

**DETERMINAR EL DETERIORO DEL PAVIMENTO FLEXIBLE MEDIANTE
ANÁLISIS DE INFORMACIÓN CAPTURADA A TRAVES DE VEHICULO AÉREO
NO TRIPULADO**

**JHON MARIO RODRIGUEZ CARRILLO
INGENIERO CIVIL
ESPECIALISTA EN SISTEMAS DE INFORMACIÓN GEOGRÁFICA**

**Universidad de Manizales
Facultad de Ciencias e Ingeniería
Maestría en Tecnologías de la Información Geográfica
Manizales, 2024**

**DETERMINAR EL DETERIORO DEL PAVIMENTO FLEXIBLE MEDIANTE
ANÁLISIS DE INFORMACIÓN CAPTURADA A TRAVÉS DE VEHICULO AÉREO
NO TRIPULADO**

JHON MARIO RODRIGUEZ CARRILLO

**Trabajo de Grado presentado como requisito para la obtención del título de Magister en
Tecnologías de la Información Geográfica**

**Director:
Ing. Alexander Mogollón Díaz, PhD**

**Línea de Investigación:
Deep Learning**

**Universidad de Manizales
Facultad de Ciencias e Ingeniería
Maestría en Tecnologías de la Información Geográfica
Manizales, 2024**

Resumen

El presente trabajo de investigación aborda la necesidad de evaluar el deterioro del pavimento asfáltico de manera eficiente, considerando la importancia de las vías para el desarrollo socioeconómico y la conectividad. Los objetivos fundamentales se centran en la determinación del estado del pavimento mediante la utilización del Índice de Condición de Pavimento (PCI) y tecnologías específicas, como el Vehículo Aéreo no tripulado, junto con algoritmos de detección de objetos basados en Deep Learning.

Los resultados indican que la propuesta metodológica constituye una alternativa viable a los métodos convencionales (personal en campo realizando muestreos), permitiendo la identificación y clasificación de los daños en el pavimento en un tiempo considerablemente menor ya que permite abarcar mayor área en menor tiempo.

Aunque se reconocen limitaciones asociadas, como la capacidad de procesamiento para entrenamiento de los modelos Deep Learning y la necesidad de ajustar los algoritmos para diferentes tipos de deterioro, se confirman la utilidad potencial de la metodología propuesta en la gestión de mantenimiento vial, alcanzando entre un 70% - 89% de precisión promedio en la detección del deterioro, y que, permite junto con el índice de Condición del Pavimento (PCI) la adecuada toma de decisiones para las intervenciones en los pavimentos.

Palabras clave: *Deterioro del Pavimento, Tecnologías de Información Geográfica, Aprendizaje Profundo, Vehículo Aéreo No Tripulado, Índice de Condición de Pavimento, Metodología No Invasiva.*

Contenido		Pág.
1.	Planteamiento del problema de investigación y su justificación.....	11
1.1	Descripción del área problemática.....	11
1.2	Formulación del problema.....	12
1.3	Justificación.....	12
2.	Antecedentes.....	14
3.	Objetivos.....	27
3.1	Objetivo general.....	27
3.2	Objetivos específicos.....	27
4.	Referente Contextual.....	29
5.	Referente Normativo y legal.....	30
6.	Referente teórico.....	32
6.1	Pavimento Flexible (asfáltico).....	32
6.2	Tipos de daños en el pavimento flexible.....	34
6.2.1	Fisuras.....	34
6.2.2	Deformaciones.....	36
6.2.3	Pérdida de capas estructurales.....	37
6.2.4	Daños superficiales.....	38
6.2.5	Otros daños.....	39
6.3	Evaluación del pavimento.....	39
6.4	Vehículo Aéreo no tripulado.....	40
6.5	Redes Neuronales.....	40
6.6	Redes Neuronales Convolucionales.....	41
6.7	Deep Learning.....	43
6.8	Detección de objetos con Deep Learning.....	44
6.8.1	Faster RCNN.....	45
6.8.2	Single Shot Detector (SSD).....	46
7.	Hipótesis de investigación.....	47
8.	Metodología.....	48
8.1	Enfoque metodológico.....	48
8.2	Tipo de estudio.....	48
8.3	Diseño de la investigación.....	48
8.4	Unidad de trabajo.....	49
8.5	Muestra y muestreo.....	49
8.6	Operacionalización de variables.....	49
8.7	Técnicas e instrumentos de recolección de información.....	50
8.8	Desarrollo metodológico.....	50

8.8.1	Definición del tipo de daño a estudiar	50
8.8.2	Datasets de entrenamiento de fuentes secundarias y primarias	51
8.8.3	Estandarización de Datasets de entrenamiento	53
8.9	Entrenamiento del dataset empleando algoritmos de detección de objetos	60
8.10	Detección de tipos de deterioro en las vías de estudio.....	63
8.11	Calculo PCI.....	65
9.	Discusión y Resultados.....	69
9.1.1	Resultado 1: Detección de los tipos de deterioro del pavimento asfaltico en el área de estudio	69
9.1.2	Resultado 2: Cuantificación del tipo de deterioro detectado	76
9.1.3	Resultado 3: Índice de condición del Pavimento Asfaltico en el área de estudio.	80
10.	Conclusiones.....	85
11.	Referencias bibliográficas.....	87

Lista de figuras

Figura 1	<i>Localización general de la zona de estudio</i>	29
Figura 2	<i>Distribución de cargas en el Pavimento Flexible</i>	32
Figura 3	<i>Redes Neuronales</i>	41
Figura 4	<i>Ejemplo de red con múltiples capas convolucionales</i>	42
Figura 5	<i>Representación gráfica Deep Learning</i>	44
Figura 6	<i>Arquitectura Faster R-CNN</i>	45
Figura 7	<i>Software LabelImg para etiquetado del deterioro</i>	52
Figura 8	<i>Código para estandarización de clases</i>	56
Figura 9	<i>Estandarización de imágenes del estudio para etiquetado</i>	57
Figura 10	<i>Verificación de correspondencia entre imágenes y etiquetas</i>	58
Figura 11	<i>Numero de etiquetas por clase</i>	59
Figura 12	<i>Flujo para entrenamiento</i>	61
Figura 13	<i>Procesamiento de imágenes capturadas con vehículo aéreo no tripulado</i>	64
Figura 14	<i>Inferencia en ArcGIS PRO para detección de objetos</i>	65
Figura 15	<i>Método para cuantificación de baches</i>	66
Figura 16	<i>Método cuantificación de fisuras</i>	67
Figura 17	<i>Desarrollo metodológico</i>	68
Figura 18	<i>Precisión promedio por época</i>	69
Figura 19	<i>Gráfico de pérdidas para SSD</i>	70
Figura 20	<i>Gráfico de pérdidas para Faster RCNN</i>	71
Figura 21	<i>Precisión promedio por modelo de detección de objetos</i>	72

Figura 23 <i>Predicciones SSD</i>	74
Figura 22 <i>Predicciones Faster RCNN</i>	74
Figura 24 <i>Ejemplo resultado de inferencia</i>	75
Figura 25 <i>Localización de las clases de deterioro detectadas por el modelo entrenado</i>	76
Figura 26 <i>Software EvalPal con datos ingresados</i>	81
Figura 27 <i>PCI para el subtramo 1</i>	82
Figura 28 <i>PCI para el subtramo 2</i>	82
Figura 29 <i>Índice PCI en el área de estudio</i>	84

Lista de tablas

Tabla 1	<i>GSD según altura de vuelo</i>	53
Tabla 2	<i>Clases de deterioro presentes en el dataset 2022</i>	54
Tabla 3	<i>Etiquetado del dataset AUDP</i>	54
Tabla 4	<i>Estandarización de etiquetas</i>	55
Tabla 5	<i>Clases y número total de muestras (etiquetas)</i>	60
Tabla 6	<i>Número de Imágenes para entrenamiento</i>	62
Tabla 7	<i>Tasas de aprendizaje obtenidas</i>	62
Tabla 8	<i>Precisión promedio por modelo de detección de objetos</i>	72
Tabla 9	<i>Cuantificación para PCI del deterioro del pavimento asfáltico</i>	77
Tabla 10	<i>Indicie de Condición del Pavimento para el área de análisis</i>	83

Introducción

La infraestructura vial es fundamental en el desarrollo socioeconómico de cualquier región, facilitando el intercambio comercial para el crecimiento económico y la mejora de la calidad de vida de sus habitantes. Dentro de esta infraestructura vial, el pavimento representa un elemento básico que permite el desplazamiento eficiente sobre la red vial, por consiguiente, se debe mantener en condiciones óptimas, garantizando sus adecuados mantenimientos para evitar el fin de su vida útil, ya que esto conduce a la pérdida de recursos invertidos y aumenta el tiempo de transporte y con ello incremento de costos asociados a este.

En este sentido, la detección y evaluación del deterioro del pavimento asfáltico representan un desafío constante para los encargados de su gestión, debido a la demanda de recursos y tiempo para llevar a cabo estas tareas de manera efectiva. La detección temprana y precisa del deterioro es esencial para la planificación de acciones de mantenimiento y rehabilitación, lo que a su vez puede prevenir costos elevados y riesgos para la seguridad de los usuarios ya que un pavimento en mal estado es un peligro latente para quienes transitan sobre la red vial.

La elección de este tema de investigación se basa en la necesidad de abordar el deterioro del pavimento asfáltico o flexible de manera eficiente y económica. La justificación radica en la búsqueda de métodos que permitan una evaluación precisa del estado de las vías, reduciendo la necesidad de inspecciones en campo que son costosas, requieren mayor tiempo y mano de obra. Este estudio se propone como una alternativa viable, utilizando tecnologías avanzadas como los Vehículos Aéreos No Tripulados (RPAS) y el aprendizaje profundo (Deep Learning), para ofrecer una solución que pueda superar las limitaciones de los métodos tradicionales, generando así una evaluación más rápida y extensiva del estado del pavimento.

La hipótesis central de este trabajo es que la combinación de imágenes capturadas por RPA y el uso de algoritmos de aprendizaje profundo (Single Shot Detector y Faster R-CNN) puede mejorar significativamente la eficiencia y reducir los costos asociados con la evaluación del deterioro del pavimento asfáltico. Se espera que esta metodología no solo sea más rápida y menos costosa que las inspecciones en campo, sino que también ofrezca una mayor precisión y detalle en la identificación de los daños.

En este contexto, el presente trabajo tiene como objetivo desarrollar y aplicar una metodología sistemática para la evaluación del estado del pavimento asfáltico, utilizando tecnología RPAS, algoritmos de detección de objetos y el Índice de Condición del Pavimento.

1. Planteamiento del problema de investigación y su justificación

1.1 Descripción del área problemática

De acuerdo con Tan & Li (2019) la rehabilitación oportuna y adecuada de las carreteras es esencial para el mantenimiento de estas, por ello, se necesita un método eficaz para detectar el deterioro de la superficie de rodadura con alta eficiencia y bajo costo.

El deterioro de la superficie asfáltica causado por agrietamientos por baja temperatura, agrietamiento por fatiga, espesor de capa insuficiente, no auscultación, y malos procesos constructivos, puede llevar a un aumento en los costos de transporte, dificultad de acceso al territorio, aumento de los accidentes de tránsito, aumento en los costos de rehabilitación y/o mantenimiento de la capa asfáltica, los cuales influyen en el desarrollo socioeconómico de la región.

Por tal razón, considerando que se carece de información confiable y periódica sobre el estado de las vías, es necesario brindar una solución eficiente, no invasiva y de menor costo que las inspecciones directas en campo, que permita determinar el deterioro del pavimento asfáltico y con ello, establecer las soluciones a implementar, por lo que esta investigación propone la implementación de las tecnologías de la información Geográfica, en busca de métodos que contribuyan a mejorar el rendimiento para determinar el deterioro de la superficie asfáltica, disminución de personal en campo y con ello reducción de costos y aumento de periodicidad de la evaluación del estado de las vías.

1.2 Formulación del problema

La carencia de información actualizada y confiable sobre el estado de las vías y el costo que tendría realizarlo por métodos directos es el principal motivo para el desarrollo de la investigación, por lo que se busca responder al interrogante ¿Es posible determinar el deterioro del pavimento asfáltico por medio de Vehículos Aéreos no tripulados para así establecer las acciones a tomar según su estado de deterioro?

1.3 Justificación

De acuerdo con el Banco Mundial (2014), “El transporte es un factor crucial para impulsar el crecimiento económico, reducir la pobreza y lograr los objetivos de desarrollo del milenio (ODM)”, adicionalmente, “Existe una relación positiva entre la provisión de infraestructura y el crecimiento económico y, por ende, el rol de la infraestructura de transporte es preponderante” (Sánchez et al., 2005).

Por su parte, USAID (2011) afirma que “las inversiones en infraestructura vial y acceso a servicios básicos, no solamente tendrá un efecto positivo en el nivel de vida de la población, sino también en propiciar condiciones para avanzar en el desarrollo económico en las localidades o entre distritos -a través de las mancomunidades municipales que tengan estos objetivos, por ejemplo-. La disponibilidad de caminos rurales y vías de interconexión entre las localidades permite mayor dinamismo económico en la zona mediante la creación de mercados y la salida rápida de productos agrícolas”.

Por lo tanto, considerando la relación entre la infraestructura vial y el desarrollo socioeconómico de la región, es importante mantener un adecuado estado de la red vial,

implementando así, acciones tempranas de mantenimiento o rehabilitación, razón por la cual, un método no invasivo, de menor costo, y que permite abarcar mayor área en menor tiempo significa un avance importante.

Esta investigación podrá servir como un referente para que el Municipio de Paipa pueda determinar tempranamente el deterioro del pavimento asfáltico con el fin de implementar acciones de rehabilitación y mantenimiento, destacando la importancia de la implementación de las tecnologías de información geográfica y aprendizaje profundo, como una estrategia efectiva para identificar y clasificar diversas formas de deterioro en pavimentos asfálticos, proporcionando datos precisos y relevantes para la toma de decisiones en el mantenimiento de vías.

2. Antecedentes

El desarrollo de nuevas tecnologías en el campo de las tecnologías de la información geográfica cada vez representa mayor utilidad en la ingeniería civil, por lo que la literatura revisada permite conocer los avances que se han tenido particularmente en el tema de interés (deterioro del pavimento asfáltico) mediante métodos de aprendizaje profundo, tal como se evidencia a continuación:

De acuerdo con Benmhahe & Chentoufi (2021), durante las últimas décadas aunque se han realizado estudios para determinar equipos y soluciones adaptables para determinar los daños en puentes, edificios y carreteras, sigue siendo un gran desafío una solución de bajo costo ya que, cuando se degrada las superficies de las carreteras y estas se vuelven severas, genera múltiples riesgos para los usuarios de las vías y el mantenimiento se vuelve costoso, es por esto que se hace necesario las acciones preventivas, con métodos precisos y eficientes basados en seguimiento en tiempo real, evaluando y estimando el estado de la carretera para decidir el mantenimiento adecuado. Para determinar el mantenimiento adecuado, es necesario conocer las clasificaciones del deterioro del pavimento las cuales se pueden clasificar en:

1. Agrietamiento, que abarca el agrietamiento por fatiga (piel de cocodrilo), agrietamiento de bloques, agrietamiento longitudinal, transversal, reflexión y por deslizamiento.
2. Distorsión, que incluye Rutting, Shoving, depresiones, socavaciones, fallos de parcheado.
3. Disgregación (Raveling y Baches).

4. Peligros de derrape (Árido pulido y bleeding)

y finalmente problemas del tratamiento de superficies.

Para detección de lo descrito anteriormente, comparó el conjunto de datos entrenados mediante YOLO V3, Faster R-CNN y SSD, en donde encontró que Faster RC-NN logra buenos resultados en la detección de grietas, sin embargo, YOLOV3 tiene buenos resultados en baches y el tiempo de detección de todos los tipos de deterioro es menor. Finalmente, concluyen que, la detección automática de los daños del pavimento es uno de los mayores retos de las ciudades inteligentes y el entrenamiento de los algoritmos es una operación crítica que puede realizarse periódicamente hasta que la detección alcance la precisión y madurez requerida.

Según Tan & Li (2019), debido al rápido desarrollo de software y hardware para fotogrametría, la fotogrametría con UAV, se presenta como un potente sustituto de bajo costo en comparación con la fotogrametría aérea tripulada, el cual, además, puede ser aplicado en agricultura, silvicultura, arquitectura, medio ambiente, emergencia y monitorio del tráfico. Conocer las condiciones de las vías, identificar oportunamente las fallas que se presentan, es importante para el mantenimiento y rehabilitación de estas, es por esto, que los UAV cuentan con ventajas como la maniobrabilidad, acceso a zonas difíciles, menos trabajo de campo, costo relativamente bajo en comparación con métodos directos e indirectos, por ende, son altamente prometedores en la evaluación de la condición del pavimento.

Para Roberts et al. (2020), los pavimentos de las carreteras necesitan un mantenimiento adecuado para garantizar que se mantengan en buen estado a lo largo de su vida útil, es por esto, que las autoridades necesitan bases de datos efectivas con información relevante sobre el estado

de las carreteras, pero, obtener esa información directa es costoso y en ocasiones difícil, sin embargo, es fundamental para las aplicaciones de ciudades inteligentes, es por esto, que se explora en el estudio, obtener información clave de las carreteras utilizando imágenes con dron para replicar la carretera como un modelo 3D, donde a través de este, se explotan estrategias de segmentación para comprender las condiciones de la carretera y hacer evaluaciones sobre el nivel de deterioro de la misma.

Cifuentes et al. (2021), presenta la metodología para la detección y clasificación de fallas en el pavimento mediante cuatro etapas las cuales son: Adquisición de las imágenes, procesamiento de las imágenes, extracción de las características y clasificación del deterioro mediante redes neuronales artificiales. La metodología se aplicó en la detección de grietas longitudinales, baches y piel de cocodrilo, en donde se obtuvo una exactitud global de 95.56% y una precisión de 94.44%.

De acuerdo al documento de enfoque de redes neuronales profundas para la segmentación de grietas en el pavimento a nivel de píxeles utilizando imágenes capturadas por dron presentado por Jiang et al. (2020), el estudio se enfoca en investigar el potencial del uso de cámaras montadas en drones para la evaluación de las condiciones del pavimento, el cual, tradicionalmente se evalúa con métodos manuales o sensores láser, sin embargo este último, es voluminoso, costoso y solo se puede cubrir un carril, es por esto, que los drones, se están convirtiendo en una solución rentable para la inspección de activos y pueden abarcar mayor área en menor tiempo. La investigación utiliza Deep learning, en donde se menciona que cuenta con desempeño bueno en la segmentación de grietas a nivel píxel, que es una característica para la evaluación de las condiciones del pavimento.

En el caso de estudio, abordado por Alkaabi et al. (2021), mediante el uso del dron DJI Phantom 4 pro, realizan la investigación para detectar grietas en la superficie de la carretera, en donde concluyeron, que la fotogrametría es ineficaz para encontrar la profundidad de las grietas, sin embargo, se considera preciso al medir la longitud transversal de la sección de las grietas y su precisión es hasta 1mm. Por lo tanto, este tipo de drones se pueden aplicar de forma eficaz en vías existentes para estudiar su deterioro.

Hoang (2019), manifiesta la desafiante tarea de detección automática de Raveling basada en muestras de imágenes debido a la compleja textura del pavimento asfáltico. Su investigación, construye e investiga la capacidad de procesamiento de imágenes para el reconocimiento de Raveling o desprendimiento progresivo de los agregados de la superficie de rodadura causado por el paso de las llantas sobre el material asfáltico. El procesamiento de las imágenes y el entrenamiento automático logra un rendimiento predictivo deseado de 88.12%, por lo tanto, el modelo puede ser una herramienta útil para las autoridades de transporte para evaluar rápidamente la condición del pavimento.

Romero-Chambi et al. (2020), desarrolló un modelo para medir baches utilizando modelos 3D generados a partir de fotografías con vehículos aéreos no tripulados y procesarlos mediante el software SfM-MVS, para ello, es importante establecer la combinación de parámetros de planificación del vuelo y captura de datos, de tal manera que brinde la precisión adecuada en la reconstrucción de modelos 3D, en donde obtuvo que para altura de 10 y 15m, es aplicable la metodología. Concluye que el uso de UAVs es un sustituto económico frente a tecnologías más sofisticadas como el láser terrestre, además, se evidencia menor error en la

medida del ancho de bache, presentando mayor error en la profundidad de este y con esto en su volumen.

Shatnawi (2018), presenta un estudio sobre la detección automática de grietas en pavimentos utilizando técnicas de procesamiento de imágenes y redes neuronales para evaluar carreteras deterioradas en el norte de Jordania, para ello, se utiliza el filtrado de imágenes, detección de bordes, eliminación de ruido y umbralización. El autor destaca el potencial de la investigación en aplicaciones relacionadas con la ingeniería de transporte, construcción de carreteras y otras áreas afines. Concluye que el modelo de la red neuronal artificial muestra idoneidad para el reconocimiento de grietas y menciona la posibilidad de contar con aplicaciones móviles para aplicar esta tecnología.

Según Furusho Becker et al. (2019), la infraestructura de transporte necesita un mantenimiento constante y se requiere que los sistemas de gestión de pavimentos sean confiables y detallados sobre el estado actual de las vías para tomar decisiones efectivas. Es por esto, que utilizó redes neuronales convolucionales para detectar automáticamente baches en carreras a partir de imágenes tomadas por vehículos aéreos no tripulados. Se realizaron diferentes configuraciones y parámetros a la red neuronal tales como resolución de las imágenes, aumentación de datos y modelos pre-entrenados Faster-RCNN. Los resultados arrojaron una precisión del 70,4% en la detección de baches.

Las grietas se consideran los signos iniciales del deterioro y degradación de la resistencia del pavimento, por ello, la inspección regular y mantenimiento de las carreteras es fundamental para evitar una mayor degradación es por esto por lo que las investigaciones sobre la detección

del agrietamiento del pavimento se han convertido en un importante tema de investigación en las últimas décadas. En el trabajo propuesto, se creó un conjunto de datos de 4000 imágenes tomadas por un vehículo aéreo no tripulado de diversas superficies en carreteras de los Emiratos árabes en donde se utiliza un algoritmo de aprendizaje profundo para entrenar el conjunto de datos. La investigación concluye que el sistema de redes convolucionales propuesto CNN en combinación con la tecnología de dron, es capaz de detectar el tipo de grieta independientemente de las condiciones de luminosidad, aclaran que la limitación del trabajo es la imposibilidad de extraer de la imagen las características internas de la imagen (Ali et al., 2019).

La calidad del pavimento tiene una estrecha relación con la vida útil de la carretera (Pan et al., 2017) por esto, considerando que son el elemento básico del sistema de transporte se debe mejorar la eficiencia de la inspección del pavimento. El estudio propuesto por Pan et al. (2017) utilizó imágenes del pavimento adquiridas por vehículos aéreos no tripulados y entrenó el conjunto de imágenes con cuatro algoritmos de aprendizaje supervisado como K-Nearest Neighbours (KNN), Support Vector Machine (SVM), Artificial Neural Network (ANN) y Random Forest (RF), con lo anterior, se concluyó que cada tipo de algoritmo cuando se le asignan parámetros específicos puede lograr una precisión mayor al 98%, particularmente RF podría tener mejor rendimiento con una mayor precisión y menor tiempo de funcionamiento.

Zhang et al. (2019) presenta un estudio sobre la detección de daños en pavimentos utilizando tecnologías de procesamiento de imágenes y vehículos aéreos no tripulados (UAV). Se destaca la importancia de la detección de deterioro en pavimentos para evaluar el estado real de las carreteras y planificar el mantenimiento. El sistema propuesto se divide en dos subsistemas: control inteligente de UAV y detección de defectos. El primero incluye programas

especiales para lograr funciones como despegue y aterrizaje automáticos, control de trayectoria automática, y control de cámara y cardán. El segundo propone un método combinado que mejora la detección de bordes y la precisión del procesamiento de imágenes. Se realizó un análisis cualitativo y cuantitativo de los algoritmos de detección de bordes, concluyendo que el método de combinación propuesto es el mejor en términos de precisión de reconocimiento de tipos de grietas y extracción de características geométricas.

Kasthurirangan et al. (2018) aborda el uso de vehículos aéreos no tripulados (UAV) para la inspección de infraestructuras civiles. Se enfoca en el uso de modelos de aprendizaje profundo pre-entrenados y transfer learning para la detección automatizada de grietas en imágenes de UAV, con énfasis en la efectividad de la transferencia de aprendizaje y la evaluación del rendimiento de diferentes clasificadores. Además, se destaca la importancia de la inspección de infraestructuras y la necesidad de mejorar los algoritmos de detección para incluir otros tipos de defectos, como la corrosión. Los resultados muestran que el enfoque propuesto puede lograr hasta un 90% de precisión en la detección de grietas en situaciones realistas.

Arya et al. (2022) presenta un amplio conjunto de datos de imágenes de carreteras recopilado de seis países para la detección y clasificación automática de daños en carreteras (RDD2022) mediante técnicas de aprendizaje profundo. El conjunto incluye 47,420 imágenes con más de 55,000 instancias de daños, enfocándose en cuatro tipos: grietas longitudinales, transversales, tipo cocodrilo y baches. El artículo detalla la evolución del RDD (Road Damage Detector) desde 2018 hasta la versión de 2022, destacando mejoras y ajustes realizados en base a retroalimentación de investigadores y la necesidad de un modelo más generalizable y robusto que abarque diversas condiciones viales internacionales utilizando una variedad de métodos de

adquisición de imágenes, incluyendo el uso de smartphones, cámaras de alta resolución montadas en vehículos y drones, así como imágenes de Google Street View.

De acuerdo con el estudio denominado “Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone” (Maeda et al., 2018) se presenta un avance significativo en la detección automatizada de daños en carreteras utilizando técnicas de aprendizaje profundo y procesamiento de imágenes. El conjunto de datos creado y los modelos entrenados están disponibles públicamente, lo que facilita la investigación y el desarrollo futuros en este campo. Se aborda el problema del envejecimiento de la infraestructura vial en Japón y la necesidad de métodos eficientes para inspeccionar el estado de las carreteras ante la escasez de expertos y recursos financieros para realizar inspecciones adecuadas, el estudio propone un enfoque automatizado utilizando técnicas de visión por computadora y aprendizaje profundo basado en redes neuronales convolucionales (CNN) de última generación.

Arya et al. (2020) describe el Global Road Damage Detection Challenge (GRDDC), integrado en la IEEE International Conference on Big Data 2020, que busca avanzar en la detección automática de daños en carreteras mediante un conjunto de datos de imágenes de carreteras y una competencia asociada sobre clasificación y detección de daños en carreteras. La competencia o desafío, contó con la participación de diferentes equipos internacionales y utilizó un conjunto de datos de 26,336 imágenes de carreteras de India, Japón y la República Checa. Las soluciones fueron evaluadas en dos conjuntos de prueba, y el mejor modelo logró una puntuación F1 (calculada a partir de la precisión y la recuperación de predicciones correctas) de 0.67 y 0.66 en las pruebas.

Se sugiere mejoras para futuros desafíos, como permitir métodos entrenados en otros datos, introducir nuevas tareas de evaluación, considerar la velocidad de inferencia y el tamaño del modelo, y mejorar el equilibrio de clases de daños en el conjunto de datos. Además, se reconoce la necesidad de seguir aumentando los datos con imágenes de diversas regiones y condiciones de carreteras para mantener la relevancia y utilidad del desafío (Arya, Maeda, Ghosh, Toshniwal, Omata, et al., 2020).

Arya, Maeda, Ghosh, Toshniwal, Mraz, et al. (2020) en su investigación denominada “Transfer Learning-based Road Damage Detection for Multiple Countries” detalla la infraestructura vial como un activo público esencial que contribuye al desarrollo económico y aporta beneficios sociales al conectar comunidades y negocios, y brindar acceso a servicios educativos, laborales y de salud, por ende, el conocimiento del grado de deterioro es crucial para un mantenimiento eficiente y rentable de las carreteras. El estudio hace varios aportes clave. En primer lugar, evalúa la aplicabilidad del modelo japonés en otros países. En segundo lugar, propone un conjunto de datos heterogéneo a gran escala que contiene 26,620 imágenes de daños en carreteras obtenidas de varios países. En tercer lugar, se proponen modelos generalizados capaces de detectar y clasificar daños en carreteras en más de un país. Por último, se brindan recomendaciones para implementar sistemas de detección y clasificación de daños viales automáticos en otros países a partir de los datos y modelos publicados por un país, en este caso Japón. La investigación se centra en el uso de teléfonos inteligentes como una alternativa económica y eficiente para la inspección de superficies viales.

El estudio presentado por Saad & Tahar (2019) se centra en la evaluación de deformaciones y baches en superficies de carreteras utilizando vehículos aéreos no tripulados

(UAV), específicamente multirrotores. La metodología del estudio se divide en cuatro fases principales: reconocimiento y planificación del sitio, adquisición de datos, procesamiento de datos y análisis de resultados. La adquisición de datos se realiza a diferentes altitudes para determinar el efecto de la resolución en la extracción de baches. Se utilizó un UAV DJI Phantom 3 Professional para capturar imágenes aéreas, y se compararon las mediciones de baches obtenidas con las imágenes de UAV con las mediciones de campo tradicionales, encontrando una discrepancia dentro de un rango de 1 cm.

Los resultados indican que las imágenes tomadas a menor altitud (10 m) proporcionan mediciones más precisas que las tomadas a mayor altitud (40 m). Además, se demostró que el uso de UAVs es adecuado para detectar y medir baches, mejorando la eficiencia en la recopilación de datos sobre el estado de las carreteras.

El artículo "A cost effective solution for pavement crack inspection using cameras and deep neural networks"(Mei & Gül, 2020), presenta una solución innovadora y rentable para la inspección de fisuras en pavimentos. El estudio se centra en el uso de cámaras deportivas comerciales y redes neuronales profundas para detectar automáticamente las grietas en las superficies de las carreteras. Los autores destacan que las grietas en el pavimento son indicadores tempranos de daños potenciales y su detección oportuna es crucial para el mantenimiento de la infraestructura vial. La práctica común de inspección manual es costosa y poco eficiente, lo que motiva la búsqueda de métodos automatizado por lo que desarrollaron un algoritmo denominado ConnCrack, que utiliza una red Wasserstein (cWGAN) y mapas de conectividad para mejorar la precisión en la detección de grietas a nivel de píxel.

Para (Du et al., 2021) el propósito de su investigación consiste en revisar y analizar imágenes para la detección del deterioro en pavimentos, esto incluye la evaluación de diferentes métodos y dispositivos de adquisición de imágenes, como cámaras digitales, cámaras de profundidad y tecnología de imagen térmica, y su uso en la ingeniería de pavimentos para identificar y clasificar fisuras, baches y fallas en las juntas. El estudio también examina la eficacia de las técnicas de procesamiento de imágenes digitales en diferentes escalas y su impacto en la precisión y eficiencia de la detección de problemas en la superficie del pavimento.

Así mismo, (Saurabh et al., 2020), presenta un estudio sobre la detección de baches en carreteras mediante el procesamiento de imágenes capturadas por Vehículos Aéreos. El estudio aborda la problemática de los baches en India, destacando su contribución a accidentes de tránsito y su impacto negativo en la infraestructura. La investigación propone un sistema automatizado de detección que utiliza técnicas de procesamiento de imágenes y operaciones para identificar baches. Se hace énfasis en la utilidad de los UAV en áreas de difícil acceso y su capacidad para recolectar datos de forma eficiente. Se menciona una precisión de detección del 80%. La implementación del sistema se realizó en MATLAB y se sugiere una ampliación futura con tecnologías de Inteligencia Artificial y Aprendizaje Automático para mejorar la precisión y la extracción de características de las imágenes.

Por otro lado, (Pan et al., 2018) llevó una investigación en un tramo de carretera en Shihezi, Xinjiang, China, el cual aborda la problemática de la detección de daños en pavimentos de asfalto, específicamente baches y grietas, utilizando un enfoque que integra imágenes multispectrales capturadas por vehículos aéreos no tripulados (UAV) y algoritmos de aprendizaje automático como máquinas de soporte vectorial (SVM), redes neuronales artificiales

(ANN) y bosques aleatorios (RF). El estudio resalta la importancia de la selección adecuada de la resolución espacial de las imágenes y la relevancia de las características espectrales, geométricas y texturales en la clasificación de los daños del pavimento. Los resultados del estudio indican que la incorporación de características espectrales, geométricas y texturales en la clasificación de bosques aleatorios mejora significativamente la delimitación de baches y grietas en las imágenes de UAV.

Mukti & Tahar (2022), describe diversas técnicas y tecnologías para la detección automática y la clasificación de baches, incluyendo la integración de sensores con sistemas de posicionamiento. Explora métodos de procesamiento de imágenes 2D y modelos 3D obtenidos mediante escaneo láser y fotogrametría, destacando la aplicación de algoritmos como redes neuronales artificiales y máquinas de vectores de soporte para mejorar la precisión en la identificación de los bordes de los baches. Se resalta la importancia de la información de la geometría de los baches para entender el mantenimiento de carreteras y determinar estrategias de mantenimiento adecuadas.

Por otra parte, Inzerillo et al. (2022) presenta una metodología de imágenes de superresolución aplicada a conjuntos de datos de UAV para la monitorización del pavimento de carreteras, evaluando la precisión geométrica de modelos 3D a grandes alturas de vuelo (Al realizar vuelos a mayores alturas las imágenes son de menor resolución, lo que resulta en modelos 3D con un error métrico inaceptable para la monitorización efectiva del pavimento) mediante el algoritmo Morpho Super-Resolution. Los investigadores implementaron un caso de estudio en Palermo, Italia, utilizando un dron equipado con un sensor CMOS de 12 megapíxeles. El estudio comparó nubes de puntos densas generadas a partir de imágenes de baja resolución y

superresolución con una nube de puntos de referencia ("ground truth"). Los resultados mostraron que el procesamiento de imágenes de baja resolución mediante el algoritmo de superresolución redujo significativamente el error cuadrático medio (RMS) en la reconstrucción 3D, pasando de más de 10 cm a un rango entre 0 y 1,5 cm.

Por otra parte, en cuanto a PCI, Benites Apolo & Torres Tocto (2022) en su tesis de investigación abordaron el cálculo del índice de condición del pavimento de la Av. Colectora en Piura, utilizando drones. El objetivo se basó en determinar el estado superficial del pavimento, aplicando el método PCI y proponer alternativas para el mantenimiento preventivo y reactivo. La metodología incluye la recolección de datos mediante drones, división de secciones de la vía en unidades de muestra, procesamiento de imágenes y el cálculo del PCI para todo el tramo de la vía. Se presenta de forma detallada los tipos de pavimentos, las causas de los daños, la calidad de tránsito y las fallas en pavimento flexible y de concreto, proporcionando información sobre las distintas categorías de daños en los pavimentos, sus causas y niveles de severidad asociados. Además, se destaca la propuesta de una metodología alternativa utilizando vehículos aéreos no tripulados para la evaluación del pavimento, con el fin de reducir costos y recursos, en comparación con métodos convencionales de inspección de campo.

3. Objetivos

3.1 Objetivo general

Determinar el deterioro del pavimento flexible mediante el análisis de información capturada con vehículo aéreo no tripulado, utilizando un enfoque basado en la detección de objetos. Posteriormente, calcular y evaluar la condición del pavimento asfáltico utilizando el Índice de Condición de Pavimento (PCI) como indicador principal, basado en las imágenes obtenidas durante el proceso de análisis.

3.2 Objetivos específicos

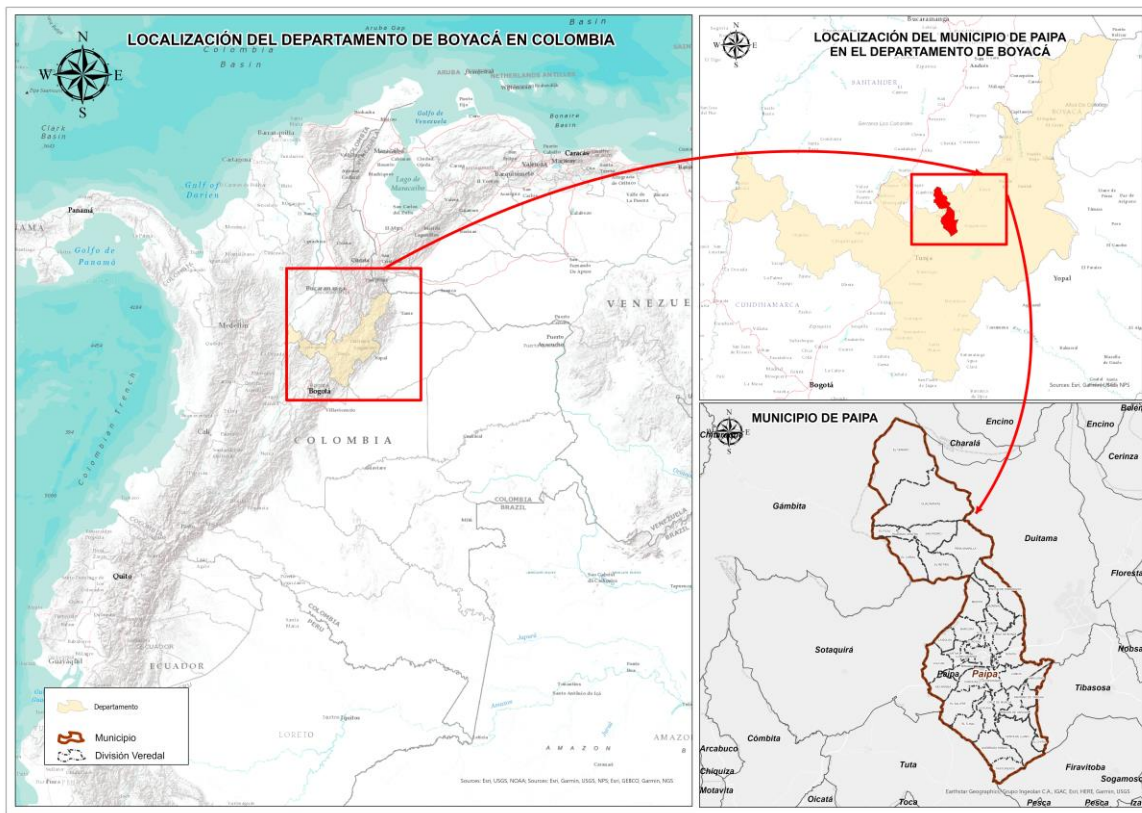
- 3.2.1. Garantizar la obtención de imágenes de alta calidad y una cobertura completa del área de interés mediante la planificación y ejecución efectiva de vuelos con vehículo aéreo no tripulado (RPA), con el objetivo de proporcionar datos detallados para su análisis en la investigación.
- 3.2.2. Generar ortofotos de alta resolución a partir de imágenes capturadas durante vuelos con RPAS, utilizando software especializado de procesamiento de imágenes aéreas, con el fin de producir resultados adecuados que sean aplicables en la investigación.
- 3.2.3. Desarrollar e implementar algoritmos de detección de objetos para identificar y localizar irregularidades en la capa asfáltica, con el fin de mejorar la precisión y la eficiencia en la detección del deterioro del pavimento.
- 3.2.4. Mejorar la precisión y la eficacia en la cuantificación de la magnitud y extensión de los defectos en la capa asfáltica al adaptar algoritmos de segmentación para delinear con precisión las áreas afectadas por las irregularidades, permitiendo así una evaluación más detallada y precisa de la condición del pavimento
- 3.2.5. Definir métricas cuantitativas para evaluar el deterioro del pavimento, utilizando el PCI como indicador principal.

4. Referente Contextual

La investigación se ubicó al noreste del departamento de Boyacá, en el municipio de paipa, el cual se caracteriza por participar en diversos sectores económicos, siendo los principales, la agricultura, ganadería y minería; adicionalmente, se destaca por ser una zona turística, razón por la cual, es fundamental contar con un buen estado de las vías de tal manera que no genere perdidas en el desarrollo socioeconómico de la región.

Figura 1

Localización general de la zona de estudio



Fuente: elaboración propia

5. Referente Normativo y legal

En este apartado, se abordan las normativas que tiene relación con la presente investigación, con el fin de tener referentes legales, normativos y técnicos para el uso de drones y la determinación del deterioro del pavimento asfáltico. A continuación, se mencionan y listan los referentes normativos:

Resolución No. 197 de 2022: “Por medio de la cual se modifica la Resolución 471 y 529 de 2020 “Por medio de la cual se establecen las especificaciones técnicas mínimas que deben tener los productos de la cartografía básica oficial de Colombia” (IGAC, 2022). La resolución relaciona lineamientos técnicos generales y especificaciones para productos escala 1:1000 a 1:50000.

Resolución 370 de 2021: “Por medio de la cual se establece el sistema de proyección cartográfica oficial para Colombia” (IGAC, 2021), en el cual se adopta el Origen único nacional (EPSG 9377), el cual será utilizado en la investigación.

RAC 91: mediante resolución 04201 del 27 de diciembre 2018 se “incorpora a la norma RAC 91 de los reglamentos aeronáuticos de Colombia, unas disposiciones sobre operación de sistemas de aeronaves no tripuladas UAS y se enumeran como apéndice 13, y se adoptan otras disposiciones”(Unidad Administrativa Especial de Aeronáutica Civil, 2018), este apéndice aborda los ámbitos generales de aplicación, régimen sancionatorio, presenta la clasificación de las operaciones con UAS, las limitaciones y requisitos para cada una de ellas.

RAC 100: mediante resolución 01983 del 27 de septiembre de 2023 se incorpora a los reglamentos aeronáuticos de Colombia el RAC100, en donde se establecen las reglas y requisitos

de operación para todo sistema de aeronave no tripulada UAS (Unidad Administrativa Especial de Aeronáutica Civil, 2023).

ASTM D6433: “Procedimiento Estándar para la Inspección del Índice de Condición del Pavimento en Caminos y Estacionamientos” (Designation A. S. T. M, 2011). Abarca la determinación de la condición del pavimento a través de inspecciones visuales usando el método del Índice de Condición del Pavimento (PCI) que cuantifica la condición del pavimento.

Manual para la Inspección Visual de Pavimentos Flexibles: de acuerdo con el Estudio e Investigación del Estado Actual de las Obras de la Red Nacional de Carreteras - Convenio Interadministrativo 0587-03: “Manual para la Inspección Visual de Pavimentos Flexibles” (Instituto Nacional de Vías -INVIAS, 2006). Brinda herramientas que pueden ser empleadas para determinar los daños encontrados durante la inspección visual, lo que permite identificar el tipo, magnitud, severidad, localización y sectores de la vía más afectados.


6. Referente teórico

6.1 Pavimento Flexible (asfáltico)

Para Adlinge & Gupta (2013), un pavimento flexible está conformado por varias capas de material granular recubiertas con una o más capas superficiales bituminosas, las cuales se flexionan bajo la carga de un neumático. Las capas del pavimento asfáltico corresponden a la superficie de rodadura, base, subbase y subrasante, las cuales permiten la distribución de cargas en toda la estructura (Figura 2) evitando la flexión excesiva del pavimento y su falla.

Figura 2

Distribución de cargas en el Pavimento Flexible



Nota. Distribución de cargas y capas del pavimento flexible. Tomado de (Adlinge & Gupta, 2013)

El deterioro del pavimento es producido por un conjunto de factores ambientales y de cargas, que inciden en las características funcionales o estructurales del mismo, en donde, los principales causantes según Adlinge & Gupta (2013) son:

El tráfico: Es el factor más influyente en el rendimiento del pavimento dada la magnitud de la carga, la configuración y número de repeticiones de carga por vehículos pesados que es sometido el pavimento.

La humedad: Puede debilitar significativamente la resistencia de los materiales principalmente los presentes en la subrasante, generando pérdida de interconexión de las partículas y posterior desplazamiento de estas, provocando la falla del pavimento.

La Subrasante: Es el suelo que soporta la base, subbase, superficie de rodadura y con ello las cargas aplicadas por el paso de las ruedas. Si la subrasante es débil o no se realiza el adecuado mejoramiento del suelo antes de la construcción de la estructura del pavimento, éste se flexionaría excesivamente lo cual provocaría la falla del pavimento.

La calidad constructiva: Es importante materiales de construcción adecuados a la necesidad técnica, adecuada compactación, evitar condiciones inadecuadas de humedad durante la construcción, espesor requerido de la capa después de la compactación, se resalta la necesidad de personal capacitado, buenos procedimientos de inspección y calidad durante el proceso constructivo.

El mantenimiento: El pavimento sufrirá deterioro con el tiempo por las condiciones mencionadas anteriormente, es por esto por lo que el mantenimiento es fundamental para evitar que se deteriore hasta un estado deficiente, sino se realiza un mantenimiento adecuado a tiempo, el costo de rehabilitación la carretera en pocos años puede ser hasta 16 veces mayor (Adlinge & Gupta, 2013, pp. 3-4).

6.2 Tipos de daños en el pavimento flexible

Los daños que presenta una estructura de pavimento flexible pueden ser clasificados en cuatro categorías (fisuras, deformaciones, pérdida de capas estructurales, daños superficiales y otros daños) y estas a su vez en otras subcategorías cuya clasificación de severidades corresponden a Baja, Media y Alta, de acuerdo con el (Instituto Nacional de Vías -INVIAS, 2006), estas se definen como sigue:

6.2.1 Fisuras

Fisuras longitudinales y transversales: “Corresponden a discontinuidades en la carpeta asfáltica, en la misma dirección del tránsito o transversales a él. Son indicio de la existencia de esfuerzos de tensión en alguna de las capas de la estructura, los cuales han superado la resistencia del material afectado”.

Fisuras en juntas de construcción: “Corresponden a fisuras longitudinales o transversales generadas por la mala ejecución de las juntas de construcción de la carpeta asfáltica o de las juntas en zonas de ampliación. Se localizan generalmente en el eje de la vía, coincidiendo con el ancho de los carriles, zonas de ensanche y en zonas de unión entre dos etapas de colocación de pavimento asfáltico “.

Fisuras por reflexión de juntas o grietas en placas de concreto: “Este tipo de daño se presenta cuando existe una capa de concreto asfáltico sobre placas de concreto rígido; tales fisuras aparecen por la proyección en superficie de las juntas de dichas placas, en cuyo caso presentan un patrón regular, o también cuando existen grietas en las placas de concreto rígido que se han reflejado hasta aparecer en la superficie presentando un patrón irregular”.

Fisuras en medialuna: “Son fisuras de forma parabólica asociadas al movimiento de la banca por lo que usualmente se presentan acompañadas de hundimientos”.

Fisuras de borde: “Corresponden a fisuras con tendencia longitudinal a semicircular localizadas cerca del borde de la calzada, se presentan principalmente por la ausencia de berma o por la diferencia de nivel entre la berma y la calzada”.

Fisuras en bloque: “Cuando se presenta este tipo daño la superficie del asfalto es dividida en bloques de forma aproximadamente rectangular. Los bloques tienen lado promedio mayor que 0,30 m. Este deterioro difiere de la piel de cocodrilo en que esta última aparece en áreas sometidas a carga, mientras que los bloques aparecen usualmente en áreas no cargadas. Sin embargo, es usual encontrar fisuras en bloque que han evolucionado en piel de cocodrilo por acción del tránsito. Por otra parte, la piel de cocodrilo generalmente está formada por bloques con más lados y ángulos agudos”.

Piel de cocodrilo: “Corresponde a una serie de fisuras interconectadas con patrones irregulares, generalmente localizadas en zonas sujetas a repeticiones de carga. La fisuración tiende a iniciarse en el fondo de las capas asfálticas, donde los esfuerzos de tracción son mayores bajo la acción de las cargas. Las fisuras se propagan a la superficie inicialmente como una o más fisuras longitudinales paralelas. Ante la repetición de cargas de tránsito, las fisuras se propagan formando piezas angulares que desarrollan un modelo parecido a la piel de un cocodrilo. Tales piezas tienen por lo general un diámetro promedio menor que 30 cm”.

Fisuración por deslizamiento de capas: “Corresponden a fisuras en forma de semicírculo o medialuna, con curvaturas definidas de acuerdo con la fuerza de tracción que

produce la llanta sobre el pavimento (al acelerar o frenar). Este tipo de fisuras se genera por acción del arranque o frenado de los vehículos lo que conlleva a que la superficie del pavimento se deslice y se deforme. Usualmente aparecen en zonas montañosas, en curvas o en intersecciones”.

Fisuración incipiente: “La fisuración incipiente corresponde a una serie de fisuras contiguas y cerradas, que generalmente no se interceptan. Suelen afectar el concreto asfáltico de manera superficial. Por ser daños muy leves no poseen niveles de severidad asociados” (INVIAS, 2006).

6.2.2 Deformaciones

Ondulación: “También conocida como corrugación o rizado, es un daño caracterizado por la presencia de ondas en la superficie del pavimento, generalmente perpendiculares a la dirección del tránsito, con longitudes entre crestas usualmente menores que 1,0 m”.

Abultamiento: “Este deterioro se asigna a los “abombamientos” o prominencias que se presentan en la superficie del pavimento. Pueden presentarse bruscamente ocupando pequeñas áreas o gradualmente en áreas grandes, acompañados en algunos casos por fisuras”.

Hundimiento: “Los hundimientos corresponden a depresiones localizadas en el pavimento con respecto al nivel de la rasante. Este tipo de daño puede generar problemas de seguridad a los vehículos, especialmente cuando contienen agua pues se puede producir hidroplaneo. Los hundimientos pueden estar orientados de forma longitudinal o transversal al eje de la vía, o pueden tener forma de medialuna, en cualquier caso, el reporte del daño debe incluir

en las aclaraciones, la orientación o la forma del hundimiento, si es fácilmente identificable en campo”.

Ahuellamiento: “El ahuellamiento es una depresión de la zona localizada sobre la trayectoria de las llantas de los vehículos. Con frecuencia se encuentra acompañado de una elevación de las áreas adyacentes a la zona deprimida y de fisuración. Un ahuellamiento significativo puede llevar a la falla estructural del pavimento y posibilitar el hidropneumático por almacenamiento de agua”. (INVIAS, 2006)

6.2.3 Pérdida de capas estructurales

Descascaramiento: “Este deterioro corresponde al desprendimiento de parte de la capa asfáltica superficial, sin llegar a afectar las capas asfálticas subyacentes”.

Baches: “Desintegración total de la carpeta asfáltica que deja expuestos los materiales granulares, lo cual lleva al aumento del área afectada y al aumento de la profundidad debido a la acción del tránsito. Dentro de este tipo de deterioro se encuentran los ojos de pescado que corresponden a baches de forma redondeada y profundidad variable, con bordes bien definidos que resultan de una deficiencia localizada en las capas estructurales”.

Parche: “Los parches corresponden a áreas donde el pavimento original fue removido y reemplazado por un material similar o diferente, ya sea para reparar la estructura (a nivel de concreto asfáltico o hasta granulares) o para permitir la instalación o reparación de alguna red de servicios. Aunque dicha área puede no presentar daños al momento de la inspección, es necesario reportar su extensión porque indica la existencia de un deterioro anterior” (INVIAS, 2006).

6.2.4 Daños superficiales

Desgaste superficial: “Corresponde al deterioro del pavimento ocasionado principalmente por acción del tránsito, agentes abrasivos o erosivos. Se presenta como pérdida de ligante y mortero. Suele encontrarse en las zonas por donde transitan los vehículos. Este daño provoca aceleración del deterioro del pavimento por acción del medio ambiente y del tránsito”.

Pérdida de agregado: “Conocida también como desintegración, corresponde a la disgregación superficial de la capa de rodadura debido a una pérdida gradual de agregados, haciendo la superficie más rugosa y exponiendo de manera progresiva los materiales a la acción del tránsito y los agentes climáticos. Este tipo de daño es común en tratamientos superficiales, caso en el que pueden aparecer estrías en la dirección del riego y debe ser reportado como surcos”.

Pulimiento del agregado: “Este daño se evidencia por la presencia agregados con caras planas en la superficie o por la ausencia de agregados angulares, en ambos casos se puede llegar a afectar la resistencia al deslizamiento”.

Cabezas duras: “Corresponde a la presencia de agregados expuestos fuera del mortero arena-asfalto, que puede llegar a aumentar la rugosidad del pavimento, provocando ruido excesivo para el conductor”.

Exudación: “Este tipo de daño se presenta con una película o afloramiento del ligante asfáltico sobre la superficie del pavimento generalmente brillante, resbaladiza y usualmente pegajosa. Es un proceso que puede llegar a afectar la resistencia al deslizamiento”.

Surcos: “Corresponde a franjas o canales longitudinales donde se han perdido los agregados de la mezcla asfáltica”. (INVIAS, 2006)

6.2.5 Otros daños

Corrimiento vertical de la berma: “Corresponde a una diferencia de elevación entre la calzada y la berma, debido a un desplazamiento de la berma. Permite la infiltración de agua hacia el interior de la estructura del pavimento, provocando su deterioro”.

Separación de la berma: “Este daño indica el incremento en la separación de la junta existente entre la calzada y la berma. Este daño permite la infiltración de agua hacia el interior de la estructura del pavimento provocando su deterioro”.

Afloramiento de finos: “Este afloramiento corresponde a la salida de agua infiltrada, junto con materiales finos de la capa de base por las grietas, cuando circulan sobre ellas las cargas de tránsito. La presencia de manchas o de material acumulado en la superficie cercana al borde de las grietas indica la existencia del fenómeno. Se encuentra principalmente en pavimentos semirrígidos (con base estabilizada)”.

Afloramiento de agua: “Presencia del líquido en la superficie del pavimento en instantes en los cuales no hay lluvia”. (INVIAS, 2006)

6.3 Evaluación del pavimento

Benmhahe & Chentoufi (2021), mencionan que la evaluación de la salud de la superficie del pavimento es una combinación del tipo y nivel de gravedad de los daños, y que, de acuerdo con la revisión de literatura, se encuentra que los índices utilizados para la evaluación del

pavimento son el Índice de Condición del Pavimento (PCI), Índice Internacional de Rugosidad (IRI), Profundidad Ruth (RD) y el Índice de Serviciabilidad del Pavimento (PSI).

Particularmente en esta investigación se evaluará la condición del pavimento mediante el PCI, que, de acuerdo con la norma D6433 (Designation A. S. T. M, 2011), el índice de condición del pavimento (PCI) se define como un valor numérico que refleja la condición del pavimento, variando en una escala de 0 a 100, donde 0 representa la condición más desfavorable y 100 la condición óptima. Este índice, de naturaleza numérica, evalúa la calidad superficial del pavimento al proporcionar una medida de su estado actual, basándose en las fallas observadas en su superficie. Dichas imperfecciones no solo indican la situación presente del pavimento, sino que también dan pistas sobre la integridad estructural y la operatividad de la superficie, incluyendo aspectos como la rugosidad localizada y la seguridad. El monitoreo continuo del PCI es usado para establecer la tasa de deterioro del pavimento, que permite una identificación prematura sobre la necesidad de una rehabilitación mayor.

6.4 Vehículo Aéreo no tripulado

El vehículo aéreo no tripulado (VANT) o del inglés RPAS (Remotely Piloted Aircraft System), de acuerdo con la Unidad Administrativa Especial de Aeronáutica Civil (2018), es una aeronave que es pilotada desde una estación de pilotaje a distancia (la RPAS es controlada de forma remota por un operador ubicado en tierra).


6.5 Redes Neuronales

Según International Business Machines Corporation (IBM, s. f.-a), las redes neuronales intentan imitar el funcionamiento del cerebro humano para resolver problemas de inteligencia

artificial, combinando ciencia de la computación y estadística. Están compuestas por capas de nodos interconectados, incluyendo una capa de entrada, capas ocultas y una capa de salida. Se entrenan con datos para mejorar su precisión y son herramientas poderosas en campos como el reconocimiento de voz e imagen, gracias a su capacidad de procesar información rápidamente. Existen diferentes tipos, como perceptrones, redes neuronales convolucionales (CNN) y recurrentes (RNN), cada una adecuada para tareas específicas como reconocimiento de imágenes o análisis de series temporales.

Figura 3

Redes Neuronales



Nota: tomado de IBM (s. f.-a)

6.6 Redes Neuronales Convolucionales

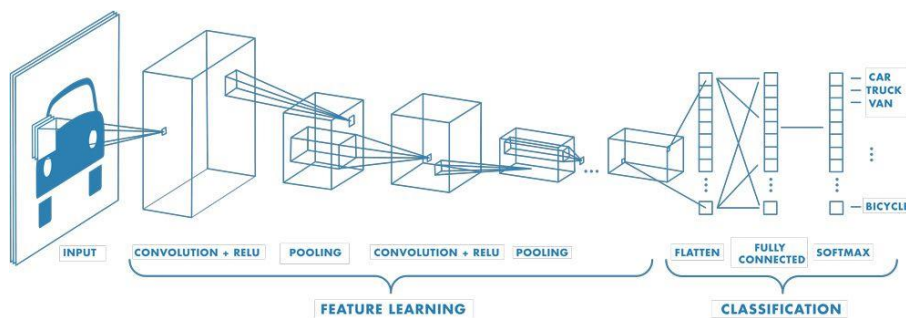
“Una red neuronal convolucional (CNN o ConvNet) es una arquitectura de red para Deep Learning que aprende directamente a partir de datos. Son particularmente útiles para identificar patrones en imágenes con el fin de reconocer objetos, clases y categorías. Además, pueden ser

muy eficaces para clasificar datos de audio, señales y series temporales” (The mathworks, s. f.-b).

Según como lo describe IBM (n.d) una CNN usualmente consta de varias capas que incluyen, las capas convolucionales en donde se aplican filtros para detectar características locales en las imágenes, como bordes o esquinas, las capas de agrupamiento (pooling) las cuales reducen la dimensionalidad de los datos, resumiendo la presencia de características en regiones más grandes y las capas totalmente conectadas que interpretan los datos de las capas convolucionales y de agrupamiento para realizar tareas como la clasificación. El “aprendizaje” en una CNN ocurre durante un proceso llamado entrenamiento, donde la red ajusta los pesos de los filtros para mejorar su capacidad de reconocer patrones y características en nuevos datos de imágenes.

Figura 4

Ejemplo de red con múltiples capas convolucionales



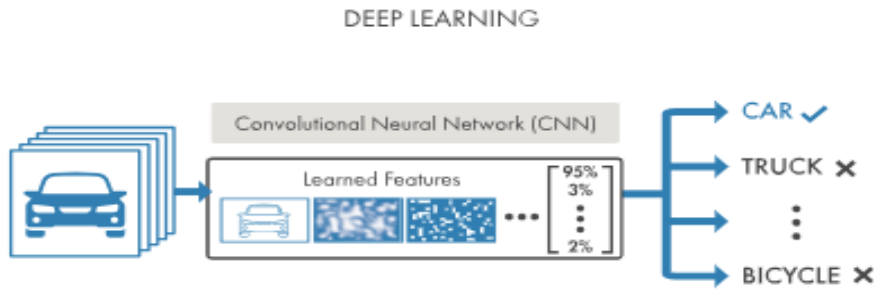
Fuente: tomado de

Fuente: tomado de The mathworks (n.d.-b).

6.7 Deep Learning

“Deep Learning es una rama de Machine Learning que utiliza redes neuronales para enseñar a equipos informáticos a hacer lo que resulta natural para las personas: aprender a partir de ejemplos. Con Deep Learning, un modelo aprende a realizar tareas de clasificación o regresión directamente a partir de datos de imágenes, texto o sonido”(The mathworks, s. f.-a).

El Aprendizaje Profundo (Deep Learning) es un conjunto de técnicas de aprendizaje automático que se basa en redes neuronales profundas para aprender representaciones complejas a partir de los datos de entrada. Estas redes son capaces de capturar relaciones complejas en los datos originales, lo que les permite resolver problemas de clasificación y otras tareas de manera efectiva. A diferencia de los métodos de aprendizaje superficial, el Aprendizaje Profundo utiliza composiciones de funciones para aprender de manera jerárquica, lo que le permite capturar relaciones complejas en los datos originales. Este enfoque ha demostrado ser especialmente efectivo en áreas como la visión computacional, el procesamiento de imágenes y el reconocimiento de patrones. Sin embargo, el Aprendizaje Profundo también presenta limitaciones, como la necesidad de grandes cantidades de datos etiquetados y la susceptibilidad a perturbaciones en los datos de entrada (Ponti & da Costa, 2018).

Figura 5*Representación gráfica Deep Learning**Fuente:*

Fuente: tomado de The mathworks (n.d.-a).

6.8 Detección de objetos con Deep Learning

Según Zhao et al. (2019) la detección de objetos con aprendizaje profundo es un área de investigación que se centra en el desarrollo de métodos para identificar la presencia y la ubicación de objetos en imágenes utilizando algoritmos de aprendizaje profundo, específicamente redes neuronales convolucionales (CNN). Este enfoque es fundamental para la comprensión semántica de imágenes y videos, y tiene aplicaciones en campos como la clasificación de imágenes, el análisis del comportamiento humano, el reconocimiento facial y la conducción autónoma. Los métodos tradicionales de detección de objetos se basaban en características diseñadas manualmente y arquitecturas de aprendizaje poco profundas, pero con el avance del aprendizaje profundo, se han introducido herramientas más robustas que pueden aprender características semánticas complejas de forma más efectiva.

Si bien existe varios algoritmos para detección de objetos, dos algoritmos destacados en este campo son Faster R-CNN y SSD (Single Shot Detector). Estos algoritmos permiten la


detección de objetos mediante la generación de propuestas de regiones y la predicción de coordenadas de cuadros delimitadores y probabilidades de clase en un solo paso (Zhao et al., 2019).

6.8.1 Faster RCNN

Faster R-CNN es un sistema de detección de objetos que consta de dos módulos principales. El primer módulo es una red completamente convolucional que propone regiones, mientras que el segundo módulo es el detector Fast R-CNN que utiliza las regiones propuestas. La innovación clave de Faster R-CNN es el uso de una Red de Propuesta de Región (RPN) que comparte características convolucionales con la red de detección (Ren et al., 2015).

Figura 6

Arquitectura Faster R-CNN



Fuente: tomado de (Ren et al., 2015)

6.8.2 Single Shot Detector (SSD)

SSD es una técnica avanzada en el campo de la visión por computadora para la detección de objetos en imágenes. Utiliza una red neuronal profunda para identificar y localizar objetos de manera eficiente, donde, genera cajas que señalan la ubicación de los objetos, a su vez, asigna puntajes a la presencia de clases de objetos y filtra las cajas para determinar las detecciones finales, ofreciendo resultados rápidos y precisos sin etapas adicionales (Wei et al., 2016).

7. Hipótesis de investigación

El uso del vehículo aéreo no tripulado y las técnicas avanzadas de detección de objetos, como Single Shot Detector (SSD) y Faster R-CNN, combinado con la evaluación del Índice de Condición de Pavimento (PCI), permitirá una identificación precisa y cuantificación del deterioro en pavimentos asfálticos. Se espera que esta metodología proporcione una solución eficiente y rentable para la evaluación del estado de las vías, superando las limitaciones de métodos convencionales.

8. Metodología

8.1 Enfoque metodológico

La presente investigación adopta un enfoque metodológico cuantitativo con el propósito de analizar y evaluar el deterioro del pavimento asfáltico. La variable independiente en este estudio es la aplicación de tecnologías de información geográfica y aprendizaje profundo mediante el uso de vehículo aéreo no tripulado, junto con algoritmos de detección de objetos y segmentación. Estas herramientas tecnológicas permitirán la captura de imágenes y el procesamiento de estas para identificar y cuantificar el deterioro en la capa asfáltica. La variable dependiente principal es el Índice de Condición de Pavimento (PCI), el cual será calculado y utilizado como indicador cuantitativo para evaluar la condición del pavimento asfáltico.

8.2 Tipo de estudio

La naturaleza de la investigación propuesta sugiere un enfoque principalmente descriptivo, ya que se busca caracterizar y evaluar el deterioro del pavimento asfáltico mediante la aplicación del Índice de Condición de Pavimento (PCI) con el uso de tecnologías específicas, como el vehículo aéreo no tripulado y algoritmos de detección de objetos.

8.3 Diseño de la investigación

Considerando lo mencionado por Agudelo Viana & Aigner Aburto (2008), el diseño de la investigación corresponde a no experimental, ya que se observan situaciones ya existentes, no provocadas intencionalmente por el investigador.

8.4 Unidad de trabajo

La unidad de trabajo comprende a un tramo vial específico dentro del municipio de Paipa denominado: Tramo en la Calle 23 entre la Carrera 17 y la Carrera 17ª, la cual corresponde a una vía habilitada para el tránsito en dos direcciones (un carril por dirección), con un ancho de 6m y una longitud aproximada de 100m.

El objetivo es detectar el tipo de daño presente en el tramo mediante técnicas de aprendizaje profundo y calcular posteriormente su Índice de Condición de Pavimento (PCI).

8.5 Muestra y muestreo

Para evaluar el deterioro del pavimento asfáltico en los tramos viales seleccionados en Paipa, se llevará a cabo un muestreo sistemático de los tramos identificados. Este muestreo se realizará mediante vuelos de dron sobre las vías descritas en la unidad de trabajo.

En cuanto al entrenamiento de modelos, se utilizarán algoritmos de detección de objetos, los cuales serán entrenados y validados con conjuntos de datos previamente recopilados de fuentes secundarias y primarias. Estos conjuntos de datos contendrán imágenes etiquetadas con diferentes tipos de deterioro del pavimento.

8.6 Operacionalización de variables

la operacionalización de variables comienza con la recolección de imágenes etiquetadas que representan diferentes clases de deterioro del pavimento asfáltico. Estas imágenes proporcionan una representación visual de los diversos tipos de daños que pueden ocurrir en el pavimento, como grietas, huecos, piel de cocodrilo y reparaciones.

8.7 Técnicas e instrumentos de recolección de información

La recolección de información se llevó a cabo utilizando dos enfoques. En primer lugar, se recurrió a fuentes de información secundaria, que consistieron en imágenes previamente etiquetadas en relación con el estudio. En segundo lugar, se empleó información primaria obtenida a través de vuelos realizados específicamente para este estudio y que fueron etiquetados según las categorías de daño establecidas.

La combinación de estos enfoques de recolección de información proporcionó una base sólida para el análisis y la evaluación del deterioro del pavimento asfáltico en el contexto del estudio. Además, garantizó la disponibilidad de datos relevantes y actualizados.

8.8 Desarrollo metodológico

8.8.1 Definición del tipo de daño a estudiar

Si bien en la sección 6.2 se describen los diferentes tipos de daños en el pavimento asfáltico según el Ministerio de Transporte, 2006), en este estudio, se ha enfatizado en 6 clases, debido a su relevancia y representatividad en el contexto del deterioro del pavimento, así como su impacto significativo en la seguridad y durabilidad de la infraestructura vial. Los tipos de daños a analizar son:

1. Fisuras:
 - 1.1. Fisuras Longitudinales (Longitudinal crack)
 - 1.2. Fisuras Transversales (Transverse crack)
 - 1.3. Fisuras oblicuas (Oblique crack)
 - 1.4. Piel de Cocodrilo (Alligator crack)
2. Pérdida de capas estructurales y daños superficiales
 - 2.1. Baches o huecos (Pothole)

2.2. Parche o reparaciones (Repair)

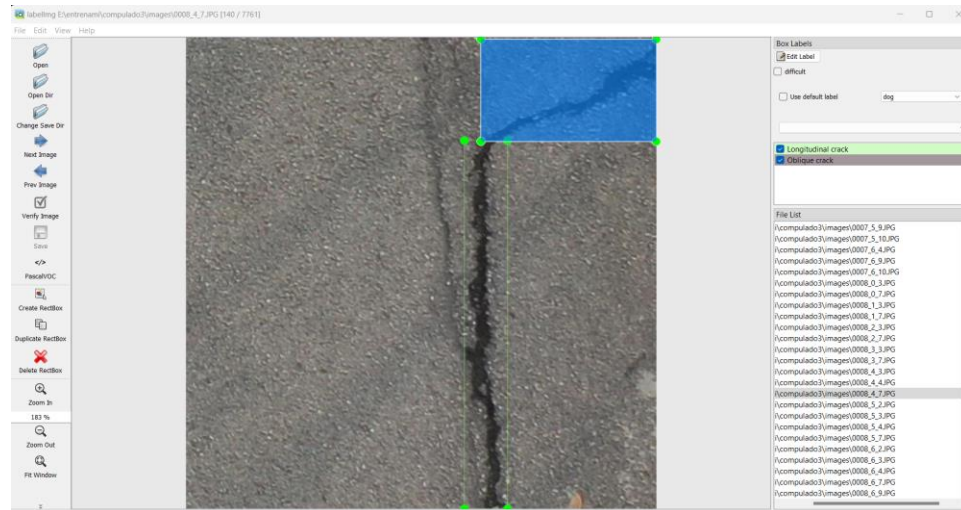
8.8.2 Datasets de entrenamiento de fuentes secundarias y primarias

Se obtuvo datasets de tres fuentes principales, tal como se detalla a continuación:

El primer dataset, denominado AUDP (Zhu et al., 2022), con un total de 3.151 imágenes debidamente etiquetadas, de este, se utilizó un total de 3.147 imágenes.

El segundo dataset, obtenido del Road Damage Detection Challenge (Arya et al., 2022), con un total de 47.420 imágenes, de las cuales 4.375 imágenes cuentan con las categorías requeridas y, por ende, son las utilizadas para el estudio.

El tercer dataset, con un total de 240 imágenes, obtenidas mediante los vuelos realizados para el estudio, en donde fue necesario la planeación del vuelo, realización del vuelo y etiquetado de las imágenes capturadas por medio del software libre labelImg (figura 7) el cual permite etiquetar en formato PASCAL VOC (requerido por los algoritmos de detección), según tipo de deterioro definidos.

Figura 7*Software LabelImg para etiquetado del deterioro*

Fuente: elaboración propia

Como se mencionó anteriormente, para los datos de fuente primaria, inicialmente se debe realizar la etapa de planeación, en donde es necesario establecer la altura de vuelo adecuada, particularmente se debe considerar que el objetivo es obtener una resolución inferior a 2 cm/pixel, para ello, se debe tener en cuenta los parámetros de la cámara del RPA, para el cálculo del GSD en función de la altura, a continuación, se presenta los parámetros de la cámara Autel Evo 2 pro:

- Ancho del sensor de la cámara (mm) Sw: 13,138
- Distancia focal de la cámara (mm) FR: 10,57
- Ancho de la imagen(pixels) imW: 5472
- Altura de imagen (pixels) imH: 3648

Considerando lo anterior, para el cálculo del GSD se tiene la siguiente ecuación (Pix4D, 2019):

$$GSD = \frac{Sw * Altura Vuelo * 100}{FR * imH}$$

Donde, la altura de vuelo se toma variable hasta obtener el valor deseado, en la siguiente tabla se presenta las alturas de vuelo utilizadas en los diferentes vuelos realizados para el estudio, en donde se evidencia que para obtener resolución inferior a 2 cm/pixel es necesario realizar el vuelo a alturas menores o iguales a 80 metros.

Tabla 1

GSD según altura de vuelo

Altura de Vuelo (m)	GSD (cm/pixel)
10	0,23
15	0,34
20	0,45
40	0,91
80	1,82

Nota: Fuente Elaboración propia

8.8.3 Estandarización de Datasets de entrenamiento

El dataset Road Damage Detection Challenge(Arya et al., 2022), cuenta con las siguientes clases, en donde, el “Nombre de la clase” corresponde al valor de etiquetado en las imágenes.

Tabla 2*Clases de deterioro presentes en el dataset 2022*

Tipo de daño		Detalle	Nombre de la clase
Fisuras	Lineales	Parte de la marca de la rueda	D00
		Parte de la junta de construcción	D01
	Transversales	Intervalo igual	D10
		Parte de la junta de construcción	D11
	Fisura de cocodrilo	Pavimento parcial, pavimento total	D20
		Surcos, bache, hoyo, separación	D40
	Otros daños	Desgaste en el paso de peatones	D43
		Desgaste en la línea blanca	D44

Nota: Tomado y adaptado de Arya et al. (2022)

Por otro lado, el dataset AUDP (Zhu et al., 2022), se encuentra etiquetado en las siguientes clases:

Tabla 3*Etiquetado del dataset AUDP*

Nombre de la clase
Transverse crack
Longitudinal crack
Oblique crack
Alligator crack
Repair
Pothole

Nota: Tomado de Zhu et al. (2022)

Como se observa, si bien tienen relación las descripciones de los datasets, el etiquetado es diferente, por lo tanto, es necesario llevar las etiquetas a un solo estándar antes de iniciar el entrenamiento, para ello, se definió el siguiente estándar de etiquetado:

- Transverse crack
- Longitudinal crack
- Oblique crack
- Alligator crack
- Repair
- Pothole

Para ajustar las etiquetas presentadas en la tabla 2, es necesario considerar su correspondencia con el estándar de etiquetado establecido para el estudio, dando como resultado lo siguiente:

Tabla 4

Estandarización de etiquetas

Nombre de clase a ajustar	Clase objetivo
D00	Longitudinal crack
D10	Transverse crack
D20	Alligator crack
D40	Pothole
Repair	Repair
	Oblique crack

Nota: Elaboración Propia

Cabe resaltar que aquellas etiquetas e imágenes que corresponden a categorías de deterioro diferentes a las que son objeto de análisis, no se consideran.

Ahora bien, dado el número de etiquetas por modificar, se realizó el siguiente código en Python para el ajuste masivo de clases:

Figura 8

Código para estandarización de clases

```
import os
import xml.etree.ElementTree as ET

def realizar_cambios_nombres_xml(ruta_carpeta):
    # Recorre todos los archivos en la carpeta
    for archivo in os.listdir(ruta_carpeta):
        if archivo.endswith('.xml'):
            ruta_xml = os.path.join(ruta_carpeta, archivo)
            # Parsea el archivo XML
            arbol = ET.parse(ruta_xml)
            raiz = arbol.getroot()

            # Busca todas las etiquetas <name> y realiza los cambios de nombre según las reglas
            for etiqueta_nombre in raiz.findall('./name'):
                clase = etiqueta_nombre.text
                if clase == 'D10':
                    etiqueta_nombre.text = 'Transverse crack'
                elif clase == 'D00':
                    etiqueta_nombre.text = 'Longitudinal crack'
                elif clase == 'D20':
                    etiqueta_nombre.text = 'Alligator crack'
                elif clase == 'D40':
                    etiqueta_nombre.text = 'Pothole'

            # Guarda los cambios en el archivo XML
            arbol.write(ruta_xml)

# Ruta de la carpeta que contiene los archivos XML
ruta_carpeta = input("Ingrese la ruta de la carpeta que contiene los archivos XML: ")

# Realizar los cambios de nombre en los archivos XML
realizar_cambios_nombres_xml(ruta_carpeta)

print("Cambios de nombre realizados en los archivos XML.")
```

Fuente: elaboración propia

Ajustada las clases en los datasets obtenidos de fuentes externas, se proceder a estandarizar las imágenes capturadas con el vehículo aéreo no tripulado para su posterior etiquetado, para ello, se realizó un paneo al 100% de cada zona de la imagen y se redimensionó a 512x512 de tal forma que fuese acorde con los demás datos de entrenamiento, el código generado para lograr esto es el siguiente:

Figura 9

Estandarización de imágenes del estudio para etiquetado

```

import os
from PIL import Image
import glob

def aplicar_zoom_y_redimensionar(ruta_carpeta_entrada, ruta_carpeta_salida, tamaño_nuevo=(512, 512)):
    # Verificar si la carpeta de salida existe, si no, crearla
    if not os.path.exists(ruta_carpeta_salida):
        os.makedirs(ruta_carpeta_salida)

    # Obtener la lista de archivos de imagen en la carpeta de entrada
    archivos_imagen = glob.glob(os.path.join(ruta_carpeta_entrada, '*.jpg')) + \
        glob.glob(os.path.join(ruta_carpeta_entrada, '*.png')) + \
        glob.glob(os.path.join(ruta_carpeta_entrada, '*.jpeg')) + \
        glob.glob(os.path.join(ruta_carpeta_entrada, '*.gif'))

    # Contador para mantener el nombre único de cada sección de imagen
    contador = 0

    # Recorrer todos los archivos de imagen
    for archivo in archivos_imagen:
        # Abrir la imagen
        imagen = Image.open(archivo)
        # Calcular el número de partes en que se dividirá la imagen
        num_partes_x = imagen.width // tamaño_nuevo[0]
        num_partes_y = imagen.height // tamaño_nuevo[1]

        # Recorrer todas las partes de la imagen y aplicar zoom y redimensionamiento
        for i in range(num_partes_x):
            for j in range(num_partes_y):
                # Calcular las coordenadas de la parte actual
                left = i * tamaño_nuevo[0]
                top = j * tamaño_nuevo[1]
                right = left + tamaño_nuevo[0]
                bottom = top + tamaño_nuevo[1]

                # Recortar la parte de la imagen
                parte_imagen = imagen.crop((left, top, right, bottom))
                # Redimensionar la parte de la imagen
                parte_redimensionada = parte_imagen.resize(tamaño_nuevo, Image.BICUBIC)
                # Generar el nombre de archivo único para la parte de la imagen
                nombre_archivo = f"{os.path.splitext(os.path.basename(archivo))[0]}_{contador}.jpg"
                contador += 1

                # Guardar la parte de la imagen en la carpeta de salida
                ruta_salida = os.path.join(ruta_carpeta_salida, nombre_archivo)
                print("Guardando imagen en:", ruta_salida) # Para depurar, imprime la ruta de salida
                parte_redimensionada.save(ruta_salida)

    # Ruta de la carpeta que contiene las imágenes originales
    ruta_carpeta_entrada = input("Ingrese la ruta de la carpeta que contiene las imágenes originales: ")
    # Ruta de la carpeta de salida para las imágenes modificadas
    ruta_carpeta_salida = input("Ingrese la ruta de la carpeta de salida para las imágenes modificadas: ")

    # Aplicar zoom y redimensionar las imágenes
    aplicar_zoom_y_redimensionar(ruta_carpeta_entrada, ruta_carpeta_salida)

```

Fuente: elaboración propia

Una vez realizado el ajuste de clases en los diferentes datasets y etiquetado en la información del estudio, es necesario verificar que todas las etiquetas tengan asociada su imagen y toda imagen tenga asociada su etiqueta, de encontrarse algún archivo faltante se genera la etiqueta o se procede a eliminar el archivo sin correspondencia, para ello se generó el siguiente código:

Figura 10

Verificación de correspondencia entre imágenes y etiquetas

```
import os

# Solicitar las rutas de las carpetas que contienen las imágenes y los XML
ruta_imagenes = input("Ingrese la ruta de la carpeta que contiene las imágenes: ")
ruta_xml = input("Ingrese la ruta de la carpeta que contiene los archivos XML: ")

# Obtener listas de nombres de archivos en las carpetas de imágenes y XML
archivos_imagenes = set([os.path.splitext(f)[0] for f in os.listdir(ruta_imagenes)])
archivos_xml = set([os.path.splitext(f)[0] for f in os.listdir(ruta_xml)])

# Encontrar imágenes sin XML asociado
imagenes_sin_xml = archivos_imagenes - archivos_xml

# Encontrar XML sin imagen asociada
xml_sin_imagen = archivos_xml - archivos_imagenes

# Mostrar resultados
print("Imágenes sin XML asociado:")
for imagen in imagenes_sin_xml:
    print(imagen)

print("\nXML sin imagen asociada:")
for xml in xml_sin_imagen:
    print(xml)
```

Fuente: elaboración propia

Hecho lo anterior, se procede a verificar las clases presentes en el dataset final y el número de etiquetas por clase, tal forma que se pueda inferir un adecuado balance en los datos y que no existan clases diferentes al objeto de análisis, para ello, se generó el siguiente código:

Figura 11

Numero de etiquetas por clase

```
def contar_clases_en_xml(ruta_carpeta):
    clases = {}

    # Recorre todos los archivos en la carpeta
    for archivo in os.listdir(ruta_carpeta):
        if archivo.endswith('.xml'):
            # Parsea el archivo XML
            arbol = ET.parse(os.path.join(ruta_carpeta, archivo))
            raiz = arbol.getroot()

            # Busca todas las etiquetas <name> y cuenta las ocurrencias de cada clase
            for etiqueta_nombre in raiz.findall('.//name'):
                clase = etiqueta_nombre.text
                if clase in clases:
                    clases[clase].append(archivo)
                else:
                    clases[clase] = [archivo]

    return clases

def contar_clases_en_xml_conteo(ruta_carpeta):
    clases = {}

    # Recorre todos los archivos en la carpeta
    for archivo in os.listdir(ruta_carpeta):
        if archivo.endswith('.xml'):
            # Parsea el archivo XML
            arbol = ET.parse(os.path.join(ruta_carpeta, archivo))
            raiz = arbol.getroot()

            # Busca todas las etiquetas <name> y cuenta las ocurrencias de cada clase
            for etiqueta_nombre in raiz.findall('.//name'):
                clase = etiqueta_nombre.text
                if clase in clases:
                    clases[clase] += 1
                else:
                    clases[clase] = 1

    return clases

# Ruta de la carpeta que contiene los archivos XML
ruta_carpeta = input("Ingrese la ruta de la carpeta que contiene los archivos XML: ")

# Obtener las clases y los nombres de los archivos asociados
clases = contar_clases_en_xml(ruta_carpeta)
conteo_clases = contar_clases_en_xml_conteo(ruta_carpeta)

# Crear un nuevo libro de Excel
libro_excel = Workbook()

# Crear una hoja para las clases y sus archivos asociados
hoja_clases_archivos = libro_excel.active
hoja_clases_archivos.title = "Clases y Archivos XML"
```

Fuente: elaboración propia

En la siguiente tabla se presenta el resultado del código anterior el cual muestra el número de veces en que una clase ha sido etiquetada, esto a su vez equivale a una muestra para entrenamiento y/o validación.

Tabla 5*Clases y número total de muestras (etiquetas)*

Clase	Cantidad de muestras (etiquetas)	Imágenes dataset
Longitudinal crack	5609	
Transverse crack	3756	
Alligator crack	1448	
Oblique crack	216	7.761
Repair	2680	
Pothole	489	
Total	14.198	7.761

Nota: Elaboración propia

Como se observa en la tabla anterior, las clases Oblique crack y Pothole tienen menor cantidad de etiquetas, por lo que se espera que el porcentaje de precisión promedio en el entrenamiento sea inferior a las demás clases.

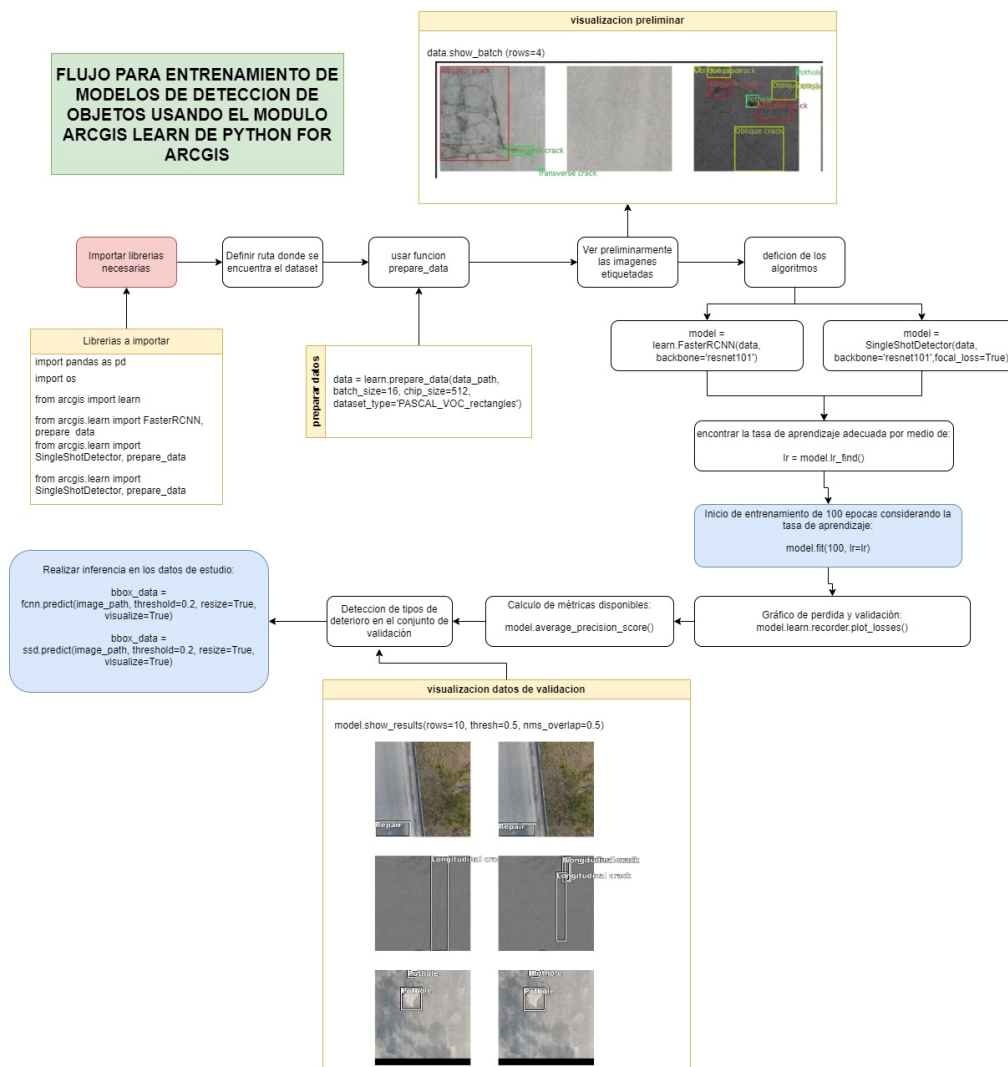
8.9 Entrenamiento del dataset empleando algoritmos de detección de objetos

Con los datos estandarizados, se llevó a cabo el entrenamiento utilizando algoritmos de detección de objetos. Este estudio se centró en los modelos Faster RCNN y Single Shot Detector (SSD) bajo la arquitectura de Red Neuronal Convolutiva ResNet 101, para ello, se crearon dos notebooks donde se desarrolló la lógica de estos modelos con ayuda del módulo de Arcgis Learn, permitiendo su ejecución adecuada en ArcGIS Online Notebooks con soporte GPU.

En la siguiente figura se presenta el flujo de entrenamiento que aplica para ambos algoritmos:

Figura 12

Flujo para entrenamiento



Fuente: elaboración propia

Dentro del flujo presentado anteriormente, se evidencia que antes de iniciar el entrenamiento se deben preparar los datos por medio de la función `prepare_data`, cabe resaltar que esta realiza la separación de los datos para obtener un dataset de entrenamiento y otro de

validación, particularmente con nuestros datos de entrada, se obtuvo el siguiente número de muestras para entrenamiento:

Tabla 6

Número de Imágenes para entrenamiento

Tipo de deterioro	Imágenes por clase
Longitudinal crack	5019
Transverse crack	3363
Alligator crack	1324
Oblique crack	196
Repair	2392
Pothole	430
Total	12724

Nota: Elaboración Propia

Ahora bien, es necesario determinar en los algoritmos de detección, la tasa de aprendizaje óptima, la cual corresponde a un hiperparámetro que “controla cuanto estamos ajustando los pesos de nuestra red con respecto al gradiente de pérdidas” (Hafidz, 2018), por lo tanto, entre menor es este valor, se puede conducir a un entrenamiento más lento del modelo, particularmente, ArcGIS.learn permite determinar la tasa de aprendizaje óptima por medio de la función `lr_find()`, para nuestro dataset de entrenamiento, se tuvo lo siguiente:

Tabla 7

Tasas de aprendizaje obtenidas

Algoritmo	Tasa de aprendizaje
SSD	0,0030199517204020187
Faster R-CNN	0,0000758577575029183

Nota: Elaboración propia

Seguidamente, se procede a entrenar el modelo por medio de la función $\text{fit}()$, en donde se definió 100 épocas de entrenamiento y una tasa de aprendizaje obtenida en la tabla 6, los resultados se presentan en el capítulo 9.


8.10 Detección de tipos de deterioro en las vías de estudio

Considerando lo mencionado en el literal 8.8.2, cabe resaltar que la planeación y ejecución de vuelo para captura de imágenes con el vehículo aéreo no tripulado, no solo se realizó para alimentar el dataset de entrenamiento, sino que también se realizó la planeación y captura de imágenes para el tramo objeto de estudio.

Una vez finalizada la misión en campo, se procede a realizar el postproceso de las imágenes capturadas con el fin de generar la ortofoto que será empleada para análisis en el modelo de detección generado.

Figura 13

Procesamiento de imágenes capturadas con vehículo aéreo no tripulado



Fuente: elaboración propia a partir del software de procesamiento.

Ahora bien, según los resultados obtenidos en los diferentes algoritmos de detección de objetos, se elige el modelo con mejor comportamiento para la detección del deterioro del pavimento de tal forma que sea posible inferir adecuadamente sobre las imágenes objeto de análisis.

La inferencia se realiza desde ArcGIS Pro empleando el archivo de Deep learning package (dlpk) o EMD (Esri Model Definition file) generado en el proceso de entrenamiento y validación, en la siguiente figura, se presenta un ejemplo sobre la herramienta “Detect Objects Using Deep Learning” la cual permite ingresar el archivo dlpk y proceder con la detección de los tipos de deterioro.

Figura 14

Inferencia en ArcGIS PRO para detección de objetos



Fuente: elaboración propia a partir del software GIS.

Una vez se realice la inferencia, el resultado obtenido será unos cuadros delimitadores que contiene la clase de deterioro del pavimento, en el capítulo 9 se presenta los resultados.

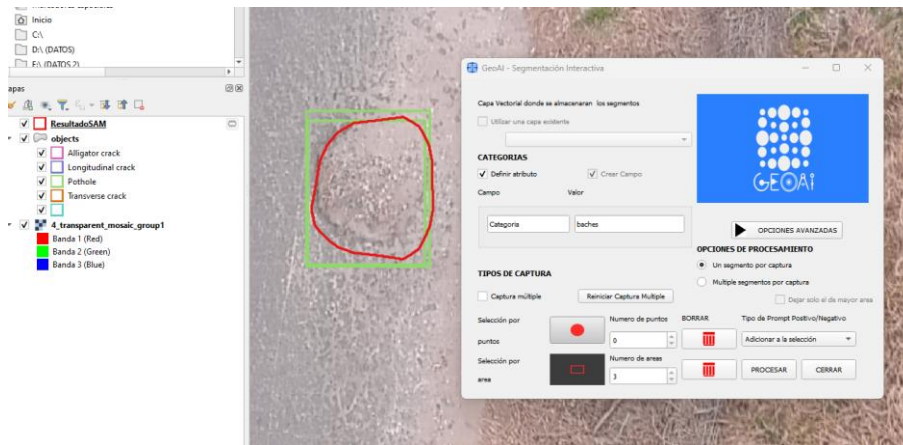
8.11 Cálculo PCI

Establecido los tipos de daños en el pavimento, se procede a realizar la segmentación de las clases por medio de modelos preentrenados disponibles en Living Atlas de ESRI como Pavement Crack Detection (modelo enfocado en fisuras) para ArcGIS Pro (ESRI, s. f.-a) y GeoAI Plugin para QGIS creado por Perez Graterol (2024), el cual, considerando su base en Segment Anything Model (SAM), se abordará para la extracción de geometría de baches.

Para GeoAI (2024), se toma como datos de entrada los delimitadores obtenidos en el proceso de detección y se selecciona “segmentación interactiva” para extraer la geometría, el cual da como resultado un polígono del bache, así:

Figura 15

Método para cuantificación de baches

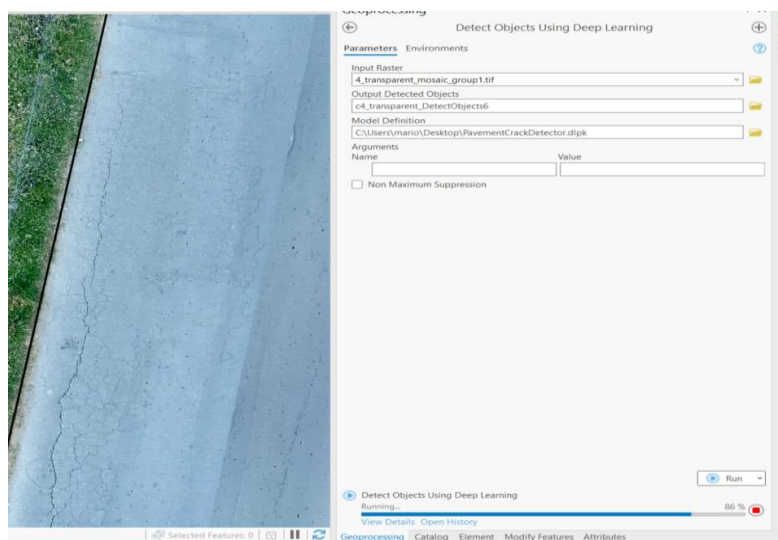


Fuente: elaboración propia

Para la cuantificación de las grietas, se debe tomar como referencia los delimitadores obtenidos y proceder a ingresar el modelo preentrenado “Pavement crack detector” en la herramienta de detección de objetos de ArcGIS Pro.

Figura 16

Método cuantificación de fisuras



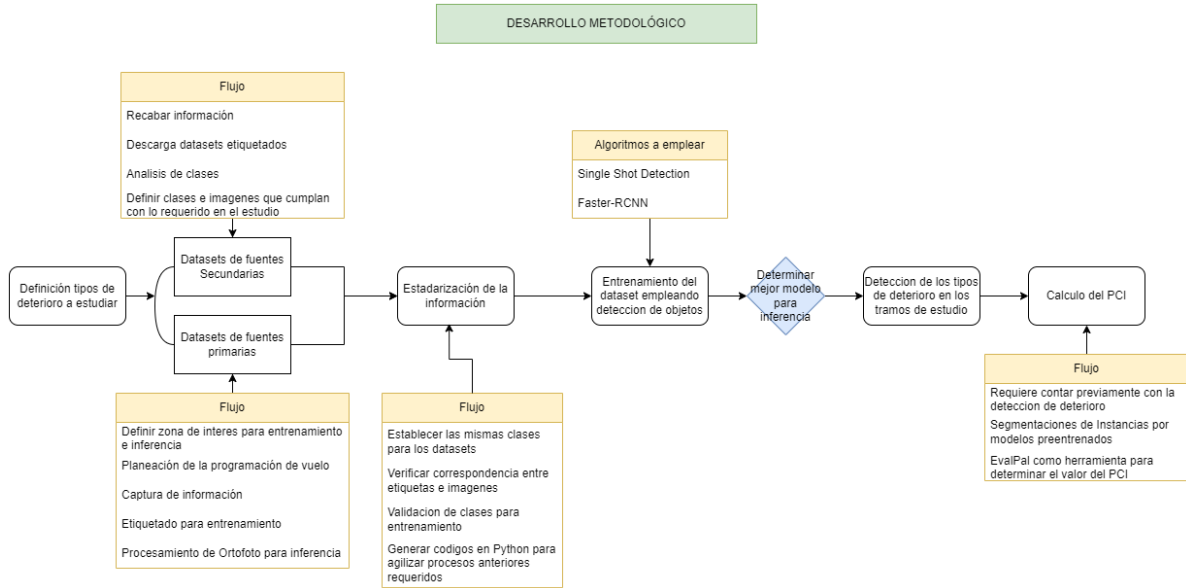
Fuente: elaboración propia

Una vez extraída la geometría de las diferentes clases presentes en los tramos de análisis se procede a incluir los datos obtenidos del proceso detección y extracción al software EVALPAL (Ministerio de Transportes y comunicaciones de Perú, 2020) y se determina el valor del PCI para el tramo de análisis.

En la siguiente figura se sintetiza el desarrollo metodológico descrito en el capítulo 8.

Figura 17

Desarrollo metodológico



Fuente: elaboración propia

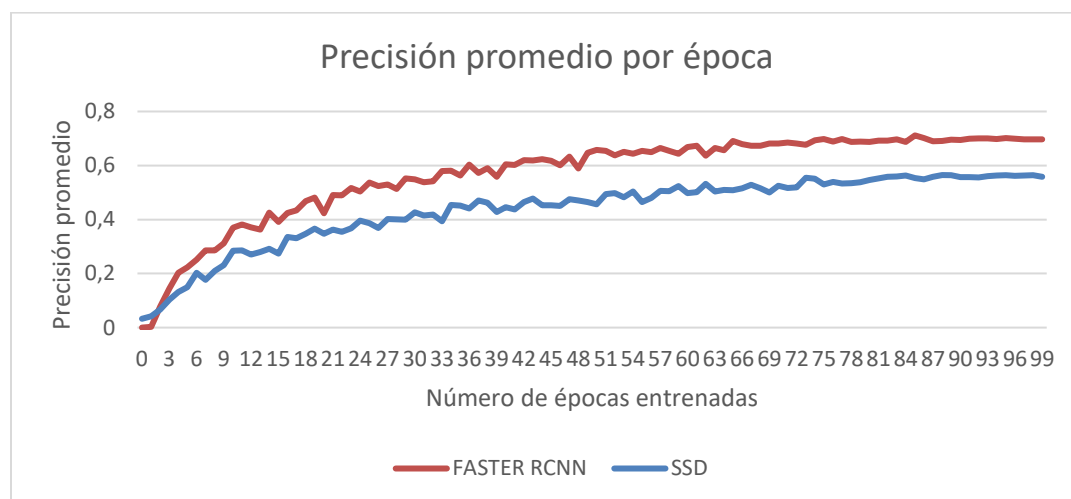
9. Discusión y Resultados

9.1.1 Resultado 1: Detección de los tipos de deterioro del pavimento asfáltico en el área de estudio

Una vez finalice el entrenamiento de Faster R-CNN y SSD, es posible analizar el comportamiento que tuvo el algoritmo en cada época, considerando el tiempo y precisión promedio, esto es importante ya que proporcionará una base para comparar el tiempo de entrenamiento con la adición de más datos en caso de requerirse la afinación del modelo.

Figura 18

Precisión promedio por época



Fuente: elaboración propia


De acuerdo con la figura anterior, se muestra que ambos modelos mejoran su precisión a medida que se entrenan más épocas. Sin embargo, en todas las épocas, Faster R-CNN tiene una mayor precisión en comparación con SSD lo que implica que tiene un mejor comportamiento de aprendizaje, obteniendo según la diferencia de precisión promedio, una mejora del 13%, sin

embargo, esta mejora implica mayor tiempo de procesamiento, en donde el promedio por época para Faster RCNN fue de 6,1 minutos para un total de 10,16 horas, mientras que para SSD fue de 4,55 minutos para un total de 7,58 horas (tiempos obtenidos desde ArcGIS Notebook con soporte GPU).

En las siguientes figuras, se presenta el gráfico de pérdidas (tasa de error) de entrenamiento y validación, en donde se puede evidenciar que las pérdidas en ambos dataset disminuyen, por lo tanto, indica que el modelo está aprendiendo a reconocer los tipos de deterioro del pavimento asfáltico.

Figura 19

Gráfico de pérdidas para SSD




Fuente: elaboración propia a partir del entrenamiento del modelo.

La convergencia de ambas líneas sugiere que el modelo está generalizando bien y no está sobreajustando, ya que la pérdida de validación sigue una tendencia similar a la de entrenamiento.

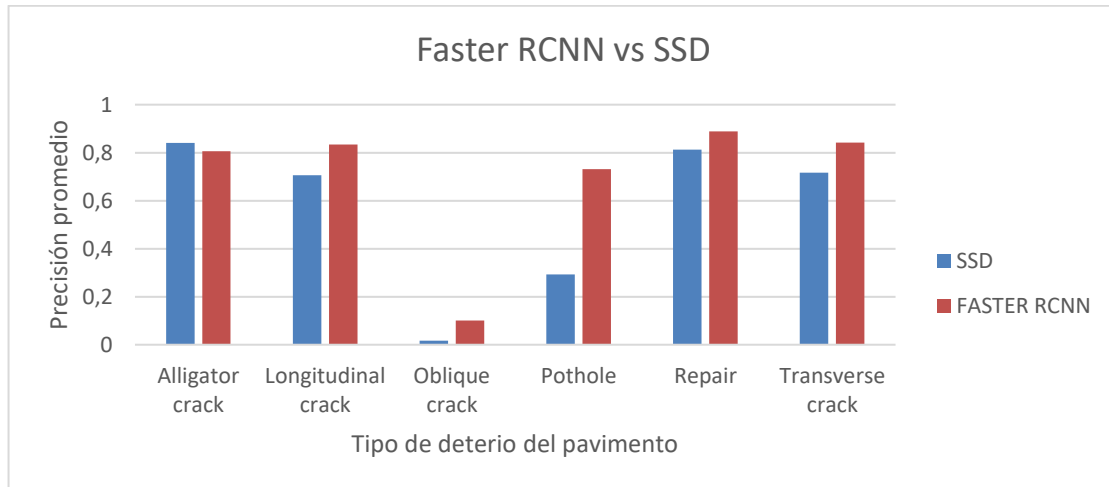
Figura 20

Gráfico de pérdidas para Faster RCNN



Fuente: elaboración propia a partir del entrenamiento del modelo

Hasta el momento se ha revisado la información general de los modelos, ahora, en la siguiente figura se presenta la comparación de la precisión promedio por tipo de daño que arroja como resultado cada algoritmo.

Figura 21*Precisión promedio por modelo de detección de objetos*

Fuente: elaboración propia a partir del entrenamiento del modelo

De la figura anterior, se observa que Single Shot Detector tuvo mayor precisión al detectar el tipo de deterioro Alligator crack (84%) que Faster RCNN (80%), sin embargo, en el resto de las clases Faster R-CNN tuvo un mejor comportamiento, obteniendo la mayor diferencia en la clase Pothol donde Faster RCNN logró una precisión del 73% y SSD tan solo del 29%, cabe resaltar que esta categoría corresponde a una de las clases con menor número de etiquetas en el dataset, en la siguiente tabla se presenta los valores de precisión por cada clase de deterioro:

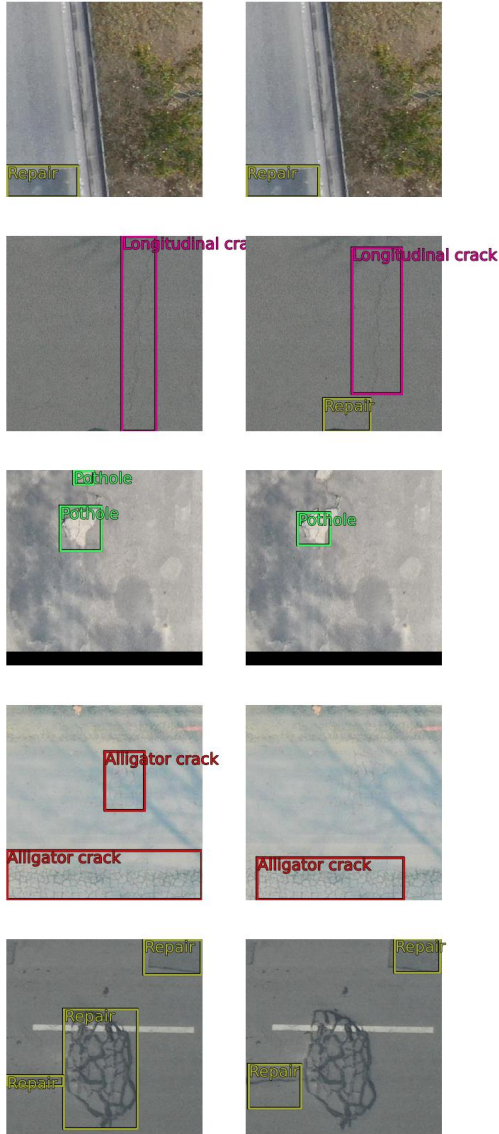

Tabla 8*Precisión promedio por modelo de detección de objetos*

Tipo de deterioro	Precisión Promedio SSD	Precisión Promedio Faster R-CNN
Alligator crack	0,840	0,806
Longitudinal crack	0,706	0,834

Tipo de deterioro	Precisión Promedio SSD	Precisión Promedio Faster R-CNN
Oblique crack	0,017	0,101
Pothole	0,292	0,732
Repair	0,813	0,889
Transverse crack	0,716	0,842

Fuente: elaboración propia a partir del entrenamiento del modelo

Por otro lado, además de las métricas cuantitativas vistas anteriormente, es importante realizar un análisis cualitativo de los resultados. Se procede a revisar manualmente algunas predicciones realizadas por cada modelo en imágenes de validación para evaluar la precisión y la calidad de las detecciones.

Figura 23*Predicciones SSD***Figura 22***Predicciones Faster RCNN*

Considerando lo anterior, el modelo entrenado y generado con el algoritmo de detección de objetos Faster R-CNN, tuvo mayor precisión para la detección de los tipos de daño presentes en las vías con pavimento asfáltico, por lo que se realizó la inferencia con dicho modelo sobre

los datos de análisis. En la siguiente figura, se presenta un acercamiento sobre uno de los resultados en donde se evidencia la clase detectada y su porcentaje de confiabilidad.

Figura 24

Ejemplo resultado de inferencia



Fuente: elaboración propia

A continuación, se presenta la localización de los tipos de deterioro detectados en el tramo de análisis, cabe resaltar que la inferencia tardó 8 minutos:

Figura 25

Localización de las clases de deterioro detectadas por el modelo entrenado



Fuente: elaboración propia

9.1.2 Resultado 2: Cuantificación del tipo de deterioro detectado

Tal como se mencionó en el literal 8.11, por medio de Qgis y ArcGIS Pro, se cuantificó los deterioros en la superficie asfáltica, sin embargo, es necesario resaltar que aún se requiere realizar una revisión manual de calidad de los resultados obtenidos, en ocasiones se presenta desplazamiento de la geometría del bache y en cuanto a fisuras, el modelo preentrenado no

extrae la totalidad de fisuras transversales y longitudinales, por ende es importante contar con los delimitadores generados en la detección de las clases de deterioro para no excluirlas.

Considerando el área mínima y máxima de muestreo en la norma ASTM D6433 (Designation A. S. T. M, 2011), el área de análisis se dividió en dos subtramos de norte a sur, el primero con una longitud de 33 metros y ancho de 6m, correspondiente a un área de muestra de 198m², el segundo con una longitud de 48metros y ancho 6m, equivalente a un área de muestra de 288 m², continuación, se presenta la cuantificación de las clases del deterioro, necesarias para determinar el PCI:

Tabla 9

Cuantificación para PCI del deterioro del pavimento asfáltico

SUBTRAMO	TIPO	SEVERIDAD	X	Y	LONGITUD m	ANCHO m	AREA m ²
1	PIEL DE COCODRILO GRIETAS	MEDIA	0,5 9	3,3	5	1,24	6,2
	LONGITUDINALE S Y TRANSVERSALES GRIETAS	ALTA	0,4 1	1,61	14,32	0	14,3
	LONGITUDINALE S Y TRANSVERSALES GRIETAS	BAJA	4,1 7	10,2 2	56	0	56
	LONGITUDINALE S Y TRANSVERSALES GRIETAS	BAJA	377	2,28	0,49	0	0,49
	LONGITUDINALE S Y TRANSVERSALES GRIETAS	BAJA	3,9 6	2,19	0,90	0	0,9
	TRANSVERSALES GRIETAS LONGITUDINALE	BAJA	3.8 7	4,19	0,31	0	0,31

SUBTRAMO	TIPO	SEVERIDAD	X	Y	LONGITUD m	ANCHO m	AREA m ²
	S Y						
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	BAJA	3,8	4,2	0,212	0	0,21
	S Y		7				
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	BAJA	3,8	4,78	0,479	0	0,48
	S Y		7				
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	BAJA	4,2	9,06	0,819	0	0,82
	S Y		9				
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	BAJA	4,3	9,66	49	0	49
	S Y		1				
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	BAJA	322	16,7	1,71	0	1,71
	S Y						
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	BAJA	397	18	0,72	0	0,72
	S Y						
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	BAJA	3,3	19,7	1,3	0	1,3
	S Y		7	4			
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	BAJA	3,2	21,8	1,17	0	1,17
	S Y		4	6			
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	BAJA	1,5	30,1	0,65	0	0,65
	S Y			8			
	TRANSVERSALES						
	GRIETAS						
	LONGITUDINALE	MEDIA	3,6	1,67	1,747	0	1,75
	S Y		7				
	TRANSVERSALES						

SUBTRAMO	TIPO	SEVERIDAD	X	Y	LONGITUD m	ANCHO m	AREA m ²
2	GRIETAS LONGITUDINALE S Y	MEDIA	3,0 2	18,3 4	1,79	0	1,79
	TRANSVERSALES GRIETAS LONGITUDINALE S Y	MEDIA	0,4 1	0,87	0,66	0	0,66
	TRANSVERSALES GRIETAS LONGITUDINALE S Y	MEDIA	4,8 6	11	5	0	5
	TRANSVERSALES BACHE	MEDIA	4,6 5	31,8 1	0,74	61	3
	PIEL DE COCODRILO	MEDIA	4,2	0,22	2,68	0,8	2,14
	PIEL DE COCODRILO GRIETAS LONGITUDINALE S Y	MEDIA	4,9 5	0	1,4	0,8	1,12
	TRANSVERSALES GRIETAS LONGITUDINALE S Y	MEDIA	2,3 1	4,76	6	0	6
	TRANSVERSALES GRIETAS LONGITUDINALE S Y	BAJA	3,4 5	11,9 6	3,28	0	3,28
	TRANSVERSALES PIEL DE COCODRILO	MEDIA	2,4 8	28	1,1	94	1,03
	TRANSVERSALES BACHE	MEDIA	0	29,3 2	0,92	0,41	3
	GRIETAS LONGITUDINALE S Y	BAJA	3,7 9	37	2,63	0	2,63
	TRANSVERSALES GRIETAS LONGITUDINALE S Y	BAJA	3,7	40	2,86	0	2,86
	TRANSVERSALES GRIETAS LONGITUDINALE S Y	MEDIA	3,4 3	43	558	0	5,58
	TRANSVERSALES						

SUBTRAMO	TIPO	SEVERIDAD	X	Y	LONGITUD m	ANCHO m	AREA m ²
	GRIETAS LONGITUDINALE S Y TRANSVERSALES	BAJA	3,7 9	47	0,79	0	0,79
	GRIETAS LONGITUDINALE S Y TRANSVERSALES	MEDIA	67	39	1,24	0	1,24
	GRIETAS LONGITUDINALE S Y TRANSVERSALES	MEDIA	36	40,2 6	2,47	0	2,47

Nota: Elaboración propia a partir de los datos obtenidos en la detección y segmentación.

9.1.3 Resultado 3: Índice de condición del Pavimento Asfáltico en el área de estudio.

Con los datos de cuantificación del deterioro, se procede a ingresarlos al software EvalPal del Ministerio de Transportes y comunicaciones de Perú (2020), tal como sigue:

Figura 26

Software EvalPal con datos ingresados

EvalPav: DETERMINACION DEL DETERIORO DEL PAVIMENTO ASFALTICO

Proyecto Evaluación Datos Imprimir

Evaluación de Pavimentos de Superficie Asfáltica - Método PCI (ASTM D 6433)

Sector 00+000 - 00+033 Carril CALZADA

Unidad de muestra 001 Area de muestra (m²) 198

Progresiva inicial 00+000 Progresiva final 00+033

Inspeccionado por JMRC

Fecha 4/04/2024 Muestra adicional

m 6.6 VRC 66 PCI 34 Pobre

Daños

1. Pel de cocodrilo	7. Grieta de borde	13. Huecos
2. Exudación	8. Grieta de reflexión de junta	14. Cruce de vía férrea
3. Agrietamiento en bloque	9. Desnivel carril/berna	15. Ahuecamiento
4. Abultamientos y hundimientos	10. Grietas longitudinales y transversales	16. Desplazamiento
5. Corugación	11. Parcheo	17. Grieta parabólica (slippage)
6. Depresión	12. Pulimento de agregados	18. Hinchamiento
		19. Desprendimientos de agregados

Diagrama

TIPO	SEVERIDAD	X	Y	LONGITUD	ANCHO	AREA
1	M	0.59	3.3	5	1.24	6.2
10	H	0.41	1.61	14.32	0	14.32
10	L	4.17	10.22	0.56	0	0.56
10	L	3.77	2.28	0.4869	0	0.4869
10	L	3.96	2.19	0.899722	0	0.899722
10	L	3.87	4.19	0.3143	0	0.3143
10	L	3.87	4.2	0.212	0	0.212
10	L	3.87	4.78	0.479	0	0.479
10	L	4.29	9.06	0.819	0	0.819
10	L	4.31	9.66	0.49	0	0.49
10	L	3.22	16.7	1.71	0	1.71
10	L	3.97	18	0.72	0	0.72
10	L	3.37	19.74	1.3	0	1.3

Diagrama

TIPO	SEVERIDAD	01	02	03	04	05	06	07	08	09	10	TOTAL	DENSIDAD	VR
1	M	6.2										6.2	3.1	33
10	H	14.3										14.3	7.2	28
10	L	0.2	0.3	0.5	0.5	0.5	0.6	0.7	0.7	0.8	5.1	9.8	5.0	6
10	M	0.7	1.7	1.8	5.0							9.2	4.6	11
13	M	3.0										3.0	1.5	39

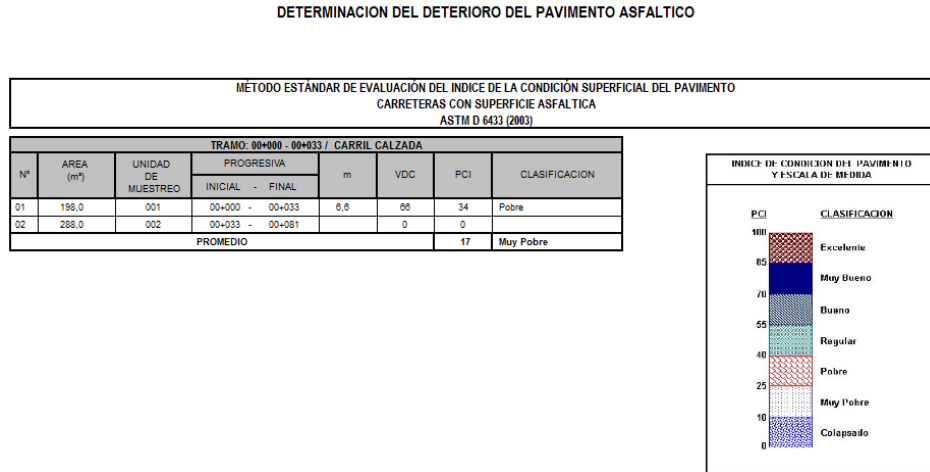
Elaborado por: Ing. Gerber J. Zavala Ascaño

Fuente: elaboración propia

Una vez ingresados, se procede a generar el reporte para cada tramo el cual contiene el valor del índice de condición del pavimento PCI:

Figura 27

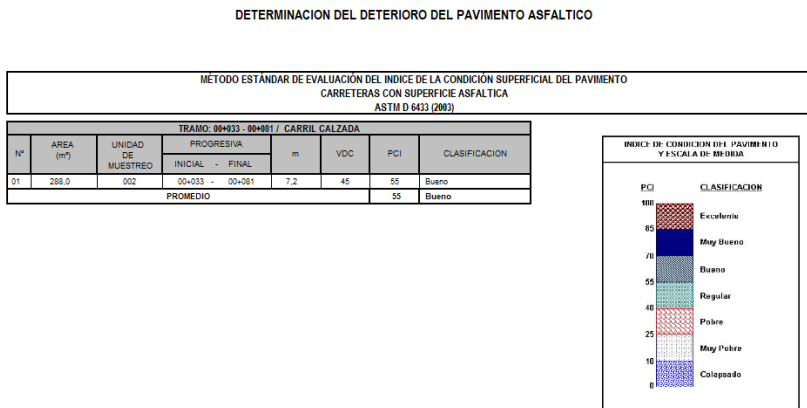
PCI para el subtramo 1



Fuente: elaboración propia a partir del software EvalPav

Figura 28

PCI para el subtramo 2



Fuente: elaboración propia a partir del software EvalPav

Sintetizando los reportes, se tiene para cada tramo los siguientes valores de PCI:

Tabla 10

Indicie de Condición del Pavimento para el área de análisis

SUBTRAMO	INDICE DE CONDICION DEL PAVIMENTO (PCI)	CLASIFICACION
1	34	POBRE
2	55	BUENO

Nota: elaborado a partir de los resultados obtenidos en el software EvalPavCar.

De acuerdo con los valores obtenidos, el subtramo 1 cuenta con un PCI pobre, lo cual se recomienda realizar rehabilitación que, según Perez acosta (2021) se lleva a cabo cuando la estructura del pavimento ya no tiene la capacidad de funcionar adecuadamente, y se busca mejorarla para un nuevo ciclo de servicio. Este proceso de mejora se realiza de tal manera que no se exceda la primera capa de materiales granulares durante la excavación. Es importante mencionar que la rehabilitación no debe implicar cambios en los diseños originales.

Considerando el valor del PCI de 55 para el subtramo 2, se recomienda realizar mantenimiento correctivo que, según Perez acosta (2021) esta tarea se centra en rectificar daños superficiales que no afectan las capas subyacentes al pavimento, como las bases. El objetivo es prolongar la durabilidad de la estructura de la vía. Las acciones principales incluyen la reparación de baches o la colocación de mezclas para la restauración de la capa de rodadura.

A continuación, se presenta la ubicación de los 2 subtramos y su clasificación según el valor de PCI obtenido.

Figura 29

Índice PCI en el área de estudio



Fuente: elaboración propia

10. Conclusiones

Es importante resaltar los recursos computacionales que se deben tener disponibles para el entrenamiento del modelo, particularmente en este trabajo de investigación se acudió a ArcGIS Notebook con soporte GPU, la cual es una solución de pago (30 créditos por hora) e incrementa los costos que se pretenden reducir, por ende, se debe contar con un equipo con al menos 8-16gdb de GPU para su adecuado procesamiento. En un equipo que no cuente con estas características, en el estudio se comparó la duración de procesamiento y, por ejemplo, para SSD (7 horas en ArcGIS Notebook) se alarga hasta más de 48 horas, lo cual es una diferencia significativa. La capacidad de procesamiento al ser una limitante para el proyecto condujo a que el número de épocas fuese de 100.

Es necesario tener en cuenta que para los modelos de detección de objetos los datos de entrenamiento definen su comportamiento en la predicción o inferencia, por ende, se requiere de un dataset robusto para aumentar el porcentaje de confianza.

El algoritmo de detección de objetos Faster R-CNN destaca por su porcentaje de precisión promedio, en donde alcanza hasta el 89% de precisión promedio para la detección de las reparaciones y un 83% para las fisuras longitudinales.

Adicionalmente, aun cuando se tiene un bajo número de datos para entrenamiento, Faster RCNN presenta un adecuado comportamiento, particularmente en el tipo de daño Pothole logró una precisión promedio del 73%.

Del mismo modo, cabe señalar que los algoritmos de detección de objetos son una opción eficiente para la detección de los tipos de deterioro del pavimento, que, combinado con modelo

de segmentación, permiten la cuantificación para el cálculo del Índice de Condición del Pavimento.

Así mismo, se resalta el Índice de Condición del Pavimento como una opción no invasiva que permite establecer preliminarmente el estado del pavimento y con ello, las acciones a realizar, que, combinado con los métodos descritos en la investigación, disminuyen el tiempo de procesamiento de la información y aumenta el grado de confianza.

La metodología propuesta, ha demostrado ser una herramienta efectiva para la detección y evaluación del deterioro del pavimento asfáltico. A través de la captura de imágenes y su posterior análisis, se puede obtener información valiosa sobre el estado de las vías, lo cual es crucial para la implementación de acciones de mantenimiento y rehabilitación tempranas y eficientes. Además, se destaca la necesidad de seguir mejorando los algoritmos y aumentar la base de datos con imágenes de diversas regiones para mantener la relevancia y utilidad de la metodología en la gestión de mantenimiento vial.

La investigación reconoce limitaciones, como las condiciones climáticas y de iluminación durante la captura de imágenes, la capacidad de procesamiento, así como la necesidad de ajustes en los algoritmos para adaptarse a diferentes tipos de deterioro del pavimento, que, si bien actualmente se consideró 6 clases, para futuras investigaciones se recomienda aumentar este número de clases y con un dataset con mayores datos que recopile deterioros en diferentes condiciones de iluminación, ángulos, y estudiar la posibilidad de multiescala.

Se recomienda para futuras investigaciones, implementar el algoritmo MASK RCNN, el cual permite detectar y segmentar objetos al mismo tiempo (ESRI, s. f.-b).

11. Referencias bibliográficas

- Adlinge, S. S., & Gupta, A. K. (2013). Pavement Deterioration and its Causes. *International journal of innovative research and development*, 2(4), 437-450. [Www.iosrjournals.org](http://www.iosrjournals.org)
- Agudelo Viana, L. G., & Aigner Aburto, J. M. (2008). *DISEÑOS DE INVESTIGACIÓN EXPERIMENTAL Y NO-EXPERIMENTAL*. <https://hdl.handle.net/10495/2622>
- Ali, L., Valappil, N. K., Kareem, D. N. A., John, M. J., & Jassmi, H. Al. (2019). Pavement Crack Detection and Localization using Convolutional Neural Networks (cnns). *International conference on digitization (ICD)*, 217-221.
- Alkaabi, K., Rhman, A., & Fawair, E. (2021). Application of A Drone Camera in Detecting Road Surface Cracks: A UAE Testing Case Study. En *The Arab World Geographer / Le Géographe du monde arabe* (Vol. 24, Número 3).
[Http://meridian.allenpress.com/awg/article-pdf/24/3/221/3095351/i1480-6800-24-3-221.pdf](http://meridian.allenpress.com/awg/article-pdf/24/3/221/3095351/i1480-6800-24-3-221.pdf)
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D., Mraz, A., Kashiyama, T., & Sekimoto, Y. (2020). *Transfer Learning-based Road Damage Detection for Multiple Countries*.
[Http://arxiv.org/abs/2008.13101](http://arxiv.org/abs/2008.13101)
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D., Omata, H., Kashiyama, T., & Sekimoto, Y. (2020). *Global Road Damage Detection: State-of-the-art Solutions*.
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D., & Sekimoto, Y. (2022). *RDD2022: A multi-national image dataset for automatic Road Damage Detection Background and Summary*.
<https://crddc2022.sekilab.global/>

Banco Mundial. (2014). *Transporte: Resultados del sector*.

<https://www.bancomundial.org/es/results/2013/04/14/transport-results-profile>

Benites Apolo, J. M., & Torres Tocto, M. F. (2022). *Cálculo del índice de condición del pavimento de la Av. Colectora en el distrito de Piura, usando drones*.

Benmhahe, B., & Chentoufi, J. A. (2021). Automated Pavement Distress Detection, Classification and Measurement: A Review. En *IJACSA International Journal of Advanced Computer Science and Applications* (Vol. 12, Número 8). [Www.ijacsa.thesai.org](http://www.ijacsa.thesai.org)

Cifuentes, L. T., Marulanda, J., & Thomson, P. (2021). *IMÁGENES Y REDES NEURONALES ARTIFICIALES*.

Designation A. S. T. M. (2011). *Designation: D6433 – 11 Standard Practice for Roads and Parking Lots Pavement Condition Index Surveys 1*. <https://doi.org/10.1520/D6433-11>

Du, Z., Yuan, J., Xiao, F., & Hettiarachchi, C. (2021). Application of image technology on pavement distress detection: A review. *Measurement: Journal of the International Measurement Confederation*, 184. <https://doi.org/10.1016/j.measurement.2021.109900>

ESRI. (s. F.-a). *Arcgis Living Atlas of the World*. Recuperado 30 de marzo de 2024, de <https://livingatlas.arcgis.com/es/browse/?Q=dlpk#d=1&q=dlpk>

ESRI. (s. F.-b). *¿Cómo funciona Mask R-CNN? | arcgis API for Python*. Recuperado 8 de abril de 2024, de <https://developers.arcgis.com/python/guide/how-maskrcnn-works/>

-
- Furusho Becker, Y. V., Lopes Siqueira, H., Takashi Matsubara, E., Nunes Goncalves, W., & Marcato Jr., J. (2019). *ASPHALT POTHOLE DETECTION IN UAV IMAGES USING CONVOLUTIONAL NEURAL NETWORKS*.
- Hafidz, Z. (2018). *Comprender las tasas de aprendizaje y cómo mejora el rendimiento en el aprendizaje profundo*. <https://towardsdatascience.com/understanding-learning-rates-and-how-it-improves-performance-in-deep-learning-d0d4059c1c10>
- Hoang, N. D. (2019). Automatic detection of asphalt pavement raveling using image texture based feature extraction and stochastic gradient descent logistic regression. *Automation in Construction*, 105. <https://doi.org/10.1016/j.autcon.2019.102843>
- IBM. (s. F.-a). *¿Qué son las redes neuronales?* Recuperado 1 de abril de 2024, de <https://www.ibm.com/es-es/topics/neural-networks>
- IBM. (s. F.-b). *¿Qué son las redes neuronales convolucionales?* Recuperado 1 de abril de 2024, de <https://www.ibm.com/es-es/topics/convolutional-neural-networks>
- IGAC. (2021). *Resolución No. 370 de 2021 “Por medio de la cual se establece el sistema de proyección cartográfica oficial para Colombia”*.
- IGAC. (2022). *Resolución No. 197 de 2022 “Por medio de la cual se modifica la Resolución 471 y 529 de 2020 “Por medio de la cual se establecen las especificaciones técnicas mínimas que deben tener los productos de la cartografía básica oficial de Colombia”*.
- Instituto Nacional de Vías -INVIAS. (2006). *Manual para la inspección visual de pavimentos flexibles*.

- Inzerillo, L., Acuto, F., Di Mino, G., & Uddin, M. Z. (2022). Super-Resolution Images Methodology Applied to UAV Datasets to Road Pavement Monitoring. *Drones*, 6(7).
<https://doi.org/10.3390/drones6070171>
- Jiang, L., Xie, Y., Associate Professor, P., Ren, T., & Engineer, S. (2020). *A DEEP NEURAL NETWORKS APPROACH FOR PIXEL-LEVEL RUNWAY PAVEMENT CRACK SEGMENTATION USING DRONE-CAPTURED IMAGES*.
- Kasthurirangan, G., Hoda, G., Akash, V., Alok, C., & Ankit, A. (2018). CRACK DAMAGE DETECTION IN UNMANNED AERIAL VEHICLE IMAGES OF CIVIL INFRASTRUCTURE USING PRE-TRAINED DEEP LEARNING MODEL. *INTERNATIONAL JOURNAL FOR TRAFFIC AND TRANSPORT ENGINEERING*, 8(1), 1-14. [https://doi.org/10.7708/ijtte.2018.8\(1\).01](https://doi.org/10.7708/ijtte.2018.8(1).01)
- Maeda, H., Sekimoto, Y., Seto, T., Kashiya, T., & Omata, H. (2018). *Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone*.
<https://doi.org/10.1111/mice.12387>
- Mei, Q., & Gül, M. (2020). A cost effective solution for pavement crack inspection using cameras and deep neural networks. *Construction and Building Materials*, 256.
<https://doi.org/10.1016/j.conbuildmat.2020.119397>
- Ministerio de Transporte, I. N. De V. (2006). *ESTUDIO E INVESTIGACIÓN DEL ESTADO ACTUAL DE LAS OBRAS DE LA RED NACIONAL DE CARRETERAS CONVENIO INTERADMINISTRATIVO 0587-03 MANUAL PARA LA INSPECCIÓN VISUAL DE*

*PAVIMENTOS FLEXIBLES REPÚBLICA DE COLOMBIA MINISTERIO DE
TRANSPORTE INSTITUTO NACIONAL DE VÍAS.*

Ministerio de Transportes y comunicaciones de Perú. (2020). *EVALPAV - SOFTWARE PARA
EVALUACION DE PAVIMENTOS EN CARRETERAS Y AEROPUERTOS DE
SUPERFICIE ASFALTICA, Y CARRETERAS NO PAVIMENTADAS.*

Mukti, S. N. A., & Tahar, K. N. (2022). Detection of potholes on road surfaces using
photogrammetry and remote sensing methods (review). *Scientific and Technical Journal of
Information Technologies, Mechanics and Optics*, 22(3), 459-471.
<https://doi.org/10.17586/2226-1494-2022-22-3-459-471>

Pan, Y., Zhang, X., Cervone, G., & Yang, L. (2018). Detection of Asphalt Pavement Potholes
and Cracks Based on the Unmanned Aerial Vehicle Multispectral Imagery. *IEEE Journal of
Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3701-3712.
<https://doi.org/10.1109/JSTARS.2018.2865528>

Pan, Y., Zhang, X., Sun, M., & Zhao, Q. (2017). Object-based and supervised detection of
potholes and cracks from the pavement images acquired by UAV. *International Archives of
the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*,
42(4W4), 209-217. <https://doi.org/10.5194/isprs-archives-XLII-4-W4-209-2017>

Perez acosta, D. Mauricio. (2021). *DIAGNÓSTICO DE PAVIMENTOS MEDIANTE EL
MÉTODO PCI Y ANÁLISIS DE LA INFLUENCIA DEL MAL ESTADO DE LA VÍA CON
RELACIÓN AL NÚMERO DE ACCIDENTES PRESENTADOS EN LA AV. LA VICTORIA
(CARRERA 4 ESTE) ENTRE CALLE 37 SUR Y CALLE 27A SUR.*

Perez Graterol, L. E. (2024). *Geoai Plugin*.

https://github.com/luiscarto/geoai_Plugin/releases/tag/Version_2

Pix4D. (2019). *GSD calculator*. [https://support.pix4d.com/hc/en-us/articles/202560249-](https://support.pix4d.com/hc/en-us/articles/202560249-TOOLS-GSD-calculator)

[TOOLS-GSD-calculator](https://support.pix4d.com/hc/en-us/articles/202560249-TOOLS-GSD-calculator)

Ponti, M. A., & da Costa, G. B. P. (2018). *Como funciona o Deep Learning*.

<http://arxiv.org/abs/1806.07908>

Ren, S., He, K., Girshick, R., & Sun, J. (2015). *Faster R-CNN: Towards Real-Time Object*

Detection with Region Proposal Networks. <http://arxiv.org/abs/1506.01497>

Roberts, R., Inzerillo, L., & Di Mino, G. (2020). Using uav based 3d modelling to provide smart monitoring of road pavement conditions. *Information (Switzerland)*, 11(12), 1-24.

<https://doi.org/10.3390/info11120568>

Romero-Chambi, E., Villarroel-Quezada, S., Atencio, E., & Rivera, F. M. La. (2020). Analysis of optimal flight parameters of unmanned aerial vehicles (uavs) for detecting potholes in pavements. *Applied Sciences (Switzerland)*, 10(12), 1-33.

<https://doi.org/10.3390/APP10124157>

<https://doi.org/10.3390/APP10124157>

Saad, A. M., & Tahar, K. N. (2019). Identification of rut and pothole by using multirotor

unmanned aerial vehicle (UAV). *Measurement: Journal of the International Measurement*

Confederation, 137, 647-654. <https://doi.org/10.1016/j.measurement.2019.01.093>

-
- Sanchez, R. J., Wilmsmeier, Gordon., & United Nations. Economic Commission for Latin America and the Caribbean. División de Recursos Naturales e Infraestructura. (2005). *Provisión de infraestructura de transporte en América Latina : experiencia reciente y problemas observados*. Naciones Unidas, Comisión Económica para América Latina y el Caribe, División de Recursos Naturales e Infraestructura.
- Saurabh, P., Prajwal, S., Shashikant, P., & Prof. Ashwini, S. (2020). Detection of Pothole by Image Processing Using UAV. *Journal of Science and Technology*, 5(3).
<https://doi.org/10.46243/jst.2020.v5.i3.pp101-110>
- Shatnawi, N. (2018). Automatic pavement cracks detection using image processing techniques and neural network. *International Journal of Advanced Computer Science and Applications*, 9(9), 399-402. <https://doi.org/10.14569/ijacsa.2018.090950>
- Tan, Y., & Li, Y. (2019). UAV photogrammetry-based 3D road distress detection. *ISPRS International Journal of Geo-Information*, 8(9). <https://doi.org/10.3390/ijgi8090409>
- The mathworks. (s. F.-a). *Introducción a Deep Learning*. Recuperado 1 de abril de 2024, de <https://la.mathworks.com/discovery/deep-learning.html>
- The mathworks. (s. F.-b). *¿Qué son las redes neuronales convolucionales?* Recuperado 1 de abril de 2024, de <https://es.mathworks.com/discovery/convolutional-neural-network.html>
- Unidad Administrativa Especial de Aeronáutica Civil. (2018). *Resolución 04201 de 2018, «Por el cual incorporan a la norma RAC91 de los reglamentos Aeronáutico de Colombia unas*

disposiciones sobre operación de sistemas de aeronaves no tripuladas UAS y se numeran como apéndice 13, y se adoptan otras disposiciones».

Unidad Administrativa Especial de Aeronáutica Civil. (2023). *RAC100 - Operación de sistemas de aeronaves no tripuladas UAS.*

USAID, & PERU PRODESCENTRALIZACION. (2011). *Desarrollo económico regional y local.*

Wei, L., Dragomir, A., Dumitru, E., Christian, S., Scott, R., Cheng-Yang, F., & Alexander, C. B. (2016). *SSD: Single Shot multibox Detector* (B. Leibe, J. Matas, N. Sebe, & M. Welling, Eds.; Vol. 9905). Springer International Publishing. <https://doi.org/10.1007/978-3-319-46448-0>

Zhang, L., Xu, W., Zhu, L., Yuan, X., & Zhang, C. (2019). Study on Pavement Defect Detection Based on Image Processing Utilizing UAV. *Journal of Physics: Conference Series*, 1168(4). <https://doi.org/10.1088/1742-6596/1168/4/042011>

Zhao, Z. Q., Zheng, P., Xu, S. T., & Wu, X. (2019). Object Detection with Deep Learning: A Review. En *IEEE Transactions on Neural Networks and Learning Systems* (Vol. 30, Número 11, pp. 3212-3232). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/TNNLS.2018.2876865>

Zhu, J., Zhong, J., Ma, T., Huang, X., Zhang, W., & Zhou, Y. (2022). Pavement distress detection using convolutional neural networks with images captured via UAV. *Automation in Construction*, *133*, 103991. <https://doi.org/10.1016/J.AUTCON.2021.103991>