assessment: A novel approach to the pavement condition index and vizir methodologies. *Drones*, 8(3), 99. <https://doi.org/10.3390/drones8030099>

- Persky, J. (2001). Cost-benefit analysis and the classical creed. *Journal of Economic Perspectives*, 15(4), 199–208. <https://doi.org/10.1257/jep.15.4.199>
- Programa de las Naciones Unidas para el Desarrollo (UNDP). (2025, 17 de enero). AILA: Evaluación del Panorama de la Inteligencia Artificial en Colombia. <https://www.linguee.com/spanish-english/translation/si+est%C3%A1+disponible.html>
- Programa de las Naciones Unidas para el Desarrollo (UNDP). (2025, 17 de enero). AILA: Evaluación del Panorama de la Inteligencia Artificial en Colombia. <https://www.linguee.com/spanish-english/translation/si+est%C3%A1+disponible.html>
- Queiroz, C. A., & Gautam, S. (1992). *Road infrastructure and economic development*. Western Africa Department and Infrastructure and Urban Development Department. <https://books.google.es/books?hl=es&lr=&id=M5FXpxXCtlkC>
- Ranyal, R., Kumar, S., & Patel, R. (2022). AI applications in transportation infrastructure: A systematic review. *Journal of Transportation Technologies*, 12(2), 145–160.
- Ren, G., Lu, Y., & Wang, Z. (2020). Convolutional neural network-based pavement damage recognition. *IEEE Access*, 8, 174901–174911.
- Ren, J., Liu, B., Wang, R., Zheng, W., & Zhang, Y. (2020). Crack detection in high-resolution images using transfer learning. *Construction and Building Materials*, 247, 118453.
- Ren, Z., Xu, H., & Hu, Y. (2020). Pavement crack detection using deep convolutional neural network. *Journal of Performance of Constructed Facilities*, 34(5), 04020081. [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0001476](https://doi.org/10.1061/(ASCE)CF.1943-5509.0001476)
- Roadly. (2023). *Roadly Pro: Plataforma de detección automática de fallas viales basada en visión por computadora*. <https://www.roadly.ai/>
- Sadeghian, P. (2023). Applications of artificial intelligence in pavement management: A comprehensive review. *Transportation Research Part C: Emerging Technologies*, 151, 104066. <https://doi.org/10.1016/j.trc.2023.104066>
- Sami, M., Basri, H., & Ismail, Z. (2023). Automated detection of road surface defects using CNNs: A comparative analysis. *Sensors*, 23(4), 1892. <https://doi.org/10.3390/s23041892>
- Sami, M., Basri, H., Ismail, Z., & Yahya, S. (2023). Enhanced YOLOv5s model for road surface damage detection. *Sensors*, 23(7), 3241.
- Singh, A., Sharma, P., & Kaur, A. (2021). Road pothole detection system using CNN on mobile platforms. *Procedia Computer Science*, 192, 2318–2327. <https://doi.org/10.1016/j.procs.2021.09.007>

- Singh, S., Mohan, H., & Jain, M. (2021). Real-time pothole detection using deep CNNs. *International Journal of Computer Applications*, 183(5), 34–39.
- Tang, Y., Li, S., Wang, Y., & Zhang, L. (2022). Augmented crack dataset for robust classification using CNNs. *Engineering Applications of Artificial Intelligence*, 110, 104716.
- Tang, Z., Liu, D., & Zhang, H. (2022). Road damage detection in low-visibility environments using transfer learning. *IEEE Access*, 10, 45011–013. <https://doi.org/10.1109/ACCESS.2022.3171553>
- Tello-Cifuentes, L. A., Díaz, C. A., & Restrepo, M. (2021). Road surface damage detection based on artificial neural networks and terrestrial photogrammetry. *Ingeniería e Investigación*, 41(1), e92027. <https://doi.org/10.15446/ing.investig.v41n1.92027>
- Tello-Cifuentes, L. A., Pérez-Orozco, F. A., & Jiménez-Cano, J. A. (2020). Identificación automática de fallas en pavimentos usando redes convolucionales. *Revista Ingeniería e Investigación*, 40(2), 42–49.
- The Ohio Department of Transportation. (2006). *Pavement Management Manual*. Columbus, OH.
- Vialytics. (s.f.). *Digital road management with artificial intelligence*. <https://www.vialytics.com/>
- Vialytics. (s.f.). *Case Study: Sonneberg, Germany – AI-powered Road Maintenance Optimization*. <https://www.vialytics.de/erfolgsgeschichten/sonneberg>
- Wang, D., Zhang, Y., & Li, T. (2024). Environmental constraints in vision-based pavement inspection: A deep learning perspective. *Automation in Construction*, 160, 105078.
- Wang, J., Li, Y., & Chen, X. (2024). Data augmentation for road damage detection using GAN and CNNs. *Pattern Recognition Letters*, 170, 12–19. <https://doi.org/10.1016/j.patrec.2023.12.19>
- Wang, Y., Li, H., & Yu, Y. (2024). Crack image data augmentation using GANs for improved detection performance. *Computer-Aided Civil and Infrastructure Engineering*.
- Xing, M., Fan, B., & Ma, Z. (2023). A multi-task learning framework for crack detection and classification. *Automation in Construction*, 148, 104812.
- Xing, Y., Zhang, Y., & Wu, X. (2023). Multi-task convolutional neural network for road crack type and severity classification. *IEEE Transactions on Intelligent Transportation Systems*.
- Yang, X., Li, H., & Yu, Y. (2019). Automatic pavement crack detection based on structured prediction with the convolutional neural network. *Computer-Aided Civil and Infrastructure Engineering*, 34(10), 913–933. <https://doi.org/10.1111/mice.12467>
- Yang, X., Li, J., Yu, H., & Zhou, L. (2019). Pixel-level crack detection using deep convolutional networks. *Computers in Civil Engineering*, 33(5), 04019037.

- Zhang, A., Li, Q., & Chen, Y. (2017). Hierarchical deep learning for road crack detection. *Computer-Aided Civil and Infrastructure Engineering*, 32(6), 488–505. <https://doi.org/10.1111/mice.12263>
- Zhang, A., Li, Q., & Chen, Y. (2017). Hierarchical deep learning for multi-type pavement damage detection. *Transportation Research Record*, 2645(1), 104–111.
- Zhang, X., Li, H., & Yu, Y. (2022). Thermal image-based pavement damage detection using deep learning. *Sensors*, 22(10), 3872.
- Zhou, F., Wang, J., Li, L., & Yang, R. (2019). Automated pavement distress detection using deep learning. *Transportation Research Record*, 2673(10), 217–229.
- Zhou, J., Gong, X., & Liu, J. (2019). Automated pavement crack detection based on deep convolutional neural network. *Construction and Building Materials*, 197, 1–10.
- Vialytics (s.f.). *Case Study: Sonneberg, Germany – AI-powered Road Maintenance Optimization*. <https://www.vialytics.de/erfolgsgeschichten/sonneberg>