

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL
DE HUAMANGA**

**FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y
CIVIL**

ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



TESIS:

**“Implementación de un método mediante visión artificial para la
evaluación del estado de conservación superficial de pavimentos
flexibles, Ayacucho 2024”**

Para optar el título profesional de:

INGENIERO CIVIL

PRESENTADO POR:

Bach. Jhon Arnold TORRES GASTELU

ASESOR:

Mg. Ing. Rocky Giban AYALA BIZARRO

AYACUCHO - PERÚ

2025

Resumen

En el Perú, especialmente en regiones como Ayacucho, el mantenimiento de pavimentos flexibles enfrenta dificultades debido a la limitada capacidad técnica y a la falta de mantenimiento oportuno. Además, los métodos tradicionales de evaluación superficial, como el PCI, VIZIR y los del MTC, suelen ser lentos, subjetivos y poco eficientes. Esta investigación propone implementar un método de visión artificial para evaluar el estado de conservación superficial de pavimentos flexibles. Para ello, se desarrolló un modelo de inteligencia artificial capaz de identificar y clasificar fallas, y calcular la calificación de condición. El estudio es de tipo aplicado, con enfoque cuantitativo, nivel aplicativo y diseño cuasiexperimental. La población estuvo conformada por imágenes digitales de tramos representativos de las rutas PE-28A, PE-26B, PE-3S y PE-28B. La muestra incluyó 3,020 imágenes etiquetadas, mientras que la validación del sistema se realizó en un tramo de 2 kilómetros de la ruta PE-26B. El programa desarrollado, denominado PAVEMAI, detecta cinco tipos de fallas: baches, fisuras, piel de cocodrilo, descascaramiento y parches, con severidades baja y alta. Se obtuvo un mAP50 de 68.9 %, y las calificaciones de condición generadas por el sistema oscilaron entre 770.02 y 861.66, frente al rango del MTC (767.00 a 955.89). El análisis estadístico evidenció una correlación moderada (Spearman: $\rho = 0.53$) y diferencias significativas (Wilcoxon: $W = 18.00$, $p = 0.0005$). Se concluye que la visión artificial es una herramienta viable para automatizar la evaluación de pavimentos. Sin embargo, se identificaron limitaciones en la detección de ciertas fallas. Se recomienda ampliar el dataset y utilizar modelos más avanzados, con el objetivo de fortalecer la gestión vial en el Perú y generar un impacto positivo en regiones como Ayacucho.

Palabras clave: Pavimentos flexibles, visión artificial, calificación de condición.

Abstract

In Peru, especially in regions like Ayacucho, the maintenance of flexible pavements faces challenges due to limited technical capacity and a lack of timely maintenance. Moreover, traditional evaluation methods, such as PCI, VIZIR, and those established by the MTC, tend to be slow, subjective, and inefficient. This research proposes the implementation of a computer vision method to assess the surface condition of flexible pavements. To this end, an artificial intelligence model was developed to identify and classify pavement distresses and calculate the condition rating. The study is applied in nature, with a quantitative approach, an applicative level, and a quasi-experimental design. The population consisted of digital images from representative segments of the PE-28A, PE-26B, PE-3S, and PE-28B routes. The sample included 3,020 labeled images, and system validation was carried out on a 2-kilometer section of the PE-26B route. The developed program, called PAVEMAI, detects five types of failures: potholes, cracks, alligator cracking, raveling, and patches, each classified by low and high severity. A mAP50 of 68.9% was achieved, and the condition ratings generated by the system ranged from 770.02 to 861.66, compared to the MTC range (767.00 to 955.89). Statistical analysis showed a moderate correlation (Spearman: $\rho = 0.53$) and significant differences (Wilcoxon: $W = 18.00$, $p = 0.0005$). It is concluded that computer vision is a viable tool for automating pavement evaluation. However, limitations were identified in the detection of certain failures. It is recommended to expand the dataset and use more advanced models to strengthen road management in Peru and generate a positive impact, especially in regions like Ayacucho.

Keywords : Flexible pavements, artificial vision, condition rating.

Introducción

Los pavimentos flexibles son una parte crucial de la infraestructura vial en el Perú, ya que soportan el tráfico vehicular y promueven el desarrollo económico y social. Sin embargo, su deterioro progresivo, evidenciado por diversas fallas, plantea desafíos significativos para su mantenimiento eficiente. Las inspecciones tradicionales, que utilizan metodologías como el PCI, VIZIR y las descritas en el Manual de Carreteras del MTC (2018), dependen de métodos manuales que son costosos, subjetivos y lentos.

La visión artificial ofrece una alternativa prometedora para superar estas limitaciones, permitiendo la detección automatizada de fallas viales con mayor rapidez y objetividad. Tecnologías como las redes neuronales convolucionales han mostrado un gran potencial en la inspección de pavimentos, aunque su aplicación en contextos locales requiere adaptaciones para abordar la diversidad de fallas y condiciones específicas. En este sentido, esta investigación desarrolla el programa PAVEMAI, un sistema basado en visión artificial, para evaluar el estado de conservación superficial de pavimentos flexibles en Ayacucho. El objetivo es modernizar la gestión vial y alinearse con los estándares establecidos por el Ministerio de Transportes y Comunicaciones.

Esta tesis está estructurada en cinco capítulos. El Capítulo 1 plantea el problema, los antecedentes, la delimitación espacial, temporal y temática, así como el objetivo general y los objetivos específicos. El Capítulo 2 desarrolla el marco teórico, abordando conceptos clave como pavimentos flexibles, visión artificial y normativas del MTC. El Capítulo 3 detalla el enfoque metodológico, describiendo el diseño de PAVEMAI, la recolección de datos de las principales carreteras departamentales que conectan la región de Ayacucho y las técnicas de análisis empleadas. El Capítulo 4 presenta los resultados obtenidos, incluyendo la detección de fallas, el cálculo de la Calificación de Condición y la comparación con métodos tradicionales. Finalmente, el Capítulo 5 expone las conclusiones y recomendaciones para optimizar PAVEMAI, contribuyendo al conocimiento en visión artificial y a soluciones prácticas para la gestión vial en el Perú.

A mis padres, Antonio Torres y Sonia Gastelu, pilares fundamentales en mi vida, por su amor incondicional, sus sacrificios silenciosos y su fe inquebrantable en mí. Este logro también es suyo.

Con el corazón lleno de gratitud, a mi abuelita Faustina Huamán, quien, aunque ya no está físicamente conmigo, sigue viva en cada recuerdo.

Agradecimientos

Quiero expresar mi más profundo agradecimiento a Dios, por brindarme la salud y fortaleza necesaria para culminar esta etapa, así como por permitirme estudiar en la Universidad Nacional de San Cristóbal de Huamanga, institución que me ha formado con responsabilidad y compromiso.

A mis padres, cuyo amor, apoyo incondicional y esfuerzo constante han sido el pilar fundamental para alcanzar mis metas personales y académicas. Sus enseñanzas, valores y ejemplo de vida me han inspirado a seguir adelante y no rendirme ante las adversidades.

Agradezco especialmente al Mg. Ing. Rocky Ayala Bizarro, por su valiosa guía, orientación y compromiso durante el desarrollo de esta investigación. Su acompañamiento fue esencial para concretar este trabajo.

Expreso mi más sincero agradecimiento al Dr. Hersmerson Lizarbe Alarcón por sus valiosas sugerencias y la minuciosa revisión de esta investigación.

A mis hermanos, Karol y Yosmel, por acompañarme incondicionalmente, estar presentes en cada momento y brindarme su valioso apoyo durante todo este proceso.

A la Ing. Karen De La Cruz, por su respaldo constante, presencia en momentos clave y valiosa colaboración a lo largo de esta investigación.

A mi primo, River Pariona, por su disposición, compromiso y ayuda invaluable en el trabajo de campo, especialmente durante la recolección de datos.

Ayacucho, Mayo de 2025

Bach. Jhon Arnold TORRES GASTELU

Índice general

Resumen	xi
Abstract	xii
Introducción	xiii
Dedicatoria	xiv
Agradecimientos	xv
Índice general	xvi
Índice de figuras	xvii
Índice de tablas	xviii
Capítulo I Planteamiento del problema	1
1.1 Descripción de la realidad problemática	1
1.2 Delimitación del problema.	3
1.2.1 Espacial (geográfica).	3
1.2.2 Temporal.	3
1.2.3 Temática y unidad de análisis.	4
1.3 Formulación del problema.	4
1.3.1 Problema general.. . . .	4
1.3.2 Problemas específicos.. . . .	4
1.4 Justificación e importancia.	4
1.5 Limitaciones de la investigación	5
1.6 Objetivos	5
1.6.1 Objetivo general.	5
1.6.2 Objetivos específicos.	5
Capítulo II Marco teórico.	6
2.1 Antecedentes	6
2.1.1 Investigaciones internacionales	6
2.1.2 Investigaciones nacionales	7
2.2 Bases teóricas	8
2.2.1 Pavimento	8
2.2.2 Evaluación de un pavimento.	19
2.2.3 Visión artificial	26
2.2.4 El seguimiento de objetos (Object Tracking)	52

Capítulo III Método de la investigación	55
3.1 Método	55
3.2 Orientación de investigación	55
3.3 Enfoque	55
3.4 Nivel de investigación	55
3.5 Diseño de investigación	56
3.6 Población y muestra.	57
3.6.1 Población	57
3.6.2 Muestra	57
3.7 Hipótesis	57
3.7.1 Hipótesis general	57
3.8 Operacionalización de variables	58
3.8.1 Identificación de Variables y dimensiones.	58
3.9 Técnicas e instrumentos.	59
3.10 Técnicas estadísticas para el procesamiento de la información.	60
3.11 Desarrollo del trabajo de tesis	61
3.11.1 Recolección de imágenes.	61
3.11.2 Pre-procesamiento de imágenes	63
3.11.3 Etiquetado de imágenes	67
3.11.4 Metodología del entrenamiento	68
3.11.5 Proceso de entrenamiento	69
3.11.6 Cálculo de índice de condición del pavimento	72
3.11.7 Desarrollo del programa	77
3.11.8 Bibliotecas y módulos utilizados	83
Capítulo IV Resultados	85
4.1 Análisis de resultados	85
4.1.1 Hipótesis específica 1	85
4.1.2 Hipótesis específica 2	96
4.1.3 Hipótesis específica 3	99
4.1.4 Hipótesis general	122
Capítulo V Conclusiones	123
5.1 Conclusiones	123
5.2 Recomendaciones	124
5.3 Trabajos futuros	124

Referencias bibliográficas	126
Glosario de términos	132
Lista de acrónimos	140
Lista de símbolos	142
Convenciones tipográficas	144
ANEXOS	145
Anexo A: Matriz de consistencia	146
Anexo B: Panel fotográfico	147
Anexo C: Manual de usuario del programa PAVEMAI	149
Anexo D: Cálculo de condición mediante la metodología del MTC.	158
Anexo E: Cálculo de condición mediante la metodología de visión artificial (PAVEMAI)	178

Índice de figuras

Figura 1.	Factores que influyen en los accidentes de tránsito en 2024	2
Figura 2.	Imagen satelital del tramo Progresiva 181+000 a 183+000 de la Ruta Nacional PE-26B.	3
Figura 3.	Estructura de un pavimento flexible	9
Figura 4.	Condición de la vía sin mantenimiento.	10
Figura 5.	Condición de la vía con y sin mantenimiento..	11
Figura 6.	Piel de cocodrilo: (a) severidad baja, (b) severidad media, y (c) severidad alta.	13
Figura 7.	Fisura: (a) severidad baja, (b) severidad media, y (c) severidad alta.	14
Figura 8.	Deformación: (a) severidad baja, (b) severidad media, y (c) severidad alta.	15
Figura 9.	Ahuellamiento: (a) severidad baja y (b) severidad alta.	15
Figura 10.	Parche: (a) severidad baja, (b) severidad media, y (c) severidad alta.	16
Figura 11.	Peladura: (a) severidad baja, (b) severidad media, y (c) severidad alta.	17
Figura 12.	Baches: (a) severidad baja y (b) severidad media.	17
Figura 13.	Fisuras transversales: (a) severidad baja y (b) severidad media.	18
Figura 14.	Exudación..	19
Figura 15.	Esquema general de visión por computadora.	27
Figura 16.	Etapas del proceso de visión artificial.	28
Figura 17.	Diagrama de Venn que representa la relación entre IA, ML y DL.	32
Figura 18.	Esquema de arquitectura de una red neuronal convolucional.	33
Figura 19.	Ejemplo de una convolución.	35
Figura 20.	Ejemplo de Convolución 2D con <i>Padding</i> igual a 1.	36
Figura 21.	Operación de Convolución 2D con <i>stride</i> igual a 1.	37
Figura 22.	Operación de Convolución 2D con <i>stride</i> igual a 2.	37
Figura 23.	Operación de Convolución 2D con <i>stride</i> igual a 2.	38
Figura 24.	Arquitectura de una red neuronal convolucional.	39
Figura 25.	Función de activación ReLU.	40
Figura 26.	Aplicación de <i>Max-Pooling</i>	41
Figura 27.	Ejemplo de detección y segmentación de de objetos.	42
Figura 28.	Intersección sobre la unión (IoU)	45
Figura 29.	Comparativa de Yolov8 con versiones anteriores	48
Figura 30.	arquitectura YOLOv8n-seg.	51
Figura 31.	Ejemplos de problemas comunes en el seguimiento visual	53

Figura 32.	Captura de video: (a) Carretera Ruta Nacional PE-28A; (b) Carretera Ruta Nacional PE-3S.	62
Figura 33.	Estructura prototípica para la captura de video en movimiento.	62
Figura 34.	Campo visual de un fotograma: dimensiones reales en campo.	63
Figura 35.	Piel de cocodrilo: (a) severidad baja, y (b) severidad alta.	64
Figura 36.	Fisura: (a) severidad baja, y (b) severidad alta.	64
Figura 37.	Descascaramiento: (a) severidad baja, y (b) severidad alta.	65
Figura 38.	Bache: (a) severidad baja, y (b) severidad alta.	66
Figura 39.	Parche.	66
Figura 40.	Cantidad de clases etiquetadas para entrenamiento.	67
Figura 41.	Etiqueta en LabelMe.	68
Figura 42.	Funciones de pérdida en entrenamiento y validación	85
Figura 43.	Evolución de las métricas de rendimiento durante el entrenamiento	86
Figura 44.	Evolución de métricas principales de detección y Segmentación durante el entrenamiento	89
Figura 45.	Curva Precision-Recall para Detección	91
Figura 46.	Curva Precision-Recall para segmentación	92
Figura 47.	Matriz de confusión del modelo.	94
Figura 48.	Detección y clasificación	94
Figura 49.	Verificación con niveles de confianza	95
Figura 50.	Interfaz del programa PAVEMAI	97
Figura 51.	Pestaña de tiempo para delimitar tramos de estudios	98
Figura 52.	Pestaña de resumen del programa PAVEMAI.	99
Figura 53.	Porcentaje de extensión por tipo de falla.	101
Figura 54.	Porcentaje de extensión por tipo de falla.	103
Figura 55.	Comparación de áreas afectadas por piel de cocodrilo.	115
Figura 56.	Comparación de áreas afectadas por fisuras.	116
Figura 57.	Comparación de áreas afectadas por Descascaramiento vs. Peladura/Desprendimiento.	117
Figura 58.	Comparación de áreas afectadas por baches.	117
Figura 59.	Comparación de áreas afectadas por parches.	118
Figura 60.	Comparativa de calificación de condición entre el método MTC y basada en visión artificial.	120
Figura 61.	Soporte prototípico instalado en vehículo para adquisición de imágenes del estado de la vía.	147
Figura 62.	Recolección de imágenes de la carretera PE-28A (vía Libertadores) . . .	147

Figura 63. Marcado de progresivas en calzada de carretera para el control de intervalos de tiempo	148
Figura 64. Deterioro severo de la plataforma vial por formación de baches.	148

Índice de tablas

Tabla 1.	Relación de fallas según la Norma ASTM D6433-07.	20
Tabla 2.	Clasificación según la metodología Índice de Condición del Pavimento. . .	21
Tabla 3.	Daños tipo A – VIZIR	22
Tabla 4.	Daños tipo B – VIZIR	22
Tabla 5.	Clasificación de acuerdo al Is	23
Tabla 6.	Deterioros o Fallas de los pavimentos asfaltados	24
Tabla 7.	Criterio de extensión de daño	25
Tabla 8.	Criterio de densidad de baches (huecos) en pavimento flexible	25
Tabla 9.	Ancho de influencia de fisuras longitudinales y transversales	25
Tabla 10.	Clasificación de condición MTC.	26
Tabla 11.	Operacionalización de las variables	59
Tabla 12.	Etapas, técnicas e instrumentos aplicados	60
Tabla 13.	Fallas predominantes en carreteras principales de la región de Ayacucho	61
Tabla 14.	Descripción y cantidad de clases	67
Tabla 15.	Parámetros de entrenamiento del modelo YOLOv8n-seg.pt	69
Tabla 16.	Pérdidas durante el entrenamiento y validación a lo largo de las épocas .	71
Tabla 17.	Métricas de desempeño a lo largo de las épocas	72
Tabla 18.	Deterioro o fallas de pavimentos flexibles	73
Tabla 19.	Puntajes de Condición (PC) propuestos para la metodología de IA	75
Tabla 20.	Clasificación de condición del pavimento	76
Tabla 21.	Tipos de conservación según clasificación de condición	77
Tabla 22.	Parámetros de calibración	82
Tabla 23.	Parámetros generales de detección.	83
Tabla 24.	Parámetros específicos por clase de falla	83
Tabla 25.	Evolución de métricas clave durante el entrenamiento.	88
Tabla 26.	Resultados de mAP50 y condición técnica por clase	90
Tabla 27.	Resultados de clasificación por clase	93
Tabla 28.	Valores de CC y su clasificación por tramo evaluado	102
Tabla 29.	Calificación de condición y tipo de intervención por tramo evaluado . . .	104
Tabla 30.	Actividades propuestas: progresiva 181+000 - 181+200	105
Tabla 31.	Actividades propuestas: progresiva 181+200 - 181+400	106
Tabla 32.	Actividades propuestas: progresiva 181+400 - 181+600	107
Tabla 33.	Actividades propuestas: progresiva 181+600 - 181+800	108

Tabla 34.	Actividades propuestas: progresiva 181+800 - 182+000	109
Tabla 35.	Actividades propuestas: progresiva 182+000 - 182+200	110
Tabla 36.	Actividades propuestas: progresiva 182+200 - 182+400	111
Tabla 37.	Actividades propuestas: progresiva 182+400 - 182+600	112
Tabla 38.	Actividades propuestas: progresiva 182+600 - 183+800	113
Tabla 39.	Actividades propuestas: progresiva 182+800 - 183+000	114
Tabla 40.	Valores de PAVEMAI, MTC y su diferencia por tramo evaluado	119
Tabla 41.	Análisis de Confiabilidad por niveles de precisión	120
Tabla 42.	Resultados de las pruebas estadísticas de comparación y correlación . .	121

Capítulo I: Planteamiento del problema

1.1 Descripción de la realidad problemática

Las carreteras en el Perú están constituidas ampliamente por pavimentos flexibles que enfrentan diversos desafíos, incluido el deterioro generalizado debido a la falta de mantenimiento adecuado y la exposición a condiciones climáticas extremas. Esta situación no solo afecta la calidad de las carreteras, sino que también tiene un impacto significativo en la seguridad vial, la economía y la calidad de vida de la población.

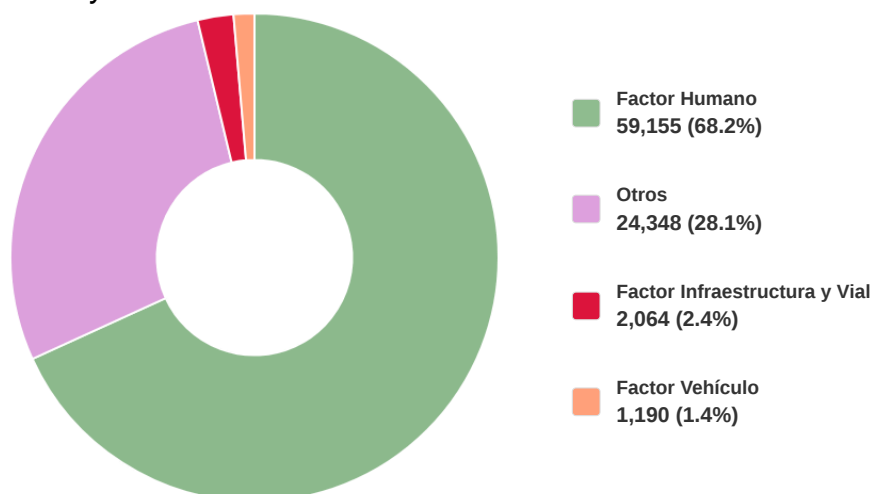
La falta de un mantenimiento preventivo y correctivo adecuado ha provocado que las intervenciones se realicen solo cuando el deterioro está avanzado, lo cual incrementa los costos y disminuye la eficacia de las reparaciones. Esta ausencia de planificación a largo plazo, repercute negativamente en la economía nacional y en la seguridad de los conductores y peatones, quienes deben transitar en condiciones peligrosas. De no atenderse esta situación o esta problemática los accidentes de tránsito, el desgaste de los vehículos y los costos de reparación aumentarían considerablemente, afectando tanto al gobierno como a los usuarios y población en general (Solminihac & Chamorro, 2001). Además, el mal estado de las vías podría aislar a comunidades rurales, limitando su acceso a servicios básicos, reduciendo la productividad económica e impidiendo su integración en los circuitos comerciales y de transporte.

Según el Ministerio de Transportes y Comunicaciones (2024), entre 2017 y 2022 las principales causas de los siniestros viales en el país fueron el exceso de velocidad, la imprudencia y la conducción en estado de ebriedad, factores que representaron más del 64.6% de los accidentes. Aunque el mal estado de las vías contribuyó solo con el 1.72%, sigue siendo un factor significativo, ya que involucra pérdidas de vidas humanas, algo que no debería incidir en la seguridad vial con consecuencias fatales.

En 2024, se registraron específicamente 1,134 siniestros vinculados al mal estado de las vías, lo que representó el 1.3% del total de siniestros viales. Al incluir el impacto del factor ambiental y la mala señalización, este porcentaje se incrementó al 2.4%, como se muestra en la siguiente figura 1.

Figura 1

Factores que influyen en los accidentes de tránsito en 2024



Nota. Información obtenida del Boletín Anual 2024 de la Dirección de Seguridad Vial (Ministerio de Transportes y Comunicaciones (2024))

La evaluación de la condición superficial de pavimentos flexibles mediante métodos tradicionales representa un proceso laborioso, ya que implica la inspección manual de la superficie de la carretera y la recopilación de datos mediante fichas y equipos especializados. Este enfoque puede ser tedioso y demandar mucho tiempo, dificultando la realización de evaluaciones frecuentes y exhaustivas del estado de conservación del pavimento. Según Zakeri et al. (2017), la cuantificación precisa de las fallas es esencial para determinar las estrategias óptimas de mantenimiento; sin embargo, el enfoque tradicional suele implicar altos costos, tiempos prolongados y resultados inconsistentes, además de exponer a los inspectores a riesgos laborales en las carreteras.

La aparición de nuevas tecnologías como la inteligencia artificial permite realizar una mejor evaluación de los pavimentos. El procesamiento de imágenes (IP), herramientas avanzadas como la visión artificial (CV), el aprendizaje automático (ML) y el aprendizaje profundo (DL) automatiza el diagnóstico de fallas en los pavimentos, ofreciendo así una mayor precisión en detectar varios defectos, para optimizar los recursos utilizados en las evaluaciones (Kheradmandi & Mehranfar, 2022). A través del aprendizaje profundo, estas tecnologías eliminan la necesidad de recolectar manualmente los diferentes tipos de características, ya que poseen la capacidad de aprender patrones complejos, esto se da a partir de grandes volúmenes de datos. En la detección de daños en los pavimentos, el aprendizaje profundo ha mostrado ser muy preciso, lo que ayuda e identifica automáticamente los tipos y grados de deterioro de los pavimentos en distintos tipos de condiciones (Zheng et al., 2024).

1.2 Delimitación del problema.

1.2.1. Espacial (geográfica).

El presente estudio puede aplicarse a cualquier carretera con pavimento flexible; sin embargo, para garantizar la validez y relevancia de los resultados, es fundamental delimitar un espacio geográfico específico que refleje las condiciones típicas de deterioro. Por ello, se ha seleccionado un tramo de la Ruta Nacional PE-26B, que conecta la región de Ayacucho con Huancavelica, comprendido entre las progresivas 181+000 y 183+000 (ver Figura 2).

Figura 2

Imagen satelital del tramo Progresiva 181+000 a 183+000 de la Ruta Nacional PE-26B



Nota. Imagen obtenida de Google Earth.

Para el conjunto de datos de entrenamiento, se han recopilado imágenes de carreteras departamentales de la región de Ayacucho, abarcando diversas fallas en pavimentos flexibles. Estas imágenes ofrecen una representación amplia y variada de los deterioros viales, garantizando un entrenamiento más robusto y eficaz del modelo de visión artificial.

1.2.2. Temporal.

El desarrollo de la investigación se efectuó en el transcurso del año 2024.

1.2.3. Temática y unidad de análisis.

La temática de la presente investigación se enfoca en implementar un método que evaluará el estado de conservación del pavimento flexible, esto se realiza a través de un modelo de visión artificial, el cual permite analizar a partir de fotogramas que capturan las fallas existentes.

En esta investigación la unidad de análisis son las diferentes imágenes de pavimentos flexibles que presentan las fallas más comunes que se encuentran en las carreteras de la región de Ayacucho, estas imágenes proporcionan los datos necesarios para entrenar el modelo y asegurar la representatividad de las condiciones reales del pavimento.

1.3 Formulación del problema.

1.3.1. Problema general.

¿De qué manera se implementa un método mediante visión artificial para la evaluación del estado de conservación superficial del pavimento flexible, Ayacucho 2024?

1.3.2. Problemas específicos.

- a) ¿De qué manera se desarrolla un modelo de visión artificial que permita identificar y clasificar de forma automatizada diferentes tipos de fallas en pavimentos flexibles?
- b) ¿De qué manera se desarrolla un programa mediante algoritmos de inteligencia artificial para calcular la calificación de condición del pavimento flexible?
- c) ¿De qué manera se determina la fiabilidad de la metodología mediante visión artificial desarrollada para evaluar el estado de conservación superficial de pavimentos flexibles, en comparación con los métodos tradicionales?

1.4 Justificación e importancia.

Al implementar un método usando la visión artificial, se podrá acelerar el proceso de evaluación del pavimento, permitiendo así, detectar a temprana edad posibles fallas que se muestren en el pavimento. De esta manera se contribuirá con la seguridad vial al poder identificar y reparar problemas de manera oportuna, ayudando a reducir costos de mantenimiento y prolongar la vida útil de las carreteras. Además, el desarrollo de este método servirá para dar lugar a nuevos campos de investigación en la rama de la ingeniería

civil y el uso de la tecnología de la información, obteniendo competitividad y el conocimiento en el área.

La presente investigación es de gran importancia ya que va a permitir desarrollar e implementar un método para poder evaluar el estado de conservación superficial de los pavimentos flexibles y así adoptar tecnologías emergentes superando los métodos tradicionales que son usados actualmente.

1.5 Limitaciones de la investigación

- La limitada disponibilidad de imágenes de diversas fallas en pavimentos flexibles en la región de Ayacucho debido a la baja frecuencia de algunas fallas, lo cual dificulta una mayor clasificación, afectando su precisión y robustez.
- La falta de acceso a equipos de alto rendimiento necesarios para el procesamiento en el entrenamiento del modelo.
- La restricción presupuestaria reduce el alcance de la recolección de imágenes de pavimento flexible en las diversas carreteras de la región.

1.6 Objetivos

1.6.1. Objetivo general.

Implementar un método mediante visión artificial para evaluar el estado de conservación superficial de pavimentos flexibles, Ayacucho 2024.

1.6.2. Objetivos específicos.

- a) Desarrollar un modelo de visión artificial que permita identificar y clasificar de forma automatizada diferentes tipos de fallas en pavimentos flexibles.
- b) Desarrollar un programa mediante algoritmos de inteligencia artificial para calcular la calificación de condición del pavimento flexible.
- c) Determinar la fiabilidad de la metodología implementada mediante visión artificial para evaluar el estado de conservación superficial de pavimentos flexibles, en comparación con las metodologías tradicionales.

Capítulo II: Marco teórico.

2.1 Antecedentes

2.1.1. Investigaciones internacionales

Tello et al. (2021) estudió el deterioro de pavimentos flexibles en Colombia, tradicionalmente evaluado mediante inspecciones manuales (VIZIR y PCI), que son subjetivas y laboriosas. Propuso un método automatizado usando fotogrametría terrestre y redes neuronales, con seis fases: i. Captación de imágenes desde un vehículo, ii. Preprocesamiento para corregir distorsiones y mejorar contraste, iii. Segmentación con detección de bordes y transformada de Beamlet, iv. Extracción de atributos, v. Clasificación con redes neuronales artificiales, y vi. Determinación del área dañada. Aplicado a grietas longitudinales, piel de cocodrilo y baches, una red neuronal perceptrón multicapa (12 12 3), entrenada con Levenberg-Marquardt, logró un 96% de precisión, 96.97% de precisión global, 93.33% de sensibilidad y un índice kappa de 0.936, con 100% de aciertos para piel de cocodrilo y grietas longitudinales, y 80% para baches.

Guerrieri y Parla (2022) presenta un método automatizado en tiempo real de bajo costo para detectar y medir los diversos tipos de deterioro en pavimentos de carreteras flexibles y rígidos. La detección, clasificación y medición de los daños se fundamentan en el enfoque de aprendizaje profundo y el algoritmo YOLOv3. Se construyó inicialmente un conjunto de datos para la detección de daños en pavimentos de carreteras, que incluyó aproximadamente 9,150 imágenes y 15,585 cuadros delimitadores de daños en pavimentos flexibles y rígidos, luego se utilizó en el entrenamiento de redes neuronales. Los valores obtenidos por las métricas de evaluación del rendimiento del modelo (Pérdida, Precisión, Recall, RMSE) demuestran la alta precisión y exactitud del modelo en la detección de los daños del pavimento. La validación del método se llevó a cabo mediante un análisis de errores comparando los deterioros del pavimento detectados con el método propuesto y los reales en algunos casos de estudio. La tasa de detección correcta de los deterioros del pavimento oscila entre el 91.0% y el 97.3%, dependiendo del tipo de pavimento y de deterioro. La eficacia de la técnica propuesta en la detección y medición de deterioros en pavimentos flexibles y rígidos ofrece nuevas perspectivas para realizar inspecciones exhaustivas utilizando dispositivos de detección económicos y técnicas de inteligencia artificial.

Ataiwe (2023) en su estudio desarrolla una metodología de procesamiento de imágenes para la detección automática de grietas en la superficie del pavimento basándose en la información del borde. Se recolectaron imágenes utilizando una cámara digital Canon EOS 500D. La metodología comenzó con el procesamiento de la imagen para mejorar la característica lineal de la grieta, convirtiendo la imagen digital a escala de grises mediante la función de transformación de escala de grises y el filtro de reconstrucción. El método de umbral adaptativo también está diseñado para mapear la información del gradiente de la grieta mientras se extrae de manera aproximada el borde de la grieta en función de la característica de escala de grises. Una vez recopilados los puntos de borde filtrados, se reconoció el borde mediante el procesamiento de filtrado de un solo píxel, mejorado mediante la diferencia local entre los píxeles en la región fija. Se concluyó que la detección de grietas se logró al pasar las imágenes digitales a través de diferentes filtros para extraerlas.

2.1.2. Investigaciones nacionales

Chávez y Reyes (2019) Tuvo como objetivo desarrollar un sistema de visión computacional para identificar fallas superficiales en pavimentos flexibles en la ciudad de Trujillo. Se realizó un estudio tipo aplicada y no experimental. La población de este estudio estuvo conformada por imágenes de pavimento flexible de la ciudad de Trujillo, con dimensiones de 1200x1200 píxeles y el muestreo probabilístico de 385 imágenes. Los instrumentos empleados fueron guías de observación. El resultado que se obtuvo por el sistema de visión computacional fue una tasa de reconocimiento mayor al 95 % de identificación de fallas superficiales del pavimento flexible. Se concluyó desarrollar un sistema de visión computacional permitiendo identificar las diferentes fallas superficiales en el pavimento flexible.

Esplana y Pérez (2021) investigó cómo la rigidez del pavimento afecta su estado de conservación en la vía nacional PE-26B, tramo Huancavelica – Lircay, empleando técnicas de inteligencia artificial. El estudio, de carácter explicativo, aplicado y no experimental, tomó como población la vía mencionada, analizando 70 unidades muestrales de 40 metros de largo por 6.60 metros de ancho. Los instrumentos utilizados incluyeron certificados de ensayos de laboratorio de mecánica de suelos, el informe de pavimentos del estudio definitivo y un formato de auscultación para evaluar la condición del pavimento. Se concluyó que la rigidez del pavimento tiene una influencia significativa en su conservación, según los resultados obtenidos mediante inteligencia artificial en dicho tramo.

Valdivia (2023) Tuvo como objetivo realizar un análisis comparativo de los parámetros de

las metodologías PCI, VIZIR y el manual MTC en la evaluación el estado superficial del pavimento de la avenida B en el distrito de Comas. El diseño metodológico adoptado es de tipo no experimental, con un enfoque cuantitativo y alcance explicativo. La población de estudio está constituida por el pavimento flexible de la avenida B, que tiene una longitud de 2000 metros, dividida en dos carriles de 1000 metros cada uno, con un ancho de calzada de 6.00 metros. Fueron seleccionadas 40 unidades de muestra para el PCI, 20 para el VIZIR y 10 para el MTC. Según los resultados obtenidos, se determinó que el pavimento tiene una condición "BUENO" con un valor de 57 según el PCI, un estado "REGULAR" con un IS de 3 utilizando el método VIZIR, y una clasificación "BUENO" con un valor de 924 empleando el MTC. Tras comparar los resultados y parámetros de evaluación, se concluyó que el PCI es la metodología más confiable para diagnosticar el estado del pavimento, ya que ofrece una menor área de evaluación por unidad de muestra y considera un mayor número de defectos, lo que permite localizar los daños con mayor precisión, lo que a su vez favorece la propuesta de intervención y mejora de la avenida.

2.2 Bases teóricas

2.2.1. Pavimento

De acuerdo con MTC (2013), los pavimentos se definen como estructuras de superficie lisa cuya principal función es distribuir las cargas generadas por los vehículos sobre el terreno. El peso de los vehículos puede causar concentraciones de carga que afecten la calidad y conservación de la vía. Asimismo, está compuesto de múltiples capas que se construye sobre la subrasante de la carretera para soportar y dispersar las fuerzas generadas por los vehículos, con el fin de mejorar la seguridad y comodidad del tráfico. Generalmente, consta de una capa de rodadura, base y subbase (Ministerio de Economía y Finanzas [MEF], 2015).

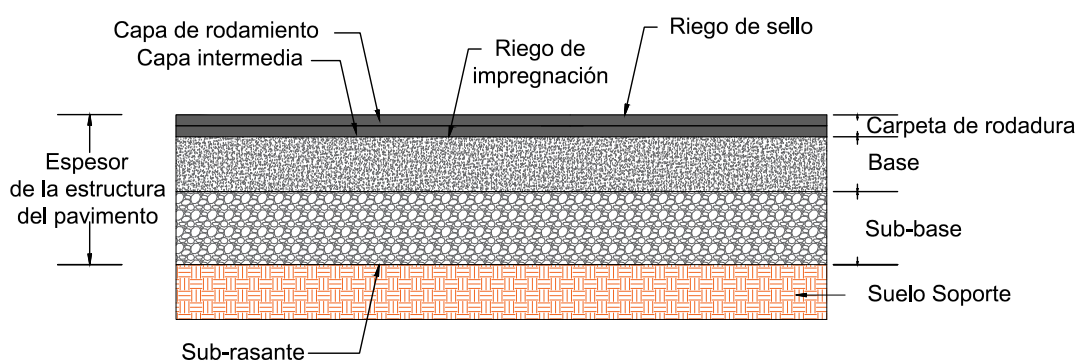
- Capa de rodadura: Es la parte superior del pavimento, que puede ser de tipo bituminoso (flexible), concreto de cemento Portland (rígido) o adoquines, diseñada para soportar directamente el tránsito.
- Base: Situada debajo de la capa de rodadura, sostiene, distribuye y transmite las cargas generadas por el tránsito. Puede ser de material granular drenante (CBR > 80%) o tratada con asfalto, cal o cemento.
- Subbase: Una capa de material específico con un espesor de diseño que brinda soporte a la base y a la capa de rodadura. También se utiliza para drenaje y control de

la capilaridad del agua. Dependiendo del tipo y diseño del pavimento, esta capa puede ser omitida. Puede estar compuesta por material granular (CBR > 40%) o tratada con asfalto, cal o cemento.

2.2.1.1 El pavimento flexible

Son sistemas compuestos por capas granulares (subbase, base) y una capa de rodadura compuesta de materiales bituminosos como aglomerantes, agregados y, posiblemente, aditivos (Figura 3). La capa de rodadura típicamente consiste en asfalto y se aplica sobre las capas granulares, como mortero asfáltico, tratamiento superficial bicapa, micro pavimentos, macadam asfáltico, mezclas asfálticas en frío o en caliente (MEF, 2015). Debe observarse que algunas superficies asfaltadas son demasiado delgadas como para poder ser calificadas de pavimento flexible, como son los tratamientos superficiales bituminosos (BST) o las capas de concreto asfáltico (AC) menores a 1.5 cm colocadas directamente sobre la subrasante (Papagiannakis & Masad, 2024).

Figura 3
Estructura de un pavimento flexible



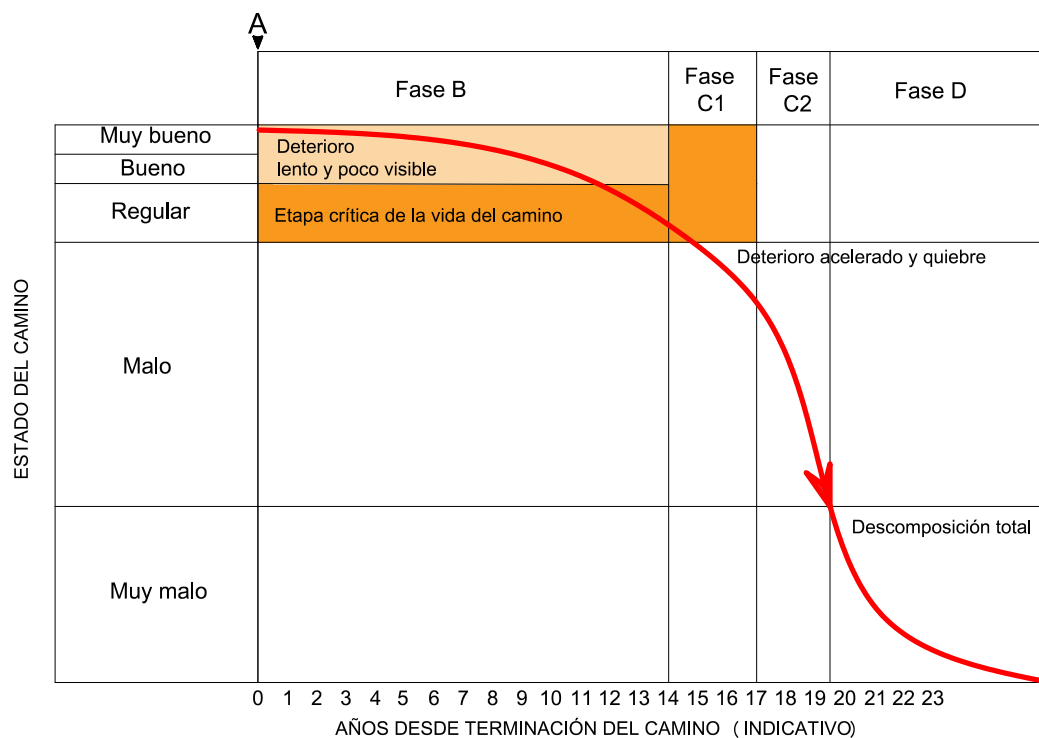
Nota. Adaptado del MEF (2015)

2.2.1.2 Ciclo de vida del pavimento asfáltico

Menéndez (2003), en su manual técnico sobre el mantenimiento rutinario de caminos con microempresas, explica que los pavimentos experimentan un deterioro continuo debido a diversos factores como el tráfico, el agua y los taludes, entre otros, que eventualmente los vuelven intransitables. Además, destaca que este proceso de deterioro pasa por diferentes etapas, desde un deterioro inicial leve y poco visible hasta una etapa crítica donde su estado ya no es óptimo y continúa empeorando hasta alcanzar el punto de falla. Por lo tanto, enfatiza la importancia de realizar mantenimiento preventivo en el momento adecuado para

prolongar la vida útil del pavimento y evitar gastos significativos de reparación en el futuro. Además, menciona que las fases del ciclo de vida del pavimento asfáltico se dividen en cuatro fases, como se muestra en la Figura 4.

Figura 4
Condición de la vía sin mantenimiento.



Nota. Adaptado de Menéndez (2003)

Fase A: Construcción, se caracteriza por estar en óptimas condiciones para satisfacer las necesidades del usuario, como se representa en el Punto A de la figura 4.

Fase B: Deterioro lento, que corresponde a los primeros años de uso, el pavimento comienza a experimentar un leve desgaste superficial debido a diversos factores externos como el tráfico y las condiciones climáticas. Aunque este deterioro es apenas perceptible al principio, con el tiempo se vuelve más evidente hasta pasar a la siguiente fase.

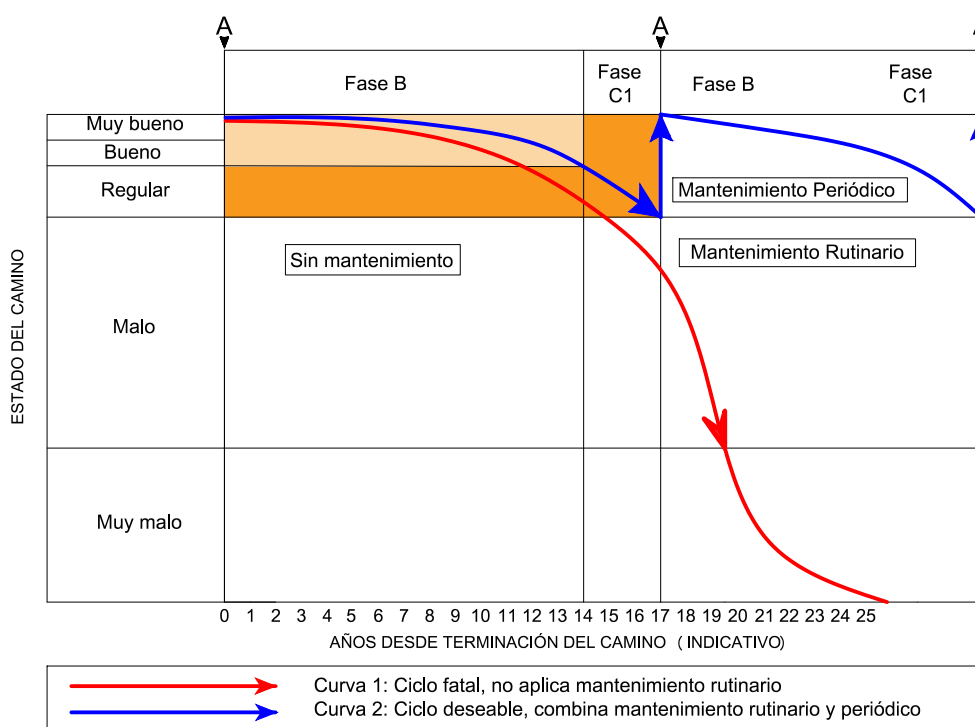
Fase C: Deterioro acelerado, se presenta después de varios años de uso, donde el pavimento muestra un deterioro más notable debido a la exposición prolongada a diferentes niveles de tráfico. A pesar de ello, la transitabilidad del pavimento aún es aceptable y no se realizan acciones correctivas de manera general. Sin embargo, esta percepción puede cambiar a medida que las fallas se extienden y se agravan, lo que puede afectar las capas inferiores del pavimento como la base y subbase.

Fase D: Deterioro total, el pavimento se halla en un estado avanzado de deterioro, empeorando con el tiempo. La capacidad de tránsito se ve constantemente disminuida, lo que resulta en una experiencia incómoda y dificultosa para los conductores, aumentando así el riesgo de accidentes en la vía. Dada la magnitud del deterioro en esta fase, las medidas correctivas ya no son viables, lo que inevitablemente conduce a la necesidad de reconstruir la vía por completo. Por lo tanto, es recomendable implementar medidas de mantenimiento preventivo en el pavimento con el objetivo de prolongar su vida útil y evitar así alcanzar esta última etapa del ciclo de vida del pavimento (Fase D).

Es fundamental considerar que el mantenimiento de las vías debe llevarse a cabo durante la fase C, conocida como el deterioro acelerado, según se muestra en la gráfica. Esto tiene como objetivo evitar que las fallas presentes en esta etapa se propaguen o se intensifiquen. Como se ilustra en la figura 5, el mantenimiento regular contribuye a elevar el nivel del estado de la vía, lo que permite regresar a la fase B, caracterizada por un deterioro más lento. A partir de entonces, se requerirá un mantenimiento rutinario para prolongar la vida útil de la vía. De lo contrario, si se posterga el mantenimiento durante la fase C, el costo de intervención aumentará considerablemente y, en ocasiones, puede volverse inviable.

Figura 5

Condición de la vía con y sin mantenimiento.



Nota. Adaptado de Menéndez (2003)

2.2.1.3 Fallas en el pavimento

Es un defecto que reduce la funcionalidad y resistencia estructural del pavimento, causado por factores como el tráfico, la construcción, los materiales y las condiciones climáticas. Esto puede comprometer significativamente la capacidad de la vía para ofrecer un tránsito seguro y confortable. Los daños pueden manifestarse en la capa asfáltica, la capa granular o la subrasante. Si el deterioro afecta a la subrasante, el pavimento requiere una reconstrucción completa.

Según Ministerio de Transportes y Comunicaciones del Perú (MTC, 2018) Los deterioros o fallas en pavimentos flexibles se dividen en dos categorías principales: estructurales y superficiales. Los deterioros o fallas estructurales están generalmente asociados con obras de rehabilitación de alto costo, mientras que los superficiales se relacionan con trabajos de mantenimiento periódico, como la aplicación de una capa delgada de concreto asfáltico o un tratamiento superficial.

- **Tipos y causas de los daños estructurales**

Los deterioros estructurales reflejan el estado estructural del pavimento y afectan a todas sus capas o, en algunos casos, solo a la capa superficial.

Las cargas vehiculares suelen provocar:

- Deformaciones verticales elásticas en los materiales de las capas granulares y en el suelo de la subrasante.
- Deformaciones horizontales elásticas por tensión de flexión en la parte inferior de las capas asfálticas.

Si las deformaciones verticales en gravas o suelos superan los límites, se producen deformaciones permanentes como hundimientos o ahuellamientos de gran amplitud. Cuando las deformaciones horizontales por flexión en las capas asfálticas exceden el umbral permitido, aparecen fisuras en la base que se propagan hacia la superficie, manifestándose como grietas longitudinales en las huellas de tráfico o fisuras tipo piel de cocodrilo.

Los deterioros estructurales, como las deformaciones y fisuras, no suelen manifestarse de inmediato; en cambio, surgen tras la repetición constante de cargas, siguiendo la curva de fatiga de cada material.


a. Deterioros o fallas Estructurales

- **Piel de cocodrilo**

La piel de cocodrilo se caracteriza por fisuras que crean polígonos irregulares con ángulos agudos. En sus etapas iniciales, puede ser poco severa, con polígonos incompletos trazados en la superficie a través de fisuras cerradas (es decir, de ancho nulo). Con el tiempo, y bajo la influencia de condiciones climáticas y el tráfico, el tamaño de la malla disminuye. Las fisuras comienzan a abrirse y se nota una pérdida de material en sus bordes.

Figura 6

Piel de cocodrilo: (a) severidad baja, (b) severidad media, y (c) severidad alta.



Nota. Extraído del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)


La Figura 6 ilustra los niveles de severidad del deterioro tipo piel de cocodrilo en pavimentos, con un tamaño de malla que disminuye de mayor a menor. En la severidad baja (a), la malla es grande (mayor a 0.5 m), con fisuras delgadas y sin material suelto. En la severidad media (b), la malla es mediana (entre 0.3 y 0.5 m), con algo de material suelto, indicando un daño progresivo. En la severidad alta (c), la malla es pequeña (menor a 0.3 m), con fisuras anchas y riesgo de desprendimiento, reflejando un deterioro avanzado. Estos niveles muestran la evolución del daño, desde fisuras leves hasta grietas densas que comprometen la superficie.

- **Fisuras longitudinales**

Las fisuras longitudinales de fatiga se describen inicialmente como discontinuas, pero que, bajo la acción del tráfico, tienden a evolucionar hacia una fisuración continua y, en muchos casos, ramificada. A través del tiempo, con la exposición continua al tránsito, se incrementa el número de fisuras, además de que estas se vuelven más pronunciadas.

Figura 7

Fisura: (a) severidad baja, (b) severidad media, y (c) severidad alta.



Nota. Extraído del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)

La Figura 7 muestra los niveles de severidad de fisuras en el pavimento según su ancho y deterioro. En severidad baja (a), las fisuras son finas, con un ancho de hasta 1 mm. En severidad media (b), las fisuras están abiertas o ramificadas, con un ancho entre 1 y 3 mm y bordes intactos. En severidad alta (c), las fisuras son gruesas, superan los 3 mm y presentan bordes desintegrados. Esta progresión refleja cómo las fisuras avanzan desde fisuras leves hasta grietas que comprometen la estructura del pavimento.

- **Deformación por deficiencia estructural**


Las deformaciones en los pavimentos flexibles se presentan generalmente bajo la forma de depresiones, ya sean continuas o localizadas, estas se presentan debido a deficiencias estructurales o las deformaciones conocidas como ahuellamientos que son generados por la inestabilidad de la capa de rodadura.

Depresión continua: Aparece en el área de las ruedas, con un ancho de al menos 0,8 m y en los laterales del pavimento, entre 0,5 y 0,8 m, que se presenta debido al asentamiento de los distintos materiales que conforman las capas del pavimento y la subrasante como consecuencia del paso de un tráfico muy intenso y concentrado.

Depresión localizada: Se refiere al hundimiento del pavimento en una zona específica, generalmente en los bordes, provocado por deficiencias en el soporte o estabilidad de los materiales, que normalmente se presentan debido a la mala calidad de los mismos o por un exceso de agua.

Figura 8

Deformación: (a) severidad baja, (b) severidad media, y (c) severidad alta.



Nota. Extraído del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)

La Figura 8 muestra niveles de deformación en el pavimento según su profundidad: (a) severidad baja con menos de 2 cm, apenas perceptible; (b) severidad media entre 2 y 4 cm, más evidente; y (c) severidad alta con más de 4 cm.

- **Ahuellamiento**

El ahuellamiento es una depresión localizada en la calzada por donde transitan o circulan las llantas de los vehículos. En general va asociado a una elevación en las zonas circundantes a la depresión y por la aparición de fisuras. Un ahuellamiento considerable puede provocar una falla estructural del pavimento e incrementar la posibilidad de hidroplaneo debido a la acumulación de agua.

Figura 9

Ahuellamiento: (a) severidad baja y (b) severidad alta.



Nota. Extraído del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018).

La Figura 9 muestra niveles de severidad del ahuellamiento del pavimento. En severidad baja (a), la profundidad es de hasta 6 mm; en severidad media, entre 6 mm y 12 mm; y en severidad alta (b), supera los 12 mm, lo que representa un deterioro


significativo para la seguridad vial.

- **Reparaciones o parchado**

Las reparaciones sirven para corregir provisional o permanentemente los defectos del pavimento. Su número, extensión y frecuencia son elementos clave en el diagnóstico, ya que una reparación reciente puede ocultar un problema subyacente, mientras que reparaciones repetidas evidencian un deterioro continuo. Las reparaciones deben evaluarse visualmente; si solucionan fallas superficiales, no afectan la calificación estructural. Sin embargo, si cubren fisuras estructurales, se consideran un factor agravante. Estos criterios determinan los niveles de gravedad.

Figura 10

Parche: (a) severidad baja, (b) severidad media, y (c) severidad alta.



Nota. Extraído del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)

La Figura 10 muestra distintos niveles de severidad en parches de pavimento. En severidad baja (a), el parche cubre deterioros superficiales sin mayores daños. En severidad media (b), la reparación cubre fisuras como piel de cocodrilo o fisuras longitudinales en buen estado. En severidad alta (c), el parche presenta un deterioro notable, evidenciando fallas que requieren intervención.

b. Deterioros o Fallas superficiales


- **Peladura y desprendimientos**

La peladura y desprendimiento representan un tipo de deterioro en el pavimento asfáltico que involucra la pérdida superficial de material debido a la desintegración de la capa asfáltica, ya sea por el desprendimiento del ligante bituminoso o de los agregados. Este deterioro puede incluir la pérdida parcial o total de la capa de rodadura. Las causas comunes de este problema son la baja adherencia o incorrecta dosificación del asfalto, el uso de asfalto envejecido que ha perdido sus propiedades

ligantes y la utilización de agregados de calidad inadecuada.

Figura 11

Peladura: (a) severidad baja, (b) severidad media, y (c) severidad alta.



Nota. Extraído del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)

La Figura 11 muestra niveles de peladura en pavimento. En severidad baja (a), la peladura es superficial sin exponer la base. En severidad media (b), hay desgaste con exposición puntual de la base. En severidad alta (c), la peladura es continua y deja la base granular visible, reflejando un daño avanzado.

- **Baches (huecos)**

Los baches, también conocidos como huecos, resultan del desgaste o daño progresivo en la capa de rodadura. Suelen ser de pequeño tamaño al aparecer, pero sin mantenimiento adecuado, crecen y se extienden, formando patrones repetidos que a menudo coinciden con el perímetro de una rueda de camión. Este deterioro surge principalmente por la falta de conservación vial y la evolución de otros daños, como el desprendimiento y la fisuración por fatiga.

Figura 12

Baches: (a) severidad baja y (b) severidad media.



Nota. Extraído del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018).

La Figura 12 muestra niveles de severidad en baches del pavimento según su tamaño. En severidad baja (a), el bache tiene un diámetro menor a 0.2 m, indicando un daño leve. En severidad media (b), el diámetro aumenta entre 0.2 y 0.5 m, reflejando un desgaste moderado. Un bache en severidad alta (no mostrado) tendría un diámetro superior a 0.5 m, señalando un daño avanzado.

- **Fisuras transversales**

Las fisuras transversales son grietas que se forman en el pavimento perpendicularmente, o casi, al eje de la vía. Este tipo de deterioro generalmente se debe a la retracción térmica de la mezcla asfáltica, que pierde flexibilidad por envejecimiento o exceso de material fino, y también puede originarse en grietas reflejadas de capas inferiores o en juntas de construcción que presentan defectos.

Figura 13

Fisuras transversales: (a) severidad baja y (b) severidad media.



(a)



(b)

Nota. Extraído del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018).

La Figura 13 muestra fisuras transversales en pavimento según su severidad: (a) severidad baja, con fisuras finas de hasta 1 mm de ancho; severidad media, con fisuras abiertas o ramificadas de entre 1 y 3 mm de ancho; y (b) severidad alta, con grietas de más de 3 mm de ancho, indicando un deterioro avanzado del pavimento.

- **Exudación**

La exudación es un tipo de deterioro que se manifiesta como una capa o afloramiento de ligante asfáltico en la superficie del pavimento, que suele verse brillante, resbaladiza y pegajosa. Este fenómeno puede reducir la resistencia al deslizamiento y se produce principalmente cuando la mezcla contiene exceso de asfalto, disminuyendo el contenido de vacíos de aire, especialmente en climas cálidos. También puede originarse por el uso de asfaltos demasiado blandos o debido al derrame de solventes

específicos (INVIAS, 2006).

Figura 14
Exudación.



Nota. Imagen extraída del manual INVIAS (2006).

La exudación en pavimentos se clasifica en tres niveles de severidad: baja, media y alta. La severidad baja corresponde a una exudación puntual en áreas específicas; la severidad media, a una exudación continua en toda la superficie; y la severidad alta como muestra la Figura 14, a una exudación continua con una superficie viscosa, indicando un nivel avanzado de deterioro en el pavimento.

2.2.2. Evaluación de un pavimento

La evaluación de pavimentos es un proceso fundamental para determinar el estado de las superficies de las carreteras y adoptar medidas adecuadas de reparación y mantenimiento. A través de un informe detallado, se analiza la condición de los pavimentos existentes con el objetivo de prolongar su vida útil (Garcés, 2017).

2.2.2.1 Metodologías para la evaluar el pavimento flexible

En la actualidad se emplean dos metodologías para evaluar la condición de los pavimentos: el método PCI (Pavement Condition Index), desarrollado en Norteamérica y el método VIZIR (Visión Inspección de Áreas y Rutas de Riesgo), de origen francés.

2.2.2.2 Metodología del PCI

El Índice de Condición del Pavimento (PCI) es una metodología más completa para evaluar y calificar de manera objetiva los pavimentos, tanto flexibles como rígidos. Se utiliza dentro

de los modelos de Gestión Vial disponibles en la actualidad. Este índice proporciona una visión completa del estado de las carreteras y ayuda a tomar decisiones informadas sobre el mantenimiento y la rehabilitación (Vásquez, 2002).

Consiste en determinar el índice de condición del pavimento (PCI), según la norma ASTM D6433-3: "Procedimiento Estándar para la Inspección del Índice de Condición del Pavimento en Caminos y Estacionamientos".

De acuerdo con ASTM (2020), se detallan los tipos de fallas, las cuales podría clasificarse en fallas funcionales y estructurales, como se muestra en la siguiente tabla 1.

Tabla 1
Relación de fallas según la Norma ASTM D6433-07.

N°	Tipo de falla	Cod.	Und. medida
Fallas estructurales			
1	Grieta piel de cocodrilo	PC	m^2
2	Grietas de contracción (bloque)	BLO	m^2
3	Elevaciones – hundimiento	ABH	m^2
4	Depresiones	DEP	m^2
5	Huecos	HUE	m^2
6	Ahuellamiento	AHU	m
7	Grietas de deslizamiento	DES	m^2
8	Hinchamiento	HN	m^2
Fallas funcionales			
9	Exudación de asfalto	EX	m^2
10	Corrugaciones	COR	m^2
11	Grietas de borde	GB	m
12	Grietas de reflexión de juntas	GR	m
13	Desnivel calzada – berma	DN	m
14	Grietas longitudinal y/o transversal	GLT	m
15	Parqueo	PA	m^2
16	Agregados pulidos	PU	n°
17	Cruce de rieles	CVF	m^2
18	Grietas parabólicas	GP	m^2
19	Disgregación y desintegración	DAG	m^2

Nota. Adaptado de Vásquez (2002).

Este método fue diseñado por ingenieros del Cuerpo de Ingenieros del Ejército de los

Estados Unidos, permite obtener una evaluación cuantitativa precisa del pavimento. El PCI asigna un valor numérico que oscila entre 0 y 100, lo que facilita la clasificación del pavimento en siete categorías según su estado, como se muestra en la Tabla 2.

Tabla 2

Clasificación según la metodología Índice de Condición del Pavimento.

Rango	Descripción
100 – 85	Excelente
85 – 70	Muy Bueno
70 – 55	Bueno
55 – 40	Regular
40 – 25	Malo
25 – 10	Muy Malo
10 – 0	Fallado

Nota. Adaptado de Vásquez (2002).

2.2.2.3 Metodología VIZIR

Desarrollado en Francia en los años 60, el método 'Visión Inspection de Zones et Itinéraires À Risque' (VIZIR) se enfocó en la evaluación de pavimentos flexibles y fue presentado por el Laboratorio Central de Puentes y Carreteras, conocido como 'Laboratoire Central des Ponts et Chaussées (LCPC)'.

La metodología VIZIR se centra en clasificar y cuantificar daños en pavimentos con revestimiento bituminoso, proporcionando un análisis detallado del estado de la superficie en un momento dado. Divide las zonas en tres niveles de daño, facilitando la identificación de áreas con igual calidad y determinando el tipo de mantenimiento requerido, desde soluciones inmediatas hasta diagnósticos complejos para la gestión de redes carreteras. Los daños se agrupan en dos categorías: tipo A y tipo B (Autret & Brousse, 1992).

Daños de tipo A

Estos daños caracterizan un estado estructural del pavimento; concerniente al conjunto de las diferentes capas del mismo y del suelo o bien solamente a la capa de superficie.

Son daños provenientes de una insuficiencia de la capacidad estructural del pavimento que interviene en la búsqueda de la solución asociada con otros criterios, en particular el soporte o capacidad portante, caracterizado por la deflexión estática; en la siguiente Tabla 3 se muestra daños tipo A-VIZIR.

Tabla 3
Daños tipo A – VIZIR

Nombre del Deterioro	Código	Unidad
Ahuellamiento	AH	<i>m</i>
Depresiones o hundimientos longitudinales	DL	<i>m</i>
Depresiones o hundimientos transversales	DT	<i>m</i>
Fisuras longitudinales por fatiga	FLF	<i>m</i>
Fisuras piel de cocodrilo	FPC	<i>m</i>
Bacheos y parches	B	<i>m</i>

Nota. Adaptado del Manual INVIAS (2006)

Daños de tipo B

Estos daños demandan reparaciones que generalmente no están asociadas a la capacidad estructural del pavimento. Se originan de un defecto de construcción, de un defecto en la calidad de un producto, o de una condición local particular que el tráfico puede acentuar evidentemente, se muestran en la Tabla 4:

Tabla 4
Daños tipo B – VIZIR

Nombre del Deterioro	Código	Unidad
Fisura longitudinal de junta de construcción	FIJ	<i>m</i>
Fisura transversal de junta de construcción	FTJ	<i>m</i>
Fisuras de contracción térmica	FCT	<i>m</i>
Fisuras parabólicas	FP	<i>m</i>
Fisura de borde	FB	<i>m</i>
Huecos	H	<i>und</i>
Abultamiento o ahuellamiento	DM	<i>m</i>
Pérdida de la película de ligante	PL	<i>m</i>
Pérdida de agregados	PA	<i>m</i>
Descascaramiento	DC	<i>m²</i>
Pulimento de agregados	PU	<i>m</i>
Exudación	EX	<i>m</i>
Afloramiento de mortero	AM	<i>m</i>
Afloramiento de agua	AFA	<i>m</i>
Desintegración de los bordes del pavimento	DB	<i>m</i>
Segregación	S	<i>m</i>

Nota. Adaptado del Manual INVIAS (2006)

Según el manual del INVIAS (2006) la metodología VIZIR considera dos índices: el índice de fisuración, referido al agrietamiento de tipo estructural (If), y el índice de deformación (Id), referido a los deterioros o deformaciones de tipo estructural. Esto permite obtener un valor numérico basado en las características de extensión y severidad, con el cual es posible calcular un índice de deterioro superficial (Is) (Romer & Yanina, 2016) .

El Índice de Fisuración (If) evalúa la gravedad y extensión de las fisuras y agrietamientos funcionales en cada zona, centrándose únicamente en las fallas de tipo B relacionadas con la fisuración del pavimento. Se cuantifica el área dañada por estas fallas para determinar el índice.

El Índice de Deformación (Id) considera la extensión y gravedad de las deformaciones estructurales, como ahuellamientos, depresiones o hundimientos, tanto longitudinales como transversales. Este índice se basa en la frecuencia e intensidad de las fallas de tipo A.

El Índice de Deterioro Superficial (Is) proporciona una medida numérica de la condición general de la capa superficial del pavimento, ayudando a guiar las decisiones sobre posibles intervenciones.

La combinación de If e Id da lugar a la primera nota de degradación, que varía de uno a siete, siendo mayor cuanto más graves o extensos sean los daños. Esta nota puede ajustarse en función de la cantidad y severidad de las intervenciones en la estructura del pavimento, lo que puede aumentar el valor de Is. Los pasos para calcular estos índices se detallan en la Tabla 5.

Tabla 5

Clasificación de acuerdo al Is

Categoría	Is
Buena	1 - 2
Marginal	3 - 4
Deficiente	5 - 6 - 7

Nota. Adaptado del Manual INVIAS (2006)

2.2.2.4 Metodología del Ministerio de Transporte y Comunicaciones (MTC)

El Manual de Mantenimiento o Conservación Vial, desarrollado por el MTC (2018), establece directrices esenciales para la gestión de pavimentos, enfatizando puntos críticos como el mantenimiento y el nivel de servicio. Este documento indica que la condición de una vía está directamente relacionada con indicadores de satisfacción del usuario, lo cual permite

fijar parámetros para evaluar su estado funcional y estructural. Esto facilita obtener una visión clara de la comodidad y seguridad que la carretera ofrece.

El MTC (2018) clasifica los daños en dos tipos: fallas estructurales y fallas superficiales. Las fallas estructurales disminuyen la capacidad de soporte del pavimento y se manifiestan en deformaciones verticales, como ahuellamientos o hundimientos, y en deformaciones horizontales, como fisuras y agrietamiento en piel de cocodrilo. Las fallas superficiales incluyen deterioros en la superficie del pavimento, como desprendimientos, baches y fisuras transversales; estos daños, con el tiempo, pueden empeorar y evolucionar hasta convertirse en fallas estructurales, Tabla 6.

Tabla 6
Deterioros o Fallas de los pavimentos asfaltados

Clasificación de los deterioros/fallas	Código de deterioro/falla	Deterioro / Falla	Gravedad
Deterioros o fallas Estructurales	1	Piel de cocodrilo	1: Malla grande (> 0.5 m) sin material suelto 2: Malla mediana (entre 0.3 y 0.5 m) sin o con material suelto 3: Malla pequeña (< 0.3 m) con o sin material suelto
	2	Fisuras longitudinales	1: Fisuras finas en las huellas del tránsito (ancho ≤ 1 mm) 2: Fisuras medias corresponden a fisuras abiertas y/o ramificadas (ancho > 1 mm y ≤ 3 mm) 3: Fisuras gruesas corresponden a fisuras abiertas y/o ramificadas (ancho > 3 mm). También se denominan grietas.
	3	Deformación por deficiencia estructural	1: Profundidad sensible al usuario < 2 cm 2: Profundidad entre 2 cm y 4 cm 3: Profundidad > 4 cm
	4	Ahuellamiento	1: Profundidad sensible al usuario pero ≤ 6 mm 2: Profundidad > 6 mm y ≤ 12 mm 3: Profundidad > 12 mm
	5	Reparaciones o parchados	1: Reparación o parchado para deterioros superficiales. 2: Reparación de piel de cocodrilo o de fisuras longitudinales, en buen estado. 3: Reparación de piel de cocodrilo o de fisuras longitudinales, en mal
Deterioros o fallas superficiales	6	Peladura y Desprendimiento	1: Puntual sin aparición de la base granular (peladura superficial). 2: Continuo sin aparición de la base granular o puntual con aparición de la base granular. 3: Continuo con aparición de la base granular.
	7	Baches (Huecos)	1: Diámetro < 0.2 m 2: Diámetro entre 0.2 y 0.5 m 3: Diámetro > 0.5 m
	8	Fisuras transversales	1: Fisuras finas (ancho ≤ 1 mm) 2: Fisuras medias, corresponden a fisuras abiertas y/o ramificadas (ancho > 1 mm y ≤ 3 mm) 3: Fisuras gruesas, corresponden a fisuras abiertas y/o ramificadas (ancho > 3 mm). También se denominan grietas.
	9	Exudación	1: Puntual 2: Continua 3: Continua con superficie viscosa.

Nota. Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)

La condición del pavimento flexible se evalúa en tramos de 200 metros. Se califica el estado de la superficie de rodadura según las fallas presentes, su gravedad y extensión.

El comienzo y el final del nivel de gravedad de cada tipo de deterioro o falla observada deben ser identificados. Posteriormente, estos datos básicos se procesan utilizando la Tabla 7, que define la clase de extensión para una sección de 200 m con deterioro; la Tabla 8, que se aplica a baches o huecos; y la Tabla 9, que especifica el ancho de influencia de las fisuras longitudinales y transversales según el nivel de gravedad del deterioro o falla.

Tabla 7

Criterio de extensión de daño

Clase	Descripción	Criterio de extensión (porcentaje de la longitud de la sección)
1	Leve	menor que el 10 %
2	Moderado	entre 10 y 30 %
3	Severo	mayor que el 30 %

Nota. Adaptado del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018).

Tabla 8

Criterio de densidad de baches (huecos) en pavimento flexible

Clase	Descripción	Criterio de densidad de baches (huecos) (número / 200 m)
1	Leve	menor a 4
2	Moderado	entre 4 y 10
3	Severo	mayor a 10

Nota. Adaptado del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)

Tabla 9

Ancho de influencia de fisuras longitudinales y transversales

Gravedad	Ancho de Influencia (m)
1	0.10
2	0.30
3	0.50

Nota. Adaptado del Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)

La suma total no debe exceder los 1000 puntos. En este sentido, la calificación de la condición del pavimento se obtiene restando el puntaje de condición a la suma total, según

la siguiente fórmula:

$$\text{Calificación de condición} = 1000 - \text{Suma puntaje de condición}$$

La calificación de condición evalúa el estado superficial del pavimento flexible y se agrupa en tres tipos:

- Bueno
- Regular
- Malo

El valor obtenido se clasifica como condición buena si es mayor a 800, como condición regular si se encuentra entre 300 y 800, y como condición mala si es menor a 300, como se muestra en la tabla 10.

Tabla 10
Clasificación de condición MTC

Tipo de condición	Rango
Condición bueno	< 800 – 1000]
Condición regular	< 300 – 800]
Condición malo	[0 – 300]

Nota. Adaptado del manual del MTC (2018)


2.2.3. Visión artificial

González et al. (2006) define como una disciplina que abarca todos los procesos y componentes que dotan a una máquina de capacidades visuales. La visión artificial, o comprensión de imágenes, implica la inferencia automática de la estructura y características de un entorno tridimensional, posiblemente dinámico, a partir de una o varias imágenes bidimensionales de dicho entorno.

El propósito de la visión artificial es identificar y analizar características de una imagen para su posterior interpretación por parte de un sistema computacional. En este campo, se persigue obtener descripciones relevantes para cada tarea específica. La figura 15 ilustra cómo una imagen de entrada es procesada para extraer atributos, generando como resultado una descripción detallada del contenido de la imagen analizada.

Figura 15

Esquema general de visión por computadora.



Nota. Adaptado de Visión computacional, Sucar y Gómez (2011).

En el núcleo de la visión artificial está la capacidad de deducir las propiedades geométricas y materiales de los objetos presentes en el mundo tridimensional. Esto incluye aspectos como la forma, tamaño y localización de los elementos, así como características de los materiales, como el color, la iluminación, la textura y la composición. Esta disciplina no solo se enfoca en identificar los elementos en una imagen, sino también en inferir el contexto de cambios que puedan producirse, e incluso llegar a predecir eventos futuros.

2.2.3.1 Formación y representación de la imagen

La formación de una imagen ocurre cuando un sensor, como el ojo humano o una cámara, captura la radiación luminosa que ha interactuado con distintos objetos físicos. Esta imagen puede describirse mediante una función bidimensional, en la cual cada valor de la función representa la intensidad o el brillo en cada punto de la imagen.

2.2.3.2 Color

El color es un fenómeno perceptual que se relaciona con la respuesta humana a distintas longitudes de onda dentro del espectro visible, el cual abarca entre 400 y 700 nm. Esto se debe a la existencia de tres tipos de receptores en el ojo humano, los cuales responden de manera distinta según la longitud de onda percibida. La combinación de estas tres señales permite la percepción de toda la gama de colores. Existen varias formas de organizar y representar estos colores a partir de componentes básicas, las cuales se conocen como espacios de color. Dos ejemplos comunes de estos modelos son RGB y HSI.

- **Modelo RGB:** Se basa en el principio de que el ojo humano posee tres sensores y considera que todos los colores pueden formarse mediante la combinación de tres colores básicos o primarios: R (rojo), G (verde) y B (azul).

- **Modelo HSI:** Este modelo es considerado el que mejor se aproxima a la percepción del color por parte del ser humano. En este modelo, el color se codifica utilizando tres componentes: H (croma), S (saturación) e I (intensidad).

2.2.3.3 Etapas en el proceso de la visión artificial

La visión artificial abarca numerosos conceptos relacionados con hardware, software y fundamentos teóricos. Según González et al. (2006), el proceso para realizar una tarea de visión artificial se estructura en varios pasos, ilustrados en la Figura 16:

Figura 16

Etapas del proceso de visión artificial.



Nota. Adaptado de González et al. (2006).

Adquisición de imágenes: La adquisición de la imagen constituye la primera etapa del proceso de visión artificial. En este paso inicial, se busca obtener la imagen de la manera

más adecuada posible para garantizar el correcto desarrollo de las etapas posteriores. Una adquisición precisa de la imagen es esencial para asegurar el éxito del proceso de reconocimiento. Durante esta fase intervienen múltiples factores, como el hardware (cámara, óptica, tarjeta de memoria, computadora y software) y el entorno junto con el posicionamiento de los elementos (iluminación, fondo, correcta ubicación de la cámara, y la presencia de ruido eléctrico u óptico externo) (González et al., 2006).

Procesamiento de imágenes: La etapa de preprocesamiento de imágenes tiene como objetivo corregir los defectos presentes en la imagen que no fueron eliminados por el hardware, tales como distorsiones, ruido, problemas de contraste o brillo, y la falta de ecualización apropiada.

Segmentación de imágenes: La segmentación consiste en separar los diferentes objetos del fondo, dividiendo la imagen en zonas disjuntas. Las técnicas mencionadas por González et al. (2006) se clasifican en transformaciones morfológicas y técnicas de segmentación (basadas en umbral, en bordes y orientadas a regiones).

Extracción de características: Una vez completado el proceso de segmentación, que permite identificar los bordes de los objetos, el siguiente paso es extraer los parámetros que definen las características de dichos objetos, tales como forma, textura, color y orientación. Para la selección de estos parámetros o descriptores, es importante considerar las recomendaciones establecidas por González et al. (2006):

- Ser discriminantes, para diferenciar efectivamente los objetos de una clase de otros.
- Ser independientes, evitando que sus valores se influyan mutuamente.
- Ser suficientes, para definir claramente la pertenencia de un objeto a una categoría.

2.2.3.4 Machine learning

Según Nandal et al. (2023) Dentro del ámbito de la inteligencia artificial, el aprendizaje automático es una disciplina que capacita a los sistemas para aprender de manera explícita a partir de experiencias pasadas; de esta manera, ya no requiere una programación individualizada para cada tarea. La notable adaptabilidad permite que los algoritmos de aprendizaje automático ejecuten operaciones, como predicción o clasificación, basadas en los datos disponibles, obteniendo un enfoque mucho más factible y rentable en comparación con la programación manual tradicional.

El Machine Learning tiene como objetivo que las computadoras adapten sus acciones de forma continua, ya sea realizando predicciones o controlando dispositivos, con el fin de mejorar su precisión. Esta precisión se evalúa por la capacidad de dichas acciones de aproximarse a los resultados correctos esperados (Marsland, 2009). En esencia, el aprendizaje automático implica *"mejorar en una tarea a través de la práctica"* (Marsland, 2009), donde el sistema aprende no solo a optimizar sus resultados mediante la experiencia acumulada, sino también a generalizar esas estrategias aprendidas para aplicarlas a nuevos contextos y problemas. Esta capacidad de adaptación y mejora progresiva permite a las computadoras actuar de forma cada vez más precisa, optimizando su rendimiento y eficiencia en diferentes tareas.

2.2.3.5 Tipos de Machine Learning

- **Aprendizaje supervisado:** Se proporciona un conjunto de ejemplos con las salidas correctas (objetivos) y, a partir de estos datos de entrenamiento, el algoritmo aprende a generalizar para responder correctamente a nuevas entradas. Este tipo de aprendizaje también se conoce como "aprendizaje por ejemplos".
- **Aprendizaje no supervisado:** En este caso, no se dispone de salidas predefinidas. El objetivo del algoritmo es identificar patrones o similitudes entre los datos de entrada, de manera que elementos con características comunes se agrupen en categorías. En el ámbito estadístico, este enfoque se conoce como "estimación densa".
- **Aprendizaje por refuerzo:** Este tipo se sitúa entre el aprendizaje supervisado y el no supervisado. El algoritmo recibe una notificación cuando la respuesta es incorrecta, pero no si es correcta. Así, debe explorar y probar diferentes alternativas hasta aprender cómo obtener la respuesta correcta. Este tipo de aprendizaje también se denomina "aprendizaje con crítica", ya que monitorea el rendimiento de las respuestas sin ofrecer sugerencias específicas para mejorarlas.
- **Aprendizaje evolutivo:** Está inspirado en el proceso de evolución biológica, donde los organismos se adaptan para mejorar su supervivencia y la capacidad de reproducirse. En este contexto, los modelos se fundamentan en la noción de "aptitud", que corresponde a una medida de qué tan buena es la solución actual.

2.2.3.6 Proceso del Machine Learning

(Marsland, 2009) describe el proceso mediante el cual se seleccionan, aplican y evalúan los algoritmos de aprendizaje automático para resolver un problema específico. Este proceso se compone de varias etapas:

- **Recolección y preparación de datos:** Se recopilan datos relevantes con las características necesarias. En el aprendizaje supervisado, se incluyen datos objetivo, requiriendo grandes volúmenes para un buen desempeño.
- **Selección de características:** Se identifican las características más relevantes para el problema, minimizando el tiempo de cálculo y evitando ruido que afecte el rendimiento.
- **Elección del algoritmo:** Se selecciona el algoritmo más adecuado, definiendo la estrategia para resolver el problema.
- **Selección de parámetros y modelo:** Se ajustan los parámetros del algoritmo para optimizar el rendimiento del modelo.
- **Entrenamiento:** Se construye el modelo usando datos de entrenamiento, permitiendo predecir resultados para nuevos datos.
- **Evaluación:** Se mide la precisión del modelo con datos no usados en el entrenamiento, empleando métricas adecuadas.

2.2.3.7 Deep learning

El Deep Learning representa una evolución de las redes neuronales artificiales hacia arquitecturas más profundas con capacidades de aprendizaje mejoradas (LeCun et al., 2015) . Se distingue del Machine Learning tradicional por su capacidad de aprender automáticamente representaciones de características a partir de datos sin procesar, sin necesidad de una extracción manual de características (Goodfellow et al., 2016).

Una característica fundamental del Deep Learning es que sus redes neuronales profundas típicamente consisten en más de una capa oculta, organizadas en arquitecturas de red profundamente anidadas. Además, suelen contener neuronas avanzadas que utilizan operaciones sofisticadas como convoluciones o múltiples activaciones en una sola neurona (Pouyanfar et al., 2018).


El Deep Learning ha demostrado un rendimiento superior en dominios con datos grandes

y de alta dimensionalidad, superando a los algoritmos de Machine Learning superficial en la mayoría de las aplicaciones que involucran procesamiento de texto, imágenes, video, voz y audio (LeCun et al., 2015). Sin embargo, para datos de baja dimensionalidad, especialmente en casos de disponibilidad limitada de datos de entrenamiento, el Machine Learning superficial aún puede producir resultados superiores (Zhang & Ling, 2018).

En la Figura 17 se ilustra la relación entre los campos de la Inteligencia Artificial (IA), el Aprendizaje Automático (ML) y el Aprendizaje Profundo (DL).

Figura 17

Diagrama de Venn que representa la relación entre IA, ML y DL.



Nota. Adaptado de Janiesch et al. (2021).

2.2.3.8 Red neuronal convolucional

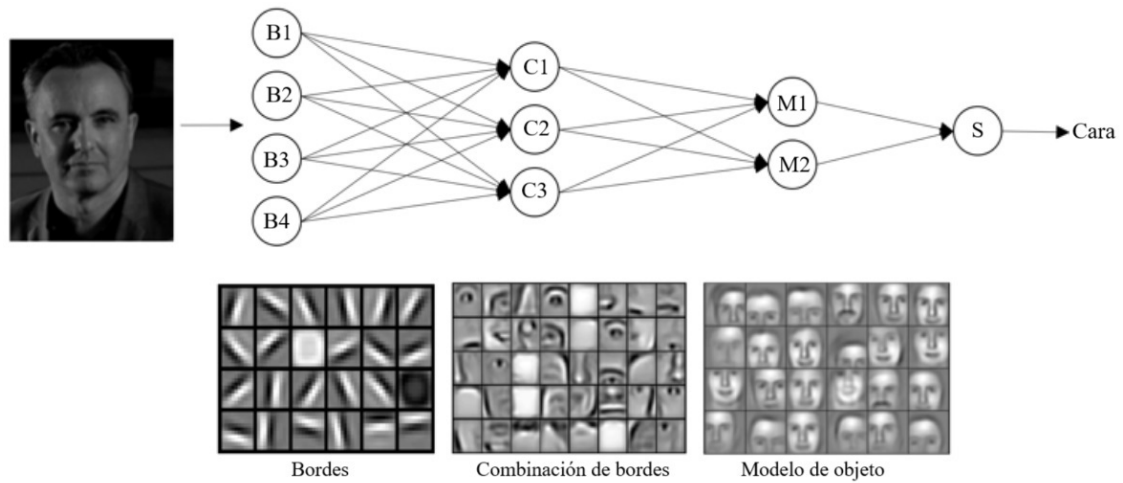
Las Redes Neuronales Convolucionales (CNN, por sus siglas en inglés) son un tipo especializado de red neuronal diseñado para procesar datos que presentan una estructura similar a una cuadrícula. Entre los ejemplos más comunes se encuentran las series temporales, que pueden representarse como una cuadrícula unidimensional (1D), con muestras obtenidas a intervalos regulares, y las imágenes, que pueden considerarse una cuadrícula bidimensional (2D) de píxeles.

Las redes convolucionales han demostrado un gran éxito en aplicaciones prácticas, especialmente en el ámbito de la visión artificial y el procesamiento de imágenes. El nombre "convolucional" proviene del uso de una operación matemática llamada convolución, la cual es un tipo especializado de operación lineal. En lugar de utilizar la multiplicación de matrices tradicional, las CNN aplican la convolución en al menos una de sus capas, lo que las distingue de las redes neuronales convencionales (Goodfellow et al., 2016). Como se

muestra en la figura 18.

Figura 18

Esquema de arquitectura de una red neuronal convolucional.



Nota. Tomado de Torres (2018).

- B1,B2,B3 y B4: Representan los bordes de la imagen.
- C1, C2 y C3: Combinaciones de bordes presentes en la imagen.
- M1 y M2: Modelos de los objetos presentes en la imagen.
- S: Representa la salida del modelo.

Según Torres (2018), en una red neuronal convolucional (CNN), cada capa aprende diferentes niveles de abstracción, comenzando por características simples, como bordes, hasta llegar a objetos completos. Este enfoque jerárquico permite extraer características cada vez más complejas, lo que hace de las CNN una herramienta eficaz para el procesamiento de imágenes.

2.2.3.9 Operador de Convolución

La **convolución** es una operación clave en redes neuronales convolucionales (CNN) para procesar datos con una estructura tipo cuadrícula, como imágenes y señales temporales. Matemáticamente, la convolución se define como:

$$s(t) = \int x(a)w(t-a) da \quad (2.1)$$

y se representa con un asterisco:

$$s(t) = (x * w)(t) \quad (2.2)$$

En las CNN, la entrada se denomina x y el kernel o filtro se representa como w . El resultado de la operación se denomina mapa de características.

En aplicaciones prácticas, la entrada y el kernel suelen ser matrices multidimensionales, conocidas como tensores. La convolución sobre una entrada bidimensional I y un kernel bidimensional K se define como:

$$S(i,j) = (I * K)(i,j) = \sum_m \sum_n I(m,n)K(i-m,j-n) \quad (2.3)$$

Esta operación es **conmutativa**, lo cual permite reordenar la entrada y el kernel sin afectar el resultado:

$$S(i,j) = (I * K)(i,j) = \sum_m \sum_n I(i-m,j-n)K(m,n) \quad (2.4)$$

En lugar de la convolución convencional, muchas bibliotecas de redes neuronales utilizan la correlación cruzada o *cross-correlation*, que es similar a la convolución pero sin invertir el kernel:

$$S(i,j) = (I * K)(i,j) = \sum_m \sum_n I(i+m,j+n)K(m,n) \quad (2.5)$$

Para el procesamiento de imágenes y datos 2D, la ecuación de convolución se expresa como:

$$S(i,j) = (I * K)(i,j) = \sum_m \sum_n I(m,n)K(i-m,j-n) \quad (2.6)$$


Donde:

- I : representa la imagen o matriz de entrada.
- K : representa el kernel o filtro.
- S : es la matriz de salida resultante, la cual contiene las características extraídas de la imagen tras aplicar la convolución.

En la Figura 19 se presenta un ejemplo de convolución 2D sin invertir el kernel.

Figura 19

Ejemplo de una convolución.



Nota. Adaptado de Goodfellow et al. (2016).

2.2.3.10 Padding

El *padding* es una característica fundamental en las redes neuronales convolucionales (CNN) que permite conservar el tamaño original de la imagen de entrada durante la operación de convolución. Esta técnica consiste en agregar valores, típicamente ceros, alrededor de la matriz de entrada, representados mediante p . Su principal objetivo es preservar las dimensiones espaciales y evitar la pérdida de información, especialmente en los bordes de la imagen.

Sin *padding* ($p = 0$), al aplicar un kernel de tamaño $f \times f$ sobre una matriz de entrada I de dimensiones $n \times n$, la matriz de salida resultante tiene un tamaño reducido de:

$$\text{Tamaño de salida} = (n - f + 1) \times (n - f + 1) \quad (2.7)$$

lo que puede ser problemático en redes profundas debido a la disminución progresiva de las dimensiones y la subrepresentación de las características ubicadas en los bordes.

Con la inclusión de *padding*, las dimensiones de la salida se ajustan mediante la fórmula:

$$\text{Tamaño de salida} = \left(\frac{n + 2p - f}{s} + 1 \right) \times \left(\frac{n + 2p - f}{s} + 1 \right) \quad (2.8)$$

donde p representa la cantidad de filas y columnas de *padding* añadidas, y s es el *stride*.

En el caso de *padding same*, p se define como:

$$p = \frac{f-1}{2} \quad (2.9)$$

lo que asegura mantener las dimensiones originales de la entrada.

Esta técnica asegura un equilibrio en el análisis de los píxeles centrales y periféricos, preserva la información y facilita el diseño de arquitecturas profundas.

El *zero-padding* es el método más utilizado debido a su simplicidad y eficacia, siendo clave para optimizar el aprendizaje, conservar la información espacial y construir modelos más robustos en aplicaciones de visión artificial.

En la figura 20 ilustra una operación de convolución donde una matriz 6x6 con padding=1 (ceros alrededor) interactúa con un kernel 3x3, produciendo una matriz resultante 4x4. Los valores (85,90,80,88,92,85,86,89,82) de la matriz de entrada generan el valor 93 en la salida.

Figura 20

Ejemplo de Convolución 2D con Padding igual a 1.

Matriz de Entrada con Padding = 1 (6x6)

0	0	0	0	0	0	0	0
	75	80	85	90	80	75	
			85	90	80		
			88	92	85		
			86	89	82		

Kernel 3x3

-1	-2	-1
0	1	0
1	2	1

Matriz Resultante (4x4)

		93	

Nota. Adaptado de Goodfellow et al. (2016).

2.2.3.11 Stride

El stride representa el desplazamiento del kernel durante la operación de convolución en redes neuronales convolucionales. Este parámetro fundamental se define como el número de píxeles que el kernel avanza sobre la imagen de entrada en cada paso del proceso de convolución. Por ejemplo, un stride de 1 significa que el kernel se mueve un píxel a la vez, realizando un análisis exhaustivo de la imagen, mientras que valores mayores generan desplazamientos más amplios.

En términos matemáticos, al aplicar un stride s junto con un padding p a una matriz de entrada $n \times n$ utilizando un kernel $f \times f$, las dimensiones de la matriz resultante se calculan

mediante la expresión:

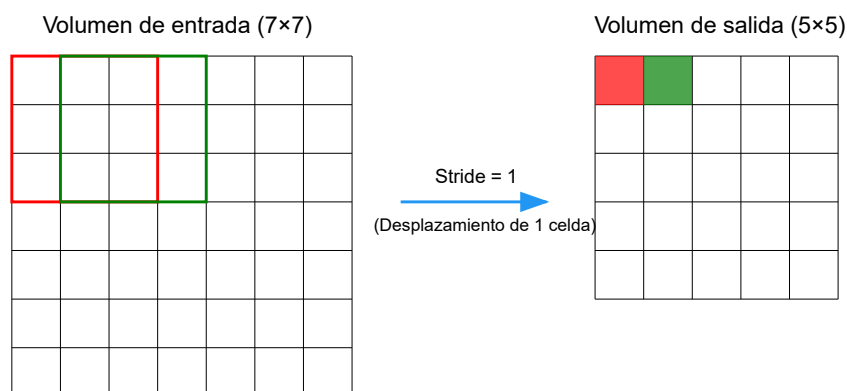
$$\left\lfloor \frac{n + 2p - f}{s} + 1 \right\rfloor \times \left\lfloor \frac{n + 2p - f}{s} + 1 \right\rfloor \quad (2.10)$$

Esta fórmula resulta esencial para comprender cómo el *stride* afecta las dimensiones de salida. Un stride mayor reduce las dimensiones de la matriz resultante, actuando como un mecanismo de submuestreo que puede ayudar a reducir la carga computacional mientras mantiene la capacidad de la red para extraer características relevantes de la imagen.

Los ejemplos muestran dos casos de convolución: con stride=1, Figura 21 el kernel se mueve una celda por vez generando una salida 5×5, mientras que en la Figura 22 con stride=2 se desplaza dos celdas produciendo una salida 3×3, ilustrando cómo el tamaño del stride afecta la dimensionalidad del resultado final.

Figura 21

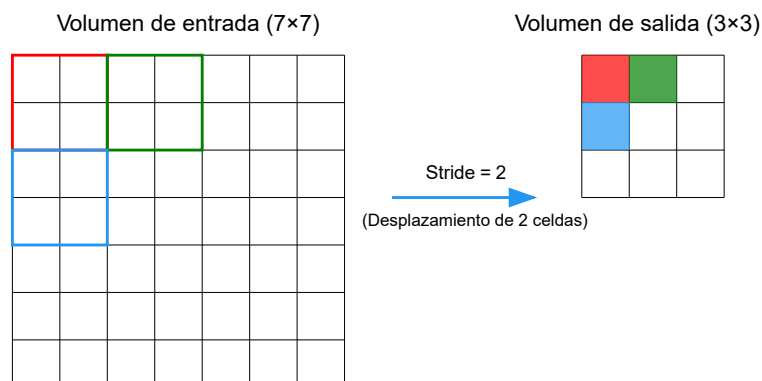
Operación de Convolución 2D con stride igual a 1.



Nota. Adaptado de Condori Quispe (2019).

Figura 22

Operación de Convolución 2D con stride igual a 2.



Nota. Adaptado de Condori Quispe (2019).

2.2.3.12 La Convolución en Imágenes RGB

La convolución en imágenes RGB representa una extensión tridimensional del proceso bidimensional, donde cada imagen incorpora tres canales de color (Rojo, Verde y Azul). La imagen de entrada se representa como un tensor $n \times n \times 3$, donde n define las dimensiones espaciales y 3 corresponde a los canales RGB, mientras que el filtro se configura como un tensor $f \times f \times 3$, manteniendo la misma profundidad que la imagen de entrada.

En este proceso, la operación se realiza simultáneamente sobre los tres canales, donde cada canal del filtro interactúa con su canal correspondiente, integrando la información en una única representación de características. La dimensión de salida se determina mediante la fórmula:


$$\text{Dimensión de salida} = \left\lfloor \frac{n + 2p - f}{s} + 1 \right\rfloor \times \left\lfloor \frac{n + 2p - f}{s} + 1 \right\rfloor \quad (2.11)$$

donde n representa las dimensiones de entrada, p el *padding*, f el tamaño del filtro y s el *stride*.

La Figura 23 muestra una convolución RGB donde una entrada de $6 \times 6 \times 3$ es procesada por dos filtros diferentes de $3 \times 3 \times 3$ (uno para bordes verticales y otro para bordes horizontales). Con un *padding* igual a 0 y un *stride* de 1, cada filtro genera un mapa de características de dimensiones $4 \times 4 \times 1$, resultando en una salida final de tamaño $4 \times 4 \times 2$, la cual representa las diferentes características detectadas por cada filtro.

Figura 23

Operación de Convolución 2D con stride igual a 2.



Nota. Imagen extraída de Condori Quispe (2019).

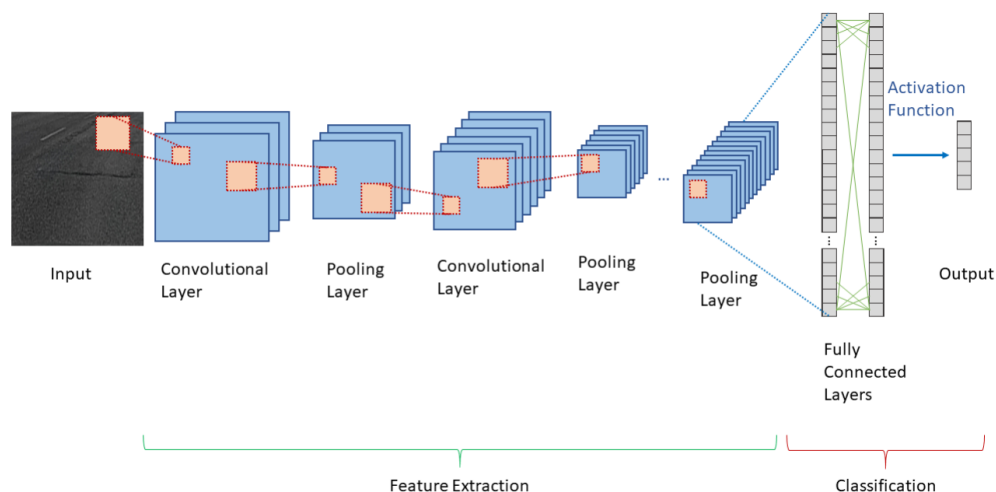
2.2.3.13 Arquitectura de una red Convolucional

La arquitectura de una Red Neuronal Convolutiva (CNN) constituye una estructura jerárquica especializada en el procesamiento de imágenes digitales, que transforma los datos a través de múltiples capas secuenciales. El proceso inicia cuando la imagen ingresa como una matriz de valores numéricos, pasando por capas convolucionales que realizan extracciones de características mediante operaciones paralelas, seguidas por funciones de activación no lineales que actúan como detectores de patrones. Posteriormente, las capas de pooling modifican y reducen la dimensionalidad de los datos, preservando la información relevante (LeCun et al., 2015). Esta secuencia de capas puede repetirse varias veces según la arquitectura específica, culminando en una capa totalmente conectada que realiza la clasificación final. Este diseño permite que la red aprenda progresivamente características desde niveles simples hasta representaciones más abstractas y complejas de la información visual.

En la Figura 24 se ilustra la arquitectura fundamental de una Red Neuronal Convolutiva (CNN), que procesa una imagen RGB mediante dos etapas principales: la extracción de características, que utiliza capas convolucionales y de pooling alternadas para detectar patrones relevantes en la imagen, y la clasificación, que emplea capas totalmente conectadas con una función de activación para generar la predicción final.

Figura 24

Arquitectura de una red neuronal convolucional.



Nota. Tomado de Khan et al. (2018).

La Capa de Convolución

Representa un componente fundamental en las redes neuronales convolucionales, donde se realiza una operación matemática específica entre la capa de entrada y un conjunto de n *kernels*. Este proceso se complementa con la adición de un término de *sesgo* (bias) y la aplicación subsecuente de una función de activación no lineal, conocida como *ReLU* (Rectified Linear Unit).

La incorporación de *ReLU* cumple un papel crucial al introducir no linealidad en el sistema, contrastando con la naturaleza puramente lineal de las operaciones de convolución, que se limitan a multiplicaciones y sumas. Aunque históricamente se emplearon funciones de activación como tanh y sigmoid, la comunidad científica ha demostrado que ReLU ofrece ventajas significativas, particularmente en términos de velocidad de entrenamiento, sin comprometer la precisión del modelo.


función ReLU

La función ReLU (Rectified Linear Unit), definida como $f(x) = \max(0, x)$, es clave en redes neuronales por su simplicidad. Activa solo neuronas con entradas positivas, lo que la hace más eficiente que funciones como la sigmoide o la tangente hiperbólica. Además, su naturaleza lineal no saturante acelera la convergencia del descenso de gradiente, facilitando el entrenamiento de modelos profundos usados en tareas de visión artificial, como clasificación de imágenes, (ver Figura 25)

$$f(x) = \max(0, x) \quad (2.12)$$

Figura 25

Función de activación ReLU.



Nota. Adaptado de Khan et al. (2018).

Softmax

La función Softmax representa una técnica avanzada de activación que transforma un conjunto de valores numéricos en una distribución de probabilidades, donde cada salida corresponde a la probabilidad de pertenencia a una clase específica. Esta función se implementa principalmente en la capa final de las redes neuronales diseñadas para clasificación multiclase, donde generaliza múltiples funciones sigmoideas para producir probabilidades normalizadas, garantizando que la suma de todas las probabilidades sea igual a 1.


$$\text{softmax}(Z)_j = \frac{e^{Z_j}}{\sum_{k=1}^K e^{Z_k}} \quad (2.13)$$

Capa de Reducción o Pooling

La capa de Pooling reduce la dimensionalidad espacial en redes convolucionales, disminuyendo el costo computacional sin perder información clave. La técnica más común, max-pooling, selecciona el valor máximo de regiones específicas (por ejemplo, reduce una ventana 4x4 a 2x2), como se muestra en la Figura 26. Esto preserva características importantes, como bordes o texturas, optimizando tareas de visión artificial como detección de objetos.

Figura 26

Aplicación de Max-Pooling.



Nota. Adaptado de: Stanford University, CS231n Convolutional Neural Networks for Visual. <https://cs231n.github.io/convolutional-networks/>

Capa totalmente conectada

La Capa Totalmente Conectada representa la etapa final del procesamiento en una red

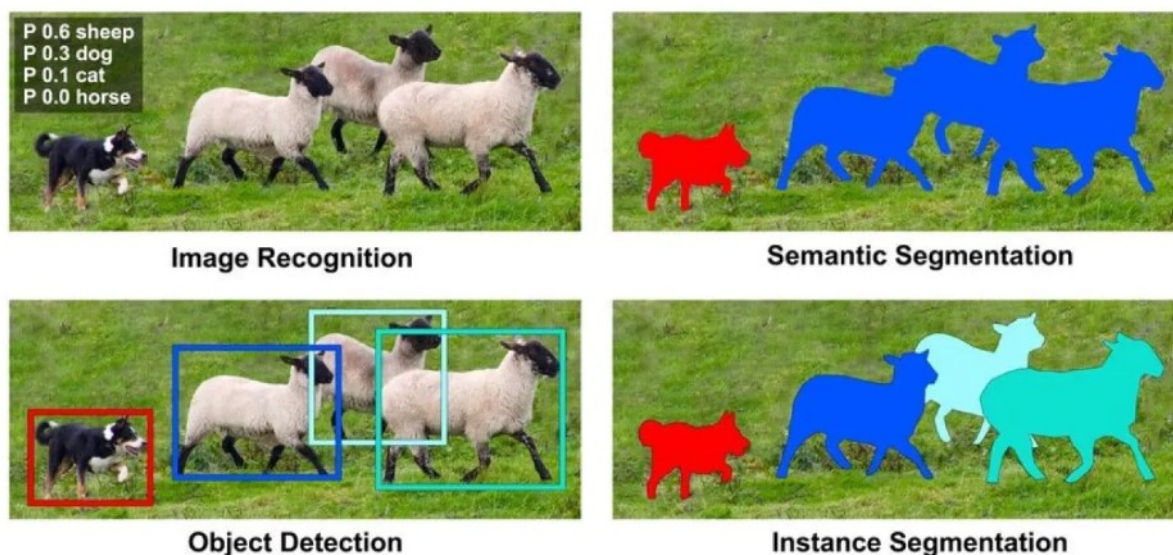
neuronal convolucional, donde las características extraídas previamente se transforman en predicciones específicas. Esta capa opera recibiendo el vector aplanado de características y conectando cada una de sus neuronas con todas las activaciones de la capa anterior, similar a la arquitectura de una Red Neuronal Artificial tradicional. El proceso se realiza mediante una multiplicación matricial entre los pesos aprendidos y las entradas, seguido de la adición de un término de sesgo, permitiendo así la integración de las características extraídas para tareas de clasificación o regresión.

2.2.3.14 Detección de objetos y segmentación de imágenes

La detección de objetos es una técnica de visión artificial que posibilita la identificación y ubicación de objetos en una imagen o video. Esta capacidad permite contar objetos en una escena, determinar su ubicación precisa y realizar un seguimiento preciso, todo ello mientras se etiqueta con exactitud. En particular, como se ilustra en la Figura 27, la detección de objetos traza cuadros delimitadores alrededor de los objetos identificados, lo que facilita la localización de su posición en una escena dada.

Figura 27

Ejemplo de detección y segmentación de de objetos.



Nota. Imagen extraída de: Una guía para profundizar en la detección de objetos en 2025
<https://www.ultralytics.com/es/blog/a-guide-to-deep-dive-into-object-detection-in-2025>

La definición del problema de la detección de objetos es determinar donde se encuentran los objetos en una imagen determinada (localización de objetos) y a qué categoría pertenece

cada objeto (clasificación de objetos) (Zhao et al., 2019). El proceso de los modelos tradicionales de detección de objetos se divide principalmente en tres etapas:

- Selección de región informativa, extracción de características y clasificación. Selección de región informativa. Como diferentes objetos pueden aparecer en cualquier posición de la imagen y tener diferentes proporciones o tamaños, es una elección natural escanear toda la imagen con una ventana deslizante de múltiples escalas. Es una operación computacionalmente costosa y produce demasiadas ventanas redundantes.
- Extracción de características. Para reconocer los objetos, se necesitan características visuales que puedan proporcionar una representación semántica y robusta.
- Clasificación. Es necesario un clasificador para distinguir el objeto de destino de todas las demás categorías y hacer que las representaciones sean más jerárquicas, semánticas e informativas para el reconocimiento visual.

Gracias a los modelos de DL, se puede conseguir desarrollar estas etapas con un mejor desempeño con la introducción de Regiones con características CNN o *Regions with CNN features* (R-CNN). Estas arquitecturas más profundas tienen la capacidad de aprender características más complejas.

La segmentación de imágenes representa un nivel más avanzado que la detección de objetos, ya que busca identificar precisamente qué píxeles pertenecen a cada objeto. Se distinguen tres categorías principales:

- **Segmentación semántica:** Clasifica cada píxel de la imagen en una categoría predefinida, pero no distingue entre instancias de la misma clase (Long et al., 2015).
- **Segmentación de instancias:** Detecta cada objeto y genera una máscara de segmentación para cada instancia, diferenciando objetos de la misma clase (He et al., 2017).
- **Segmentación panóptica:** Combina la segmentación semántica (para fondos y objetos amorfos) con la segmentación de instancias (para objetos contables), proporcionando una comprensión unificada de la escena (Kirillov et al., 2019).

Métricas de rendimiento

La evaluación efectiva de sistemas de detección de objetos requiere un análisis cuantitativo que va más allá de la simple detección. Esta evaluación se fundamenta en métricas específicas que determinan objetivamente el rendimiento del sistema (Aurélien, 2022).

La validación cruzada emerge como metodología clave, dividiendo sistemáticamente los datos de entrenamiento en subconjuntos para entrenar y validar el modelo. Este enfoque no solo proporciona una estimación del rendimiento mediante el promedio de errores de validación, sino que también determina la precisión de dicha estimación (Aurélien, 2022). La implementación efectiva de estas métricas requiere establecer definiciones fundamentales como base para un análisis sistemático del rendimiento.

Intersección sobre la unión (IoU)

Es una métrica utilizada para medir el grado de superposición entre dos cuadros delimitadores (*Bounding Boxes*). Estos cuadros son representaciones de las regiones donde se localizan los objetos y se clasifican en dos tipos:


- **Groundbox:** Son las anotaciones manuales realizadas sobre las imágenes, utilizadas como referencia en el entrenamiento y validación del sistema de detección de objetos.
- **Cuadros detectados:** Son las regiones que el sistema de detección identifica como objetos.

La métrica **IoU** evalúa el porcentaje de superposición entre el cuadro anotado y el cuadro detectado. Su valor varía entre 0 y 1:

- **IoU = 1:** Indica una coincidencia perfecta entre el cuadro anotado y el cuadro detectado.
- **IoU < 1:** Mientras menor sea el valor, menor será la precisión y confiabilidad de la detección.

La Figura 28 ilustra gráficamente el concepto de intersección sobre la unión.

Figura 28*Intersección sobre la unión (IoU)*

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$


Nota. Extraído de Shah (2018).

Evaluación de detección de objetos

Para determinar si una detección es válida o no, se consideran los siguientes conceptos:

- **Verdadero Positivo (True Positive, TP):** Se produce cuando el sistema detecta correctamente un objeto y el valor de IOU es mayor o igual al umbral predefinido.
- **Falso Positivo (False Positive, FP):** Ocurre cuando el sistema detecta un objeto, pero el valor de IOU es menor al umbral, lo que indica una detección incorrecta.
- **Falso Negativo (False Negative, FN):** Sucede cuando existe un cuadro delimitador anotado (*Ground Truth*), pero el sistema no detecta ningún objeto en esa región.
- **Verdadero Negativo (True Negative, TN):** Este concepto no se aplica en la detección de objetos, ya que implicaría evaluar cuadros vacíos sin objetos, lo cual es impráctico debido a la cantidad infinita de posibles cuadros sin detección.

Umbral de IOU

El umbral de IOU define el valor mínimo de superposición entre el cuadro anotado y el cuadro detectado para considerar que la detección es válida. Los umbrales más utilizados son:

- 50% (0.50): Proporciona una evaluación más flexible.
- 75% (0.75): Nivel de precisión intermedio.
- 95% (0.95): Requiere una coincidencia casi exacta, adecuado para aplicaciones donde la precisión es crítica.

Un umbral más alto exige una mayor superposición, lo que aumenta la rigurosidad de la

detección.

Precisión y Recall

La precisión es una métrica que evalúa qué tan eficiente es un modelo al identificar correctamente los objetos en una imagen. Específicamente, mide la proporción de detecciones realizadas por el sistema que corresponden efectivamente a objetos reales. En otras palabras, la precisión determina cuántas de las detecciones son correctas con respecto al total de objetos identificados. Su valor ideal es **1**, lo cual indicaría que todas las predicciones son exactas, sin falsos positivos.

La precisión se calcula utilizando la siguiente ecuación matemática:

$$\text{Precisión} = \frac{\text{TP}}{\text{TP} + \text{FP}} = \frac{\text{TP}}{\text{total de detecciones}} \quad (2.14)$$

donde:

- **TP (True Positives):** Número de detecciones correctas.
- **FP (False Positives):** Número de detecciones incorrectas.

Por otro lado, el **Recall** o sensibilidad es una métrica que mide la capacidad del modelo para detectar todos los objetos reales presentes en una imagen. Es decir, determina qué fracción de los objetos existentes ha sido identificada correctamente. Un valor elevado de *Recall* indica que el sistema es capaz de localizar la mayoría de los objetos relevantes, reduciendo al mínimo los falsos negativos.

La fórmula para calcular el Recall es:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} = \frac{\text{TP}}{\text{total de objetos reales}} \quad (2.15)$$

donde:

- **TP (True Positives):** Número de objetos detectados correctamente.
- **FN (False Negatives):** Número de objetos reales no detectados.

Precisión media (mAP)

La Precisión Media (mAP) constituye una métrica fundamental en la evaluación de sistemas de detección de objetos, basada en el cálculo del área bajo la curva Precision-Recall. Esta metodología unifica dos aspectos críticos: la precisión en detecciones positivas y la exhaustividad en la identificación de objetos, generando un indicador numérico único

que sintetiza el rendimiento global del sistema. Esta medida facilita la evaluación objetiva entre diferentes modelos y establece un estándar cuantitativo en visión por computadora, permitiendo determinar la eficacia del detector mediante un valor único y comparable.

2.2.3.15 La red You Only Look once (YOLO)

YOLO (You Only Look Once) constituye una arquitectura de detección de objetos que se distingue por su eficiente balance entre velocidad y precisión. Desarrollada por Joseph Redmond, implementa un proceso de detección unificado mediante una única propagación a través de su red neuronal convolucional, permitiendo la determinación simultánea de cuadros delimitadores (bounding boxes), la evaluación de probabilidad y la clasificación de objetos en tiempo real (Redmon et al., 2016).

A diferencia de los sistemas tradicionales de detección, que requieren múltiples pasadas sobre la imagen, YOLO procesa la imagen completa en una sola evaluación, dividiendo la imagen en regiones y prediciendo simultáneamente los cuadros delimitadores y las probabilidades para cada región. Esta aproximación unificada permite que YOLO razone globalmente sobre la imagen y sus detecciones, lo que resulta en un sistema altamente eficiente y preciso para la detección de objetos en aplicaciones de tiempo real.

La arquitectura YOLO destaca por tres beneficios esenciales:

- **Velocidad Superior:** Reduce la detección a un problema de regresión lineal simple, eliminando procesos complejos y ejecutando predicciones en una única pasada.
- **Análisis Completo:** Procesa la imagen íntegramente, no por regiones, minimizando errores en la identificación de objetos al considerar todo el contexto.
- **Generalización Efectiva:** Desarrolla representaciones versátiles que reducen errores al procesar nuevos datos, superando a métodos tradicionales.


YOLOv8

YOLOv8 (You Only Look Once, versión 8), desarrollado por Ultralytics y lanzado el 10 de enero de 2023, es un modelo avanzado de detección de objetos que combina precisión y velocidad mediante un enfoque de una sola pasada. A diferencia de métodos tradicionales que separan la propuesta de regiones y la clasificación, YOLOv8 predice simultáneamente cuadros delimitadores, clases y puntajes de confianza, lo que lo hace adecuado para aplicaciones en tiempo real. Basado en los avances de versiones anteriores (YOLOv5, YOLOv7), introduce optimizaciones y nuevas funcionalidades que lo posicionan como una

solución versátil (Jocher et al., 2023), ver Figura 31.

Figura 29

Comparativa de YOLOv8 con versiones anteriores



Nota. Gráficos comparativos que muestran la superioridad de YOLOv8 frente a versiones anteriores, destacando mayor precisión con menor tamaño (izquierda) y mayor velocidad (derecha) en tareas de detección de objetos. Imagen extraída de <https://docs.ultralytics.com/es/models/yolov8/#overview>

Arquitectura de YOLOv8

La arquitectura de YOLOv8 consta de tres componentes principales: backbone, neck y head, cada uno optimizado para procesar imágenes y generar detecciones precisas.

1. **BACKBONE (CSPDarknet):** El backbone es la columna vertebral del modelo, responsable de extraer características de la imagen de entrada:
 - Imagen de Entrada: RGB de 640×640 píxeles. Esta es la resolución estándar con la que trabaja YOLOv8N.
 - Conv2D (Convolución 2D): Primera capa que aplica filtros convolucionales a la imagen para detectar características básicas como bordes, texturas y gradientes. Es el primer paso en la extracción de características.
 - Bloques C2f (Cross Stage Partial): Estos bloques son una mejora de las conexiones residuales tradicionales. El diseño "Cross Stage Partial" divide los canales en dos partes: una pasa directamente a la siguiente etapa, mientras la otra pasa por varias convoluciones. Esto reduce los cálculos manteniendo el rendimiento.

- SPPF (Spatial Pyramid Pooling - Fast): Este módulo captura contexto a múltiples escalas mediante pooling paralelo con diferentes tamaños de kernel, seguido de una fusión de estas características. La versión "Fast" optimiza este proceso para mayor eficiencia.
 - Salida del Backbone: Produce mapas de características en tres escalas diferentes (P3, P4, P5), que representan características a resoluciones progresivamente más bajas pero con mayor contenido semántico.
2. NECK (PANet - Path Aggregation Network) El cuello conecta el backbone con las cabezas de detección/segmentación, permitiendo que la información fluya entre diferentes niveles de resolución:
- Upsample (Aumento de resolución): Aumenta el tamaño espacial de los mapas de características de menor resolución para combinarlos con mapas de mayor resolución.
 - Concat (Concatenación): Fusiona mapas de características de diferentes resoluciones alineándolos espacialmente y combinándolos por sus canales.
 - Bloques C2f: Procesan las características concatenadas para mejorar la fusión de información multi-escala.
 - Conexiones laterales: Permiten que la información fluya entre diferentes niveles de la red, combinando características de alta resolución (detalles espaciales) con características de baja resolución (información semántica).
 - Salida del Neck: Conjunto de mapas de características que contienen información fusionada de múltiples escalas, con enriquecimiento bidireccional (de arriba abajo y de abajo arriba).
3. HEAD (Cabeza Dual): Las cabezas son las responsables de la predicción final. YOLO8N tiene una arquitectura dual con dos cabezas especializadas: Cabeza de Detección:
- Cabeza de Segmentación:

- Cajas Delimitadoras (x, y, ancho, alto): Coordenadas normalizadas que localizan cada objeto detectado.
- Confianza de Detección: Valor que indica la certeza del modelo sobre la presencia de un objeto.
- Probabilidades de Clase: Distribución de probabilidad sobre las posibles categorías de objetos.

Cabeza de Segmentación:

- Prototipos de Máscara: Componentes básicos de las máscaras que se combinan para formar la máscara final.
- Coeficientes de Máscara: Pesos que indican cómo combinar los prototipos para cada objeto específico.
- Máscaras por Instancia: Máscara binaria para cada objeto individual detectado.

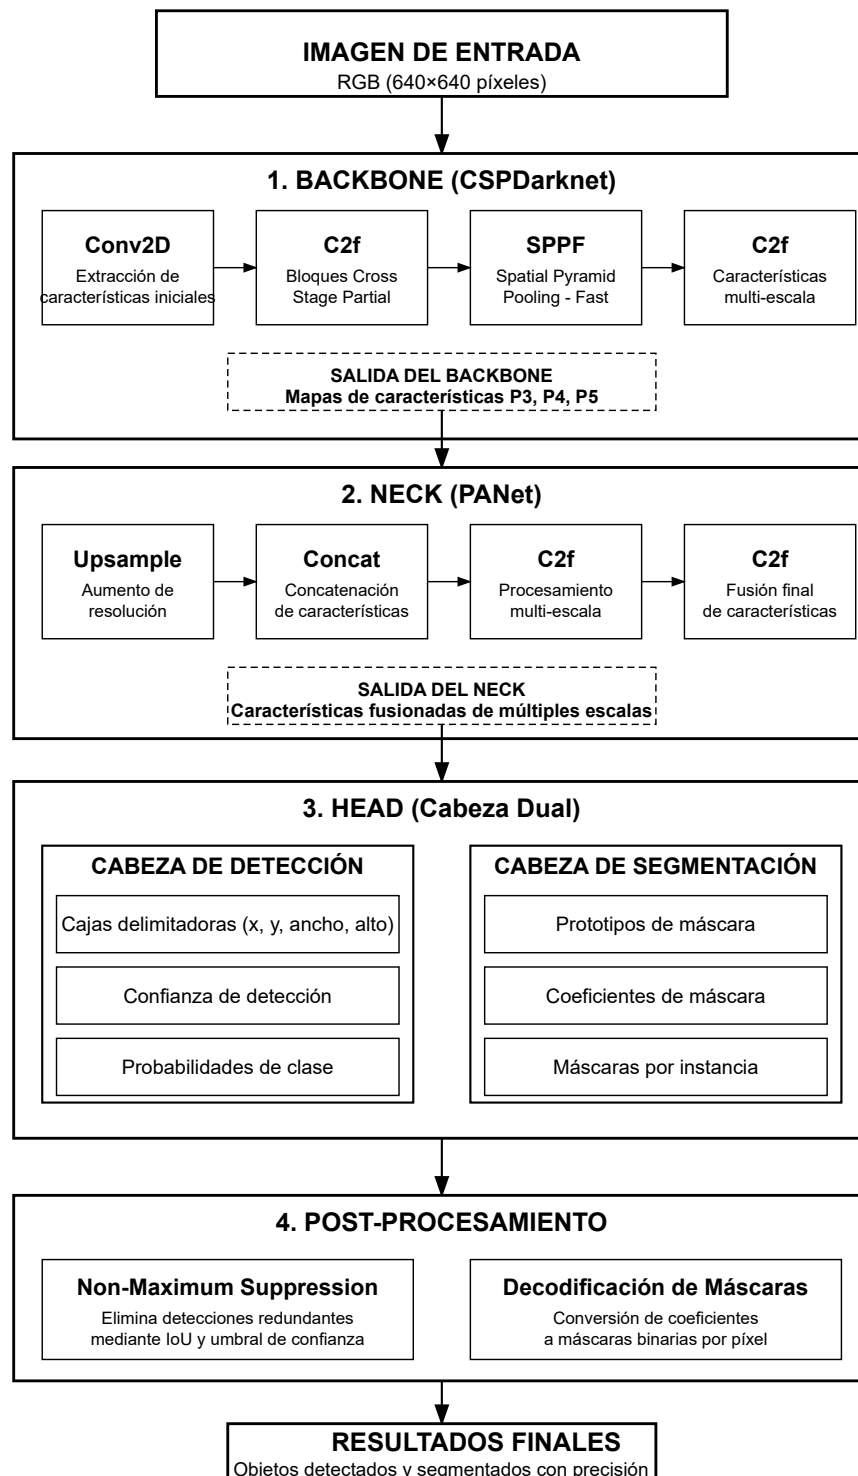
4. Post-Procesamiento: Etapa final donde se refinan los resultados crudos del modelo:

- Non-Maximum Suppression (NMS): Elimina detecciones duplicadas o superpuestas. Si varias cajas detectan el mismo objeto, el NMS mantiene solo la de mayor confianza basándose en:
- IoU (Intersection over Union): Medida de superposición entre cajas. Umbral de confianza: Filtra detecciones de baja confianza.
- Decodificación de Máscaras: Transforma los coeficientes abstractos de máscara y los prototipos en máscaras binarias por píxel para cada instancia detectada.

5. Resultados finales: El output del modelo consiste en:

- Objetos detectados con sus cajas delimitadoras, etiquetas de clase y valores de confianza. Para cada objeto, una máscara de segmentación a nivel de píxel que delinea precisamente su forma.
- Este diseño arquitectónico permite que YOLO8N realice simultáneamente detección y segmentación de objetos con alta precisión y velocidad, haciendo que sea adecuado para aplicaciones en tiempo real.

Figura 30
arquitectura YOLOv8n-seg



Nota. Diagrama de procesos de la arquitectura simplificada de YOLOv8n-Seg, que muestra el flujo desde la imagen de entrada hasta la salida segmentada. Incluye extracción de características (Backbone), fusión multi-escala (Neck), cabeza dual para detección y segmentación (Head) y post-procesamiento para obtener resultados precisos de objetos detectados y segmentados.

2.2.4. El seguimiento de objetos (Object Tracking)

El seguimiento de objetos (Object Tracking) constituye un avance revolucionario en el campo de la visión artificial, centrándose en la detección y monitoreo continuo de elementos dinámicos en secuencias de vídeo (Yilmaz et al., 2006). Este campo ha transformado la capacidad de los sistemas computacionales para comprender y analizar el comportamiento espacio-temporal de los objetos. En el contexto de Multiple Object Tracking (MOT), esto implica:

- Detección: Identificación de objetos en cada fotograma individual
- Asociación: Vinculación de detecciones del mismo objeto entre fotogramas consecutivos
- Mantenimiento de identidad: Asignación de identificadores únicos a cada objeto rastreado

Como señala Bewley et al. (2016), el seguimiento robusto es fundamental para numerosas aplicaciones que requieren análisis de movimiento y comportamiento de objetos, a continuación se muestran los tipos de seguimiento de objetos:

2.2.4.1 El seguimiento de un solo objeto (SOT)

El SOT constituye una tecnología avanzada de visión artificial que permite rastrear automáticamente un objeto específico a lo largo de una secuencia de vídeo (Li et al., 2019). Esta metodología enfrenta cuatro retos principales:

- Oclusión: Pérdida temporal del objeto cuando es cubierto por otros elementos
- Transformaciones morfológicas: Cambios en la apariencia del objeto a lo largo del tiempo
- Interferencia del fondo: Dificultad para distinguir entre el objeto y elementos del entorno
- Movimientos complejos: Trayectorias no lineales o cambios bruscos de dirección

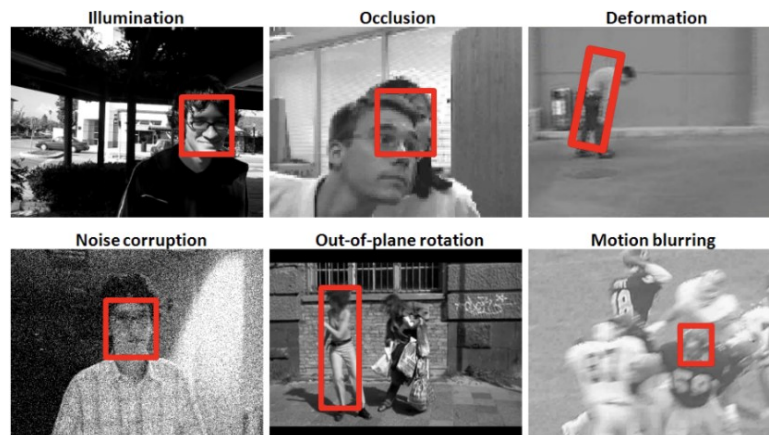
Además de estos retos fundamentales identificados en la literatura, la experiencia empírica en implementaciones prácticas de sistemas SOT revela desafíos adicionales que impactan significativamente su rendimiento:

- Variaciones de iluminación: Cambios de luz que alteran significativamente la apariencia visual del objeto

- Desenfoque por movimiento: Distorsión causada por movimientos rápidos del objeto o la cámara
- Cambios de escala: Variaciones en el tamaño aparente del objeto al acercarse o alejarse de la cámara
- Salida del campo visual: Pérdida temporal del objeto cuando abandona el encuadre

Figura 31

Ejemplos de problemas comunes en el seguimiento visual



Nota. iluminación variable, oclusión parcial, deformación del objeto, corrupción por ruido, rotación fuera de plano y desenfoque por movimiento. Cada caso ilustra cómo estos factores dificultan el mantenimiento preciso de la identidad de los objetos a través de secuencias de video. Imagen extraída de <https://www.aprendemachinelearning.com/seguimiento-de-objetos-con-yolo-v8-y-bytetrack-object-tracking/>

2.2.4.2 El Seguimiento Multi-Objeto (MOT)

El MOT constituye una tecnología esencial en la visión por computadora moderna, permitiendo rastrear simultáneamente diversos objetivos en secuencias de video, asignando trayectorias independientes a cada uno (Luo et al., 2022). Aunque enfrenta desafíos como la oclusión entre objetos y la diferenciación entre objetivos similares, se han desarrollado dos enfoques principales para abordarlos:

- Seguimiento por detección: Identifica y rastrea objetos secuencialmente
- Detección y seguimiento Conjunto: Realiza ambas tareas simultáneamente

Como destaca Milan et al. (2016), impulsado por el aprendizaje profundo, el campo ha evolucionado significativamente con algoritmos como SORT, DeepSORT, Tractor y

JDE, que han demostrado excelente rendimiento en aplicaciones prácticas como vigilancia automatizada, reconocimiento de acciones e interacción humano-computadora.

2.2.4.3 Seguimiento basado en geometría y firmas espaciales

Este enfoque, implementado en el programa analizado, representa un tipo especializado de seguimiento particularmente efectivo para objetos estáticos en escenarios donde el movimiento relativo es causado principalmente por el desplazamiento de la cámara, como en el caso de defectos en pavimentos (Zhou et al., 2019). Sus características principales incluyen:

- Identificación mediante firmas geométricas: Caracterización de objetos utilizando propiedades espaciales discretizadas
- Asociación basada en similitud espacial: Uso de métricas como IoU y distancia entre centros para vincular detecciones
- Independencia de modelos dinámicos complejos: No requiere predicción de trayectorias o filtros de Kalman
- Optimización para contextos específicos: Ajuste de parámetros según la naturaleza de los objetos rastreados

Este método destaca por su simplicidad computacional y robustez en entornos donde los objetos mantienen posiciones relativamente estables, como es el caso de defectos en infraestructuras.

2.2.4.4 Persistencia Temporal

La persistencia temporal es un concepto esencial en el procesamiento de video que permite filtrar detecciones espurias, basándose en la premisa de que un objeto válido debe aparecer consistentemente en múltiples fotogramas consecutivos (Stauffer & Grimson, 1999). Factores que pueden afectar la consistencia de las detecciones incluyen: Vibraciones de la cámara, cambios en la iluminación, errores inherentes al modelo de detección

Como destaca Andriluka et al. (2008)), esta técnica es crucial para reducir falsos positivos y mejorar la robustez del seguimiento.

Capítulo III: Método de la investigación

3.1 Método

Este estudio es deductivo, parte de la capacidad de la visión artificial para evaluar infraestructuras viales y la aplica al caso particular de los pavimentos flexibles en Ayacucho, utilizando el programa PAVEMAI constituido por algoritmos de inteligencia artificial para generar métricas cuantitativas que determinan su estado de conservación.

3.2 Orientación de investigación

Tendrá una orientación aplicada, según Caballero (2014). “La investigación aplicada cuyo propósito fundamental es dar solución a problemas prácticos”

Este estudio busca ofrecer una solución efectiva al problema mediante el desarrollo de un método innovador basado en visión artificial para evaluar el estado de los pavimentos flexibles. Esta investigación no solo busca avanzar en la tecnología, sino también mejorar significativamente las prácticas actuales de evaluación de pavimentos.

3.3 Enfoque

La investigación tiene un enfoque cuantitativo, porque se analizan imágenes de pavimentos flexibles para cuantificar métricas como el área y cantidad de fallas para calcular la calificación de la condición del pavimento (CC) a partir del desempeño del modelo YOLOv8n-seg (mAP50, precisión, recuperación), asegurando una validación objetiva de los resultados.

3.4 Nivel de investigación

La investigación se enmarca en el nivel aplicativo, que, según Supo y Zacarías (2020), se centra en implementar una intervención sobre la población de estudio para mejorar directamente una condición específica, evaluando sus procesos, resultados e impacto. A diferencia de niveles como el predictivo, en el nivel aplicativo la intervención tiene como propósito principal optimizar una condición práctica, demostrando una mejora tangible en un aspecto relacionado con la población de estudio.

En este caso, la población está constituida por imágenes digitales de pavimentos flexibles con fallas superficiales, capturadas en las carreteras de Ayacucho. La intervención consiste en aplicar un sistema de visión artificial (YOLOv8n-seg) para procesar y analizar estas imágenes de manera automatizada, con el objetivo de optimizar los procesos de evaluación del estado de conservación de pavimentos. Este método tecnológico detecta, clasifica y cuantifica las fallas superficiales presentes en las imágenes, generando métricas como la calificación de condición del pavimento (CC), lo que genera un procesos automatizado frente a metodologías tradicionales.

3.5 Diseño de investigación

Según S. R. Hernández et al. (2014), el diseño de investigación corresponde a un conjunto organizado de etapas y estrategias que guían el desarrollo del estudio, desde la recolección hasta el análisis de datos, adaptándose a las características del problema investigado.

- **Según el propósito:** Cuasi-experimental, al implementar una intervención (método de visión artificial) y compararla con un método tradicional, pero sin asignación aleatoria de los grupos.
- **Según el número de mediciones:** Transversal, ya que la evaluación se realiza en un único momento.
- **Según la planificación de toma de datos:** Prospectivo, porque los datos se recolectan específicamente para esta investigación.

Descripción del diseño cuasi-experimental: Se selecciona un tramo de estudio de 2 km ya existente, sobre el cual se realiza una evaluación inicial utilizando el método tradicional del Ministerio de Transportes y Comunicaciones (MTC). Luego, se aplica el método de visión artificial (PAVEMAI) sobre el mismo tramo, sin una asignación aleatoria previa entre grupos. Las dos metodologías se utilizan para analizar el mismo tramo bajo condiciones controladas y comparables. Posteriormente, se contrastan los resultados obtenidos por ambos métodos en términos de fiabilidad. Dado que no se realiza una asignación aleatoria ni una manipulación completa de las variables del entorno, el diseño corresponde a un estudio cuasi-experimental.

3.6 Población y muestra

3.6.1. Población

La población está constituida por 20 000 imágenes digitales de pavimentos flexibles que presentan fallas superficiales, capturadas en las principales carreteras nacionales de Ayacucho (Rutas PE-28A, PE-26B, PE-3S y PE-28B). Estas imágenes representan las condiciones reales de deterioro de la región, abarcando diversos tipos de fallas y niveles de severidad características del entorno local.

3.6.2. Muestra

La selección se realiza mediante una técnica de muestreo no probabilística e intencional, priorizando imágenes representativas de las condiciones de las carreteras compuestas por pavimentos flexibles de Ayacucho. Para entrenar el modelo YOLOv8n-seg, se utilizan 3.020 imágenes etiquetadas (resolución 853x480 píxeles), asegurando la calidad y diversidad de los datos para la detección de fallas.

La validación del método de visión artificial propuesto se lleva a cabo en un tramo de 2 km de la Ruta PE-26B (Ayacucho-Huancavelica), seleccionado por su alta incidencia de fallas superficiales y su representatividad en la región.

3.7 Hipótesis

3.7.1. Hipótesis general

La implementación de un método mediante visión artificial es fiable en la evaluación del estado de conservación superficial de pavimentos flexibles, Ayacucho 2024.

3.7.1.1 Hipótesis específicas

- a) El desarrollo de un modelo de visión artificial permite una identificación y clasificación de forma automática diferentes tipos de falla en pavimentos flexibles.
- b) El desarrollo de un programa mediante algoritmos de inteligencia artificial permite determinar la calificación de condición del pavimento flexible.
- c) La metodología implementada mediante un modelo de visión artificial es fiable para la evaluación del estado de conservación de pavimentos flexibles en comparación con

las metodologías tradicionales.

3.8 Operacionalización de variables

La operacionalización de variables es un proceso esencial en la investigación científica, ya que permite traducir conceptos abstractos en indicadores observables y medibles. Según R. Hernández et al. (2014), “la operacionalización consiste en definir las variables en términos de procedimientos específicos de medición o manipulación, lo que implica establecer cómo se observarán y cuantificarán las variables en la realidad”.

Este proceso facilita la recolección de datos de forma sistemática y confiable, asegurando la validez del estudio al conectar la teoría con la observación empírica.

3.8.1. Identificación de Variables y dimensiones.

Variable de calibración

Método mediante un modelo de visión artificial

Se define como el uso de algoritmos de inteligencia artificial para procesar imágenes, detectando y clasificando fallas en pavimentos flexibles mediante el modelo YOLOv8n-seg. Como variable de calibración, se manipula al ajustar parámetros del modelo (como umbrales de confianza, IoU y persistencia temporal) para optimizar la detección y evaluación del estado de conservación de pavimentos, influyendo directamente en los resultados de la variable evaluativa.

Variable evaluativa

Estado de conservación superficial de pavimentos flexibles

Se refiere al estado físico y funcional de la capa superficial del pavimento, determinado por la presencia, tipo y severidad de fallas, según el Manual de Carreteras: Mantenimiento y Conservación Vial (MTC, 2018). Como variable evaluativa, mide el impacto de la implementación del método de visión artificial al comparar la fiabilidad de la evaluación automatizada con métodos tradicionales.

En la tabla 11 se presenta el cuadro de operacionalización de las variables identificadas, donde se detalla sus dimensiones, indicadores y unidad de medida.

Tabla 11
Operacionalización de las variables

Variable	Dimensión	Indicador	Unidad de medida
CALIBRACIÓN: Método mediante visión artificial	Parámetros de entrenamiento	Número de épocas	Numeral
		Tamaño de redimensionamiento de imágenes	Píxeles
	Precisión de detección y segmentación	mAP50 (Mean Average Precision)	0–1
		Precisión en la detección de fallas	%
		Tasa de verdaderos positivos	%
		Tasa de falsos negativos	%
		Tasa de falsos positivos	%
	Adaptabilidad a normativas	Cumplimiento con el Manual del MTC (2018)	Nominal
	Fiabilidad	Correlación entre calificación de condición con método tradicional (MTC)	0–1
	EVALUATIVA: Estado de conservación superficial del pavimento	Tipos de falla	11 tipos de falla (MTC)
5 tipos de falla (PAVEMAI)			m ² , cantidad
Nivel de severidad		G(1), G(2) y G(3) [MTC]	Nominal
		Bajo y alto (PAVEMAI)	Nominal
Índice de condición (CC)		Clasificación por el método MTC	0–1000
	Clasificación por método mediante visión artificial	0–1000	

3.9 Técnicas e instrumentos.

En este estudio se emplean técnicas de recolección, procesamiento y análisis de datos para implementar el método de visión artificial y evaluar el estado de conservación de pavimentos flexibles. A continuación, se describen las técnicas e instrumentos utilizados, organizados según las etapas del proceso: recolección de imágenes, preprocesamiento, etiquetado, entrenamiento del modelo, evaluación automatizada y análisis comparativo.

Tabla 12
Etapas, técnicas e instrumentos aplicados

Etapa	Técnica	Instrumento
1. Recolección de imágenes	Observación directa mediante captura de video en tránsito	Armadura metálica con soporte para celular Samsung A54 (1920x1080 px, 30 fps).
2. Preprocesamiento de imágenes	Estandarización de resolución y características visuales	Scripts en Python (OpenCV, PIL) para redimensionado a 853x480 px.
3. Etiquetado de datos	Anotación manual de imágenes para clasificación multiclase	Software LabelMe (Anaconda), con 3,020 imágenes y 4,512 instancias anotadas.
4. Entrenamiento del modelo	Aprendizaje supervisado con segmentación semántica (YOLOv8n-seg)	Python (Ultralytics) en equipo con GPU NVIDIA GTX 1650, Intel Core i7-9750H y 16 GB RAM (80 épocas, partición 70/30).
5. Evaluación automatizada	Análisis automatizado de video mediante métricas EFP y CC	Programa PAVEMAI en Python (tkinter, OpenCV, Ultralytics, NumPy, Pandas).
6. Análisis comparativo	Comparación estadística de resultados automatizados vs manuales	Scripts en Python (scipy, statsmodels), exportación y visualización con xlsxwriter.

Nota. Elaboración propia del proceso metodológico aplicado.

3.10 Técnicas estadísticas para el procesamiento de la información.

El procesamiento estadístico se llevó a cabo con técnicas no paramétricas, elegidas por el tamaño limitado de la muestra, la no normalidad de los datos y la presencia de valores atípicos. Las técnicas empleadas abarcan análisis descriptivo, prueba de normalidad, prueba de Wilcoxon para datos pareados, correlaciones de Spearman y Kendall, análisis de concordancia mediante los coeficientes de Lin y de Correlación Intraclase, análisis de Bland-Altman, y medidas de error, todas implementadas con un nivel de significancia estándar.

3.11 Desarrollo del trabajo de tesis

3.11.1. Recolección de imágenes

En la primera etapa de la investigación, se realizaron visitas a las carreteras departamentales que conectan a la región de Ayacucho, con el objetivo de identificar las fallas más representativas en los pavimentos flexibles. Esto permitió construir una base de datos amplia para desarrollar el método propuesto. Entre las fallas más comunes se identificaron fisuras longitudinales y transversales, piel de cocodrilo, baches, descascaramiento y parches. Estas observaciones permitieron clasificar cinco tipos de fallas predominantes en la región, en la Tabla 13 se presenta un resumen de las rutas visitadas para la recolección de imágenes.

Tabla 13

Fallas predominantes en carreteras principales de la región de Ayacucho

Ruta y tramo	Fallas Predominantes
PE-28A (Huascaura – Apacheta)	Fisuras, piel de cocodrilo, baches
PE-26B (C.P. Compañía – Santiago de Pischa)	Fisuras, baches
PE-3S (Ayacucho – Huanta)	Fisuras, descascaramiento
PE-28B (Huayllapampa – Quinua)	Fisuras

Nota. Recopilación de información basada en el reconocimiento visual de fallas en campo.

Carretera Ruta Nacional PE-28A (Vía Los Libertadores), tramo Huascaura – Apacheta:

En esta carretera, las fallas predominantes fueron fisuras, piel de cocodrilo y baches, que se presentan de manera continua a lo largo de la vía. Este tipo de deterioros indican problemas estructurales (figura 32).

Carretera Ruta Nacional PE-26B (vía hacia Huancavelica), tramo Centro Poblado de

Compañía – Distrito de Santiago de Pischa: Se observaron principalmente fisuras y baches, los cuales representan un peligro significativo en la seguridad vial.

Carretera Ruta Nacional PE-3S (vía hacia Junín), tramo Ciudad de Ayacucho – Ciudad

de Huanta: las fallas más frecuentes fueron fisuras y descascaramiento, comprometiendo la capacidad de carga del pavimento y un desgaste acelerado de la capa de rodadura (figura 32).

Carretera Ruta Nacional PE-28B (vía hacia Cusco), tramo Centro Poblado

Huayllapampa – Distrito de Quinua: Las fisuras destacaron como la falla principal.

Figura 32

Captura de video: (a) Carretera Ruta Nacional PE-28A; (b) Carretera Ruta Nacional PE-3S.



(a)

(b)

Nota. Recolección de imágenes de las principales vías de la región Ayacucho.

La captura se realizó por carril utilizando un prototipo de armadura de acero montado en una camioneta pickup, diseñado para sostener un celular Samsung A54 a 2.40 m de altura (figura 33), con un campo visual de 5.30 m transversalmente y 3.00 m longitudinalmente (figura 34). Este diseño optimizó la cobertura del pavimento durante el desplazamiento a 20-40 km/h, capturando las imágenes de manera perpendicular a la plataforma de la carretera. Los videos se grabaron en resolución de 1920x1080 píxeles a 30 fps.

Figura 33

Estructura prototípica para la captura de video en movimiento.





Figura 34

Campo visual de un fotograma: dimensiones reales en campo.



Los videos capturados sirvieron como base para extraer fotogramas, seleccionando cuadros cada 0.3 segundos para evitar redundancia y garantizar representatividad de las condiciones del pavimento.

3.11.2. Pre-procesamiento de imágenes

Se identificaron y clasificaron las fallas más comunes en las principales vías con pavimentos flexibles de la región de Ayacucho, las cuales son: piel de cocodrilo, fisuras, baches, descascaramientos y parches con severidades baja y alta, agrupando un total de 9 clases.

Se ajustaron las imágenes a una resolución de 853 píxeles de ancho y 480 píxeles de altura, por la sobrecarga que puede representar el gran volumen de datos en el proceso de entrenamiento. Posteriormente se determina los parámetros de las diversas fallas de acuerdo al Manual de Carreteras Mantenimiento y Conservación Vial (2018), adaptados para el análisis automatizado.

3.11.2.1 Tipos de fallas

a) Deterioro / falla 1: Piel de cocodrilo.

Se manifiesta como fisuras con formas de polígonos irregulares con ángulos agudos. Este tipo de falla en su etapa inicial es leve, sin partículas sueltas. La condición empeorará con el tiempo debido al tráfico y las condiciones climáticas; esto agrandará las fisuras y, a largo plazo, ocurrirá la pérdida de material en los bordes.

Nivel de severidad.

El criterio principal es el orden de magnitud de la malla.

Bajo: Malla grande ($\geq 3 m$) sin material suelto.

Alto: Malla pequeña ($< 3m$) sin o con material suelto

Figura 35

Piel de cocodrilo: (a) severidad baja, y (b) severidad alta.



b) Deterioro / falla 2: Fisuras

Las fisuras longitudinales son fracturas que se presentan de manera paralela al eje de la carretera. Comienzan como discontinuas y, con el tiempo, pueden evolucionar hacia fisuras continuas, ramificadas y cerradas, a causa del tráfico. Por otro lado, las fisuras transversales son aquellas que cruzan o atraviesan la mayor parte del eje de la vía.


Nivel de severidad.

Bajo: Fisuras abiertas y/o ramificadas (ancho $\leq 3mm$.)

Alto: Fisuras grandes, que abarcan fisuras abiertas y/o ramificadas (ancho $> 3mm$.)

Figura 36

Fisura: (a) severidad baja, y (b) severidad alta.



a) Deterioro / falla 3: Descascaramiento

Es la pérdida de la carpeta asfáltica, debido a la reducción parcial o total del material bituminoso o de los agregados, dicho deterioro afecta la seguridad y calidad del rodamiento, por lo cual el diagnóstico y tratamiento del mismo son imprescindibles.

Nivel de severidad.

Bajo: Diámetro $\leq 0.5m$

Alto: Diámetro $> 0.5m$

Figura 37

Descascaramiento: (a) severidad baja, y (b) severidad alta.



(a)

(b)

La caracterización del descascaramiento se llevó a cabo conforme a los requerimientos establecidos en el Manual de Inspección y Evaluación de Pavimentos de INVÍAS, debido a que esta falla presenta características claramente definidas, lo que facilita su identificación y registro. Los datos recolectados en campo, como la extensión, profundidad y patrón de pérdida de material, permitieron una clasificación precisa y estandarizada. A diferencia del Manual del MTC, que agrupa peladura y desprendimiento como una sola categoría, el enfoque de INVÍAS distingue el descascaramiento como una falla específica, lo que optimiza su diagnóstico y la propuesta de tratamientos correctivos.

Deterioro / falla 4: Baches (Huecos)

Se produce la desintegración total de la capa asfáltica, exponiendo con ello los materiales granulares, lo cual trae consigo el aumento del área afectada y la profundidad, dependiendo del tráfico. El tipo de deterioro presenta los denominados ojos de pescado, que son baches redondeados de profundidad variable, con bordes determinados por una deficiencia localizada en las capas estructurales.

Nivel de severidad.

Bajo: Diámetro $\leq 0.5m$

Alto: Diámetro $> 0.5m$

Figura 38

Bache: (a) severidad baja, y (b) severidad alta.



e) Deterioro / falla 5: Reparaciones o parchado

Superficie de pavimento flexible que ha sido retirada y sustituida con un material que sea similar y/o diferente del existente, con el propósito de poder restaurar la funcionalidad del mismo, de tal forma que la intervención será necesaria para poder solucionar problemas de transitabilidad y la durabilidad, garantizando las condiciones adecuadas para la circulación y la seguridad vial.

Nivel de severidad.

Para el presente estudio se contempló un solo grado de severidad, dado que las fallas no eran comunes en las carreteras principales de la región Ayacucho.

Figura 39

Parche.



3.11.3. Etiquetado de imágenes

Una vez establecidos los parámetros del modelo, se procedió a seleccionar las imágenes que contenían las fallas más visibles para su posterior etiquetado, para ello, se utilizó el software Anaconda con la herramienta gráfica de anotación de imágenes de LabelMe, etiquetándolos manualmente las fallas reconocidas de cada una de las imágenes. Las etiquetas fueron estructuradas en 9 clases (Tabla 14). El conjunto de datos finales generados fue en un total de 3,020 imágenes etiquetadas y 5512 clases como se muestra la distribución en la Figura 40).


Tabla 14

Descripción y cantidad de clases

N°	Clase	Descripción	Cantidad de clases
1	PC_B	Piel de cocodrilo bajo	614
2	PC_A	Piel de cocodrilo alto	679
3	FS_B	Fisura bajo	1125
4	FS_A	Fisura alto	883
5	DC_B	Descascaramiento bajo	707
6	DC_A	Descascaramiento alto	472
7	BCH_B	Bache bajo	287
8	BCH_A	Bache alto	603
9	PCH	Parche	142

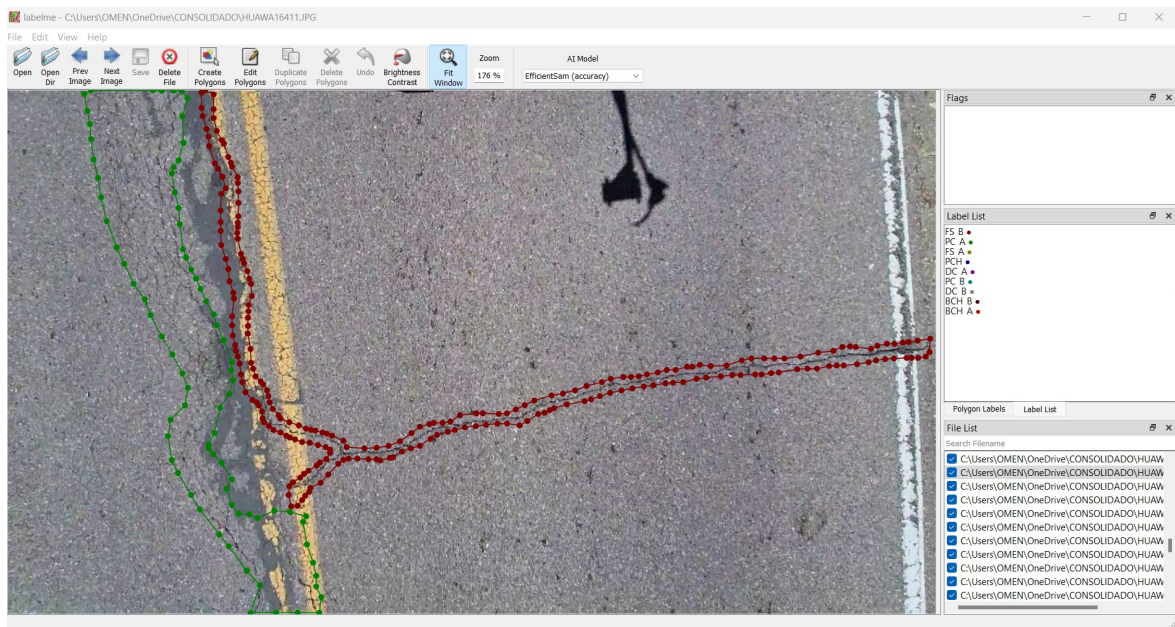
Figura 40

Cantidad de clases etiquetadas para entrenamiento.



El uso de LabelMe facilitó la segmentación detallada de las imágenes, resaltando áreas específicas asociando a las clases establecidas. Este proceso fue importante con el fin de entrenar el modelo de aprendizaje profundo tuviese acceso a datos que fuesen suficientemente buenos y que las clases de fallas estuvieran bien establecidas de modo que el modelo de aprendizaje mejorase y aprenda de una forma eficiente las características de cada tipo de fallo superficial en los pavimentos.

Figura 41
Etiqueta en LabelMe.



Nota. LabelMe permite delinear polígonos precisos alrededor de los contornos de objetos de estudio

3.11.4. Metodología del entrenamiento

El modelo de visión artificial fue entrenado utilizando la arquitectura YOLOv8n-seg (versión nano con segmentación), seleccionada principalmente debido a limitaciones de capacidad computacional. Esta versión destaca por su eficiencia computacional (3.2 millones de parámetros) y su capacidad para realizar detecciones en tiempo real con un consumo reducido de recursos.

El dataset se dividió en un 70% para entrenamiento (2,114 imágenes) y un 30% para validación (906 imágenes), con una división estratificada para preservar la proporción de las 9 clases.

3.11.5. Proceso de entrenamiento

La configuración del modelo se basó en los parámetros definidos en la tabla 15 , que detalla cada aspecto del proceso de entrenamiento.

Tabla 15

Parámetros de entrenamiento del modelo YOLOv8n-seg.pt

Parámetro	Valor	Descripción
Modelo	YOLOv8n-seg.pt	Versión ligera con segmentación para detección y delimitación de fallas.
Dataset	dataset.yaml	Incluye 3,020 imágenes y 4,512 instancias etiquetadas en 9 clases.
Épocas	80	Iteraciones completas del modelo sobre todo el dataset.
Tamaño de lote	16	Cantidad de imágenes procesadas por iteración.
Resolución de imagen	640×640 px	Dimensión de entrada redimensionada desde 853×480 px.
Optimizador	AdamW	Con tasa de aprendizaje inicial de 0.01 y <i>weight decay</i> de 0.0005.
Dispositivo	GPU NVIDIA GTX 1650 (4 GB)	Hardware con Intel Core i7-9750H y 16 GB de RAM.
Tiempo total	14 horas	Estimación con un promedio de 10.5 minutos por época.

Código de entrenamiento

El código utilizado para entrenar el modelo se presenta a continuación, implementado en Python con la biblioteca Ultralytics. Este código carga el modelo, entrena con el dataset especificado, y libera recursos de la GPU al finalizar.

```

1  from ultralytics import YOLO
2
3  # Cargar el modelo YOLOv8n-seg para segmentación
4  model = YOLO("yolov8n-seg.pt")
5
6  # Entrenar el modelo para segmentación
7  model.train(
8      data="dataset.yaml",
9      epochs=80,
10     imgsz=640
11 )
12
13 # Liberar la memoria de la GPU para optimizar recursos
14 import torch
15 torch.cuda.empty_cache()

```

Donde:

- **Ultralytics:** La biblioteca `ultralytics` proporciona una interfaz de alto nivel para entrenar modelos YOLO, simplificando la configuración y ejecución.
- **Carga del Modelo:** `YOLO("yolov8n-seg.pt")` carga el modelo pre-entrenado `yolov8n-seg.pt`, que sirve como base para el entrenamiento fino con el dataset específico.
- **Entrenamiento:** El método `model.train()` ejecuta el proceso con los parámetros:
 - `data="dataset.yaml"`: Especifica el archivo de configuración del dataset.
 - `epochs=80`: Define el número total de iteraciones.
 - `imgsz=640`: Establece la resolución de entrada a 640x640 píxeles.

Otros parámetros por defecto (tamaño de lote, optimizador AdamW y tasa de aprendizaje inicial) son ajustados automáticamente por YOLOv8 según el hardware y el dataset.

- **Liberación de Memoria:** `torch.cuda.empty_cache()` libera la memoria de la GPU tras el entrenamiento, evitando cuellos de botella en sistemas con recursos limitados.
- **Salida:** El modelo entrenado se guarda automáticamente (como `runs/train/exp/weights/best.pt`), junto con gráficos y métricas generados por YOLOv8.

Evolución de las Pérdidas durante el entrenamiento

El modelo YOLOv8n-seg se entrenó durante 80 épocas, monitoreando cuatro funciones de pérdida: *Box Loss*, *Segmentation Loss*, *Classification Loss* y *DFL Loss*, que evaluaron la precisión de localización, exactitud de segmentación, capacidad de clasificación y distribución focal, respectivamente. Los resultados muestran una reducción progresiva en todas las funciones, tanto en entrenamiento como en validación, con estabilización a partir de la época 60. La pérdida de clasificación presentó la mayor reducción, seguida por la de segmentación, indicando desarrollo robusto en la discriminación de tipos de fallas. La tasa de aprendizaje mostró una disminución controlada, optimizando la convergencia. Esta evolución, detallada en la Tabla 16, valida la efectividad del proceso y la configuración de hiperparámetros seleccionada para el modelo.

Tabla 16*Pérdidas durante el entrenamiento y validación a lo largo de las épocas*

Época	Train Box Loss	Train Seg Loss	Train Cls Loss	Train DFL Loss	Val Box Loss	Val Seg Loss	Val Cls Loss	Val DFL Loss	lr/pg0
1 (Inicio)	1.685	3.8304	3.8605	1.6481	1.7062	3.2241	3.5526	1.7029	0.000254
10	1.3413	2.3328	1.9271	1.3657	1.4261	2.4915	2.0871	1.4737	0.000683
20	1.2201	2.1350	1.6531	1.2889	1.3437	2.1514	1.7835	1.3983	0.000588
30	1.1496	2.0069	1.4518	1.2440	1.3002	2.0790	1.6745	1.3552	0.000493
40	1.0888	1.8880	1.3206	1.1980	1.2665	2.0253	1.6061	1.3398	0.000397
50	1.0328	1.7886	1.2015	1.1679	1.2698	2.0450	1.5292	1.3323	0.000302
60	0.9872	1.7390	1.0967	1.1398	1.2442	1.9681	1.4546	1.3319	0.000207
70	0.9492	1.6776	1.0469	1.1150	1.2269	1.9504	1.4300	1.3247	0.000121
80 (Final)	0.8213	1.4246	0.7992	1.0645	1.2367	1.9547	1.4063	1.3485	0.000071

Donde:

- **Box Loss:** Mide la precisión de las coordenadas de las bounding boxes. Disminuyó de 1.685 a 0.8213 (entrenamiento) y de 1.7062 a 1.2367 (validación), indicando mejor localización de fallas, con leve sobreajuste tras la época 50.
- **Segmentation Loss:** Evalúa la exactitud de las máscaras de segmentación. Se redujo de 3.8304 a 1.4246 (entrenamiento) y de 3.2441 a 1.9547 (validación), reflejando un ajuste progresivo en los contornos de fallas.
- **Classification Loss:** Mide la exactitud en clasificar las 9 clases. Cayó de 3.8605 a 0.79926 (entrenamiento) y de 3.5526 a 1.4063 (validación), mostrando un aprendizaje efectivo entre clases similares.
- **DFL Loss:** Optimiza la confianza de predicciones (específica de YOLOv8n). Descendió de 1.6481 a 1.0645 (entrenamiento) y de 1.7029 a 1.3485 (validación), indicando mayor enfoque en detecciones relevantes.
- **Tasa de Aprendizaje (lr/pg0):** Se redujo de 0.000254 a 0.0000071, facilitando una convergencia estable tras la época 60.

Métricas de detección

La métrica de detección evalúa la precisión, generalización y robustez de un modelo de

visión artificial para identificar y localizar objetos en imágenes. En la tabla 17 se presentan los datos numéricos del entrenamiento.

Tabla 17
Métricas de desempeño a lo largo de las épocas

Época	Precisión (B)	Recall (B)	mAP50 (B)	mAP50-95 (B)
1 (Inicio)	0.36032	0.21945	0.15739	0.07923
10	0.45691	0.52617	0.48539	0.28926
20	0.54369	0.56619	0.58055	0.38055
30	0.53434	0.57459	0.57954	0.37544
40	0.57911	0.59883	0.59838	0.39029
50	0.62236	0.62629	0.64601	0.42701
60	0.64354	0.63072	0.66630	0.44747
70	0.64442	0.65477	0.66939	0.44911
80 (Final)	0.68565	0.63742	0.68269	0.45773

Donde:

- **Precision(B)**: Representa la proporción de predicciones correctas entre todas las predicciones positivas realizadas por el modelo (para bounding boxes). Aumentó de 0.36032 a 0.68565, indicando que el modelo se volvió más preciso en sus detecciones.
- **Recall(B)**: Mide la proporción de fallas reales que fueron correctamente detectadas. Creció de 0.21945 a 0.63742, mostrando una mejora en la capacidad del modelo para identificar todas las fallas presentes.
- **mAP50(B)**: Métrica de precisión promedio (mean Average Precision) a un umbral de IoU (Intersection over Union) de 0.5, que mide la precisión global del modelo. Aumentó de 0.15739 a 0.68269, reflejando un rendimiento sólido.
- **mAP50-95(B)**: Promedio de mAP sobre umbrales de IoU de 0.5 a 0.95, evaluando la robustez del modelo en diferentes niveles de precisión. Subió de 0.07923 a 0.45773, indicando una mejora en la generalización.

3.11.6. Cálculo de índice de condición del pavimento

El presente estudio propone una metodología basada en inteligencia artificial (IA) para la evaluación automatizada de pavimentos flexibles, considerando cinco tipos de fallas como son: piel de cocodrilo, fisuras, descascaramiento, baches y parches. Esta metodología

se desarrolla en función a los lineamientos establecidos por el Manual de Carreteras: Mantenimiento o Conservación Vial - 2018 del Ministerio de transportes y comunicaciones, asegurando que los parámetros de evaluación se alineen a la especificaciones técnicas del manual como la extensión de evaluación y gravedad de las fallas, así como procedimientos necesarios para su evaluación en función a las capacidades y limitaciones del modelo entrenado, buscando así mejorar su aplicación en el campo de la ingeniería civil.

A continuación, se describen los parámetros de evaluación y las consideraciones adoptadas, teniendo en cuenta factores técnicos, normativos y prácticos. Estos criterios han sido ajustados para su detección automatizada, manteniendo alineación con los estándares del MTC. Como se detalla en la Tabla 18, se han establecido criterios de severidad basados en las características físicas y geométricas de los deterioros en pavimentos flexibles.

Tabla 18
Deterioro o fallas de pavimentos flexibles

Tipo de Falla	Código	Unidad	Criterio de severidad
Piel de Cocodrilo	PC	m ²	Bajo: Malla grande (≥ 0.3 m) sin material suelto. Alto: Malla pequeña (< 0.3 m) con material suelto.
Fisuras	FS	m ²	Bajo: Separación ≤ 3 mm. Alto: Separación > 3 mm con material suelto.
Descascaramiento	DC	m ²	Bajo: Diámetro ≤ 0.5 m. Alto: Diámetro > 0.5 m.
Baches	BCH	m ²	Bajo: Diámetro ≤ 0.5 m. Alto: Diámetro > 0.5 m.
Parches	PCH	m ²	El estudio consideró una única severidad, ya que las fallas eran infrecuentes.

Porcentaje de extensión de falla (EF). Es un indicador que mide la proporción del área afectada por fallas en relación con el área total evaluada de un pavimento flexible. Se expresa en porcentaje y permite cuantificar el nivel de deterioro en un tramo determinado y se calcula mediante la siguiente ecuación:

$$EF = \left(\frac{\text{Área afectada por la falla}}{\text{Área de la sección evaluada}} \right) \times 100 \quad (3.1)$$

Donde la **Área de la sección evaluada** se determina como:

$$\text{Área de la sección evaluada} = (\text{carril} + \text{berma adyacente}) \times 200 \text{ m} \quad (3.2)$$

Descripción de los parámetros

- Área afectada por la falla: Representa la superficie del pavimento que presenta deterioro, incluyendo fisuras, baches, descascaramiento, entre otros.
- **Área de la sección evaluada:** Corresponde a la superficie total inspeccionada en cada segmento de 200 metros de longitud, considerando el ancho del carril más la berma adyacente.

Calculo de extension promedio ponderada (PEF)

La extension promedio ponderada considerando tres grados de severidad (baja, media y alta) se expresa como:

$$PEF = \frac{(EF_B \times A_B + EF_M \times A_M + EF_A \times A_A)}{(A_B + A_M + A_A)} \quad (3.3)$$

Donde:

- PEF = Porcentaje de extensión de falla.
- EF_B, EF_M, EF_A = Porcentajes de falla para severidad baja, media y alta, respectivamente.
- A_B, A_M, A_A = Áreas afectadas por la falla en los niveles de severidad baja, media y alta.

Si se simplifica el modelo considerando únicamente dos grados de severidad, agrupando el nivel bajo y medio en una sola categoría, y suponiendo $A_B = A_M$, finalmente, la expresión más simplificado:

$$PEF = \left(\frac{EF_B \times \frac{A_B}{2} + EF_A \times A_A}{A_B + A_A} \right) \times 100 \quad (3.4)$$

Esta reformulación permite adaptar el modelo al análisis con solo dos severidades, optimizando el cálculo del PEF.

Propuesta de parámetros de puntaje de condición (PC)

Los parámetros propuestos en la tabla 19 optimizan la evaluación cuantitativa de pavimentos flexibles mediante algoritmos de inteligencia artificial, superando las limitaciones del modelo mediante visión artificial, que depende de inspecciones visuales y clasificaciones cualitativas. La asignación de 800 puntos a las cinco fallas detectadas refleja su impacto estructural, funcional y de usuario, respaldada por el manual del MTC (2018) e influenciados por el método PCI y VIZIR.

Tabla 19*Puntajes de Condición (PC) propuestos para la metodología de IA*

Tipo de Falla	Puntaje Máx. (PC)	Rangos de PC por EFP	Justificación Técnica
Piel de Cocodrilo	200	0%: 0, <10%: 0–40, 10–30%: 40–200, >30%: 200	Se mantiene el máximo del MTC (200 puntos) debido a su impacto estructural severo y progresivo, asociado con fatiga asfáltica según el Manual MTC.
Fisuras	200	0%: 0, <10%: 0–40, 10–30%: 40–200, >30%: 200	Se incrementa de 100 a 200 porque se agrupan fisuras longitudinales y transversales, reconociendo su impacto combinado.
Descascaramien	100	0%: 0, <10%: 0–20, 10–30%: 20–100, >30%: 100	Se incrementa a 100 puntos debido a su relación con fallas estructurales críticas como ahuellamiento, pérdida de agregado y exudación. Esta falla toma mayor importancia en metodologías como PCI y VIZIR.
Baches	200	0 baches: 0, <4 baches/200 m: 0–40, 4–10 baches/200 m: 40–200, >10 baches/200 m: 200	Se otorgan 200 puntos debido a su severo impacto en la seguridad y transitabilidad, alineado con criterios de mantenimiento vial. Es altamente considerado en PCI y VIZIR.
Parches	100	0%: 0, <10%: 0–20, 10–30%: 20–100, >30%: 100	Máximo de 100 por su indicación de reparaciones previas fallidas, afectando la durabilidad y continuidad del pavimento.
Total (Fallas Detectadas)	800		Suma máxima para las fallas incluidas, con 200 puntos adicionales a criterio del evaluador para fallas no detectadas (deformaciones, exudación, etc.).

La reserva de 200 puntos bajo el criterio del evaluador permite compensar las fallas no incluidas en la evaluación inicial, como deformaciones, exudación, ahuellamiento, entre otras, alineándose con las inspecciones manuales recomendadas por el MTC. Este ajuste asegura una evaluación más completa y precisa, ya que incorpora aspectos que pueden no ser capturados por la inteligencia artificial (IA) debido a limitaciones en la detección automática de ciertos tipos de deterioro. Si bien esta práctica introduce un grado de subjetividad, es fundamental para reflejar de manera más fiel las condiciones reales del pavimento. Al final del proceso, el evaluador tiene la capacidad de ajustar los puntajes basándose en la información recolectada en campo, lo que permite equilibrar la objetividad de la IA con la experiencia y el criterio técnico del evaluador. Este enfoque híbrido no solo mejora la precisión de la evaluación, sino que también garantiza que se consideren todos los factores relevantes.

Calificación de condición

La clasificación de condición se basa en un índice numérico denominado Calificación de Condición (CC), calculado como:

$$CC = 1000 - \sum PC \quad (3.5)$$

donde los PC se asignan a cada tipo de falla según su Extensión del Fenómeno Patológico (EFP) ponderada, con un total máximo de 800 puntos para las fallas detectadas y un ajuste adicional de hasta 200 puntos al criterio del evaluador para fallas no incluidas.

La calificación de condición representa el estado superficial del pavimento flexible y se sintetiza en tres tipos:

Tabla de Calificación de Condición

Tabla 20

Clasificación de condición del pavimento

Condición	Rango de Puntuación
Bueno	> 800
Regular	$300 \leq CC \leq 800$
Malo	≤ 300

Nota. Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)

De acuerdo con la calificación obtenida, se puede determinar el tipo de conservación requerido para el pavimento flexible, estableciendo criterios para mantenimiento rutinario,

conservación periódica o rehabilitación estructural.

Tipos de conservación según clasificación de condición mediante el método de visión artificial.

Tabla 21

Tipos de conservación según clasificación de condición

Tipo de Conservación	Rango de Calificación de Condición (CC)
Reconstrucción / Rehabilitación	≤ 300
Conservación Periódica	$300 < CC < 800$
Conservación Rutinaria	≥ 800

Nota. Manual de carreteras: Mantenimiento o conservación vial, MTC (2018)

3.11.7. Desarrollo del programa

PAVEMAI surge como una solución tecnológica innovadora para la inspección de infraestructura vial, ofreciendo una evaluación automatizada del estado de pavimentos flexibles mediante procesamiento de videos. Desarrollado en Python, este programa utiliza inteligencia artificial para detectar fallas, calcular métricas y determinar la calificación de Condición del Pavimento (CC). Además, genera reportes detallados que facilitan la toma de decisiones en el mantenimiento y conservación de carreteras, optimizando así la gestión de la infraestructura vial.

Estructura del programa

PAVEMAI está diseñado bajo el patrón de diseño Modelo-Vista-Controlador (MVC), que separa la lógica de negocio, la interfaz gráfica y la gestión de datos para mejorar la modularidad y mantenibilidad. La estructura se compone de las siguientes clases principales:

1. **Modelo** (PavementModel):

- Gestiona la lógica de negocio, incluyendo el procesamiento de detecciones, cálculo de métricas (EFP, PC, CC) y seguimiento de objetos.
- Administra configuraciones como dimensiones del área, progresivas y parámetros de detección.

2. **Vista** (PavementView):

- Implementa la interfaz gráfica utilizando `tkinter`, con pestañas para configuración, tiempos, resultados y resumen.
 - Muestra el video procesado en tiempo real, estadísticas dinámicas y flechas para indicar el sentido de progresivas.
3. **Controlador (PavementController):**
- Coordina la comunicación entre el modelo y la vista, gestionando el procesamiento de video mediante hilos para lectura y análisis de fotogramas.
 - Integra el modelo YOLO para detecciones y actualiza los resultados en la interfaz.
4. **Utilidades auxiliares:**
- Clases como `ExportManager` para generar reportes en Excel.

Flujo de trabajo del programa

El flujo de trabajo de PAVEMAI se organiza en las siguientes etapas:

1. Inicialización y configuración:

- La vista (`PavementView`) inicializa la interfaz gráfica con `tkinter`, creando pestañas para configuración, tiempos, resultados y resumen.
- El modelo (`PavementModel`) carga parámetros iniciales, como dimensiones del área, progresivas (formato K+MMM) y el modelo YOLO preentrenado.
- El controlador (`PavementController`) configura hilos para lectura y procesamiento de video.

2. Procesamiento y análisis del video:

- El usuario selecciona un video, que se carga mediante `OpenCV (cv2.VideoCapture)`.
- El controlador procesa fotogramas en hilos separados: uno lee frames (`_video_read_worker`) y otro los analiza (`_video_process_worker`).
- El modelo YOLO detecta defectos (piel de cocodrilo, fisuras, baches, etc.) en cada fotograma, aplicando filtros de IoU, distancia mínima y persistencia temporal para evitar duplicaciones.
- Se calculan áreas afectadas (en metros cuadrados) usando un factor de conversión píxeles-metros, y se actualiza el seguimiento de objetos con firmas únicas.

3. Cálculo de la calificación de condición (CC):

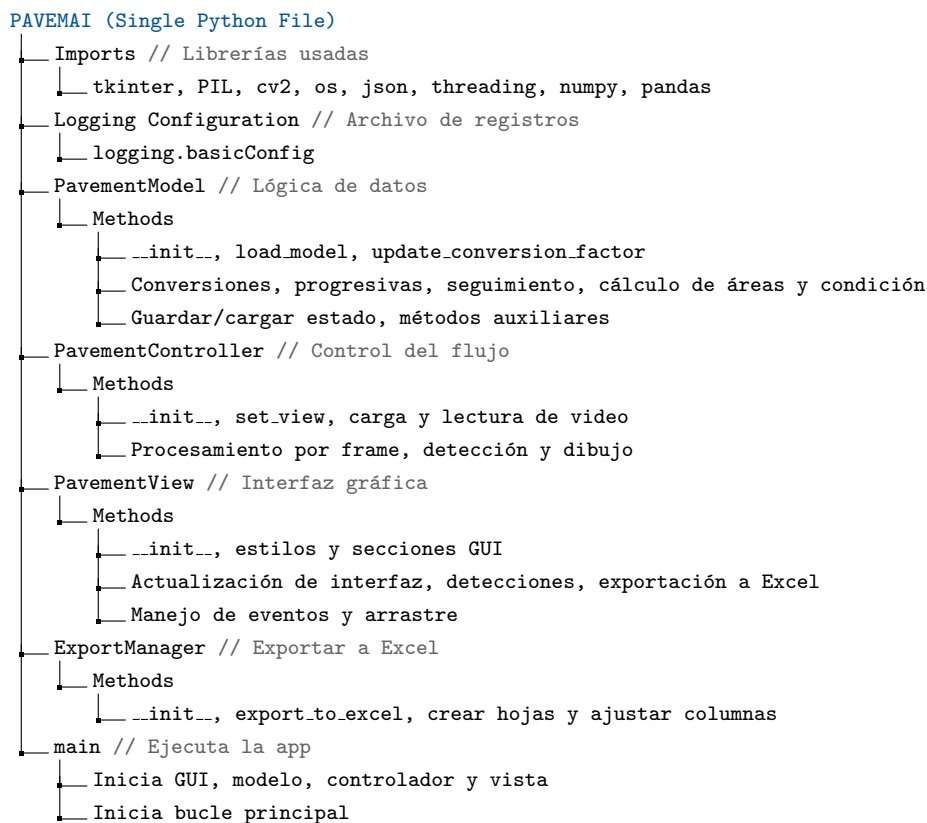
- El modelo calcula la Extensión del Fenómeno Patológico (EFP) como el porcentaje del área afectada respecto al área total.
- Se determinan los puntajes de condición (PC) según el **Manual de Carreteras: Mantenimiento y Conservación Vial (2018)**.
- La CC se calcula integrando los PC y EFP, clasificando el pavimento en categorías: bueno, regular o deficiente.

4. Visualización y exportación de resultados:

- La vista muestra detecciones en tiempo real, estadísticas (número de defectos, severidad, distribución) y un resumen de la CC.
- Los resultados se exportan a Excel mediante ExportManager, generando hojas para información general, detecciones por intervalo, evaluación de condición y resumen.

Árbol de organización del código

El código del programa PAVEMAI se organizó en una estructura jerárquica, donde la clase principal PavementDetectionGUI contiene métodos para cada funcionalidad. A continuación, se presenta el árbol de organización completo del código, detallando cada método y su propósito.



Descripción de los métodos

1. PavementModel:

- `__init__()`: Inicializa variables, configura el modelo YOLO y parámetros de detección.
- `load_model()`: Carga el modelo YOLO preentrenado.
- `progresiva_a_metros()`: Convierte progresivas (K+MMM) a metros.
- `calculate_area()`: Calcula el área evaluada en metros cuadrados.
- `update_tracked_objects()`: Actualiza el historial de detecciones con firmas únicas.
- `filter_detections_temporal()`: Aplica filtrado temporal para validar detecciones.
- `calculate_condition()`: Calcula EFP, PC y CC según el Manual de Carreteras.
- `clasificar_pavimento()`: Clasifica el pavimento según la CC.

2. PavementView:

- `__init__()`: Inicializa la interfaz gráfica y configura pestañas.
- `create_gui()`: Crea el layout con pestañas, panel de video y controles.
- `create_logo()`: Carga y muestra el logo de PAVEMAI.
- `create_control_notebook()`: Configura pestañas para configuración, tiempos y resultados.
- `update_frame()`: Actualiza la visualización del fotograma procesado.
- `update_statistics()`: Muestra estadísticas dinámicas de detecciones.
- `export_results_to_excel()`: Inicia la exportación de resultados a Excel.
- `update_arrows()`: Actualiza flechas para el sentido de progresivas.

3. PavementController:

- `__init__()`: Inicializa el controlador, conectando modelo y vista.
- `load_video()`: Carga el video seleccionado.
- `start_processing()`: Inicia hilos para lectura y procesamiento de video.

- `_video_read_worker()`: Lee fotografías y los almacena en una cola.
- `_video_process_worker()`: Procesa fotografías con YOLO y actualiza detecciones.
- `_process_single_frame()`: Aplica YOLO a un fotograma individual.
- `stop_processing()`: Detiene el procesamiento y libera recursos.

4. **ExportManager:**

- `export_results_to_excel()`: Genera el archivo Excel con hojas detalladas.
- `_write_general_info()`: Escribe información general (progresivas, dimensiones).
- `_write_interval_results()`: Detalla detecciones por intervalo.
- `_write_summary()`: Resume la CC y clasificación del pavimento.

5. **ConfigManager:**

- `save_state()`: Guarda la configuración del programa.
- `load_state()`: Carga la configuración guardada.

6. **Métodos Auxiliares (en varias clases):**

- `time_to_seconds()`: Convierte tiempo (HH:MM:SS) a segundos.
- `is_frame_in_interval()`: Verifica si un fotograma está en el intervalo seleccionado.
- `update_conversion_factor()`: Actualiza el factor de conversión píxeles-metros.
- `calculate_iou()`: Calcula la intersección sobre unión para filtrar detecciones.
- `log_message()`: Registra eventos y errores en `pavemai.log`.

Tablas de referencia

El la tabla 22 y 23 presenta una tabla con los parámetros clave utilizados en el programa PAVEMAI para la detección de fallas en pavimentos flexibles. Se divide en dos secciones:

La Tabla 22 presenta los parámetros fundamentales utilizados en la calibración del sistema PAVEMAI para el procesamiento de video. Los parámetros `video_width_px` y `video_height_px` representan las dimensiones del video en píxeles, calculadas de forma automática cuando el usuario ingresa el archivo a través de la interfaz. Por su parte,

los parámetros `real_width_m` y `real_height_m` corresponden a las dimensiones físicas (en metros) del área de pavimento que está siendo evaluada en cada fotograma. Estos valores son determinantes para establecer la escala correcta entre el espacio digital y el mundo real. El factor de conversión `pixels_to_meters_factor` se calcula dinámicamente en función de las dimensiones anteriores y permite transformar medidas tomadas en píxeles a sus equivalentes en unidades métricas. Este parámetro es esencial para el análisis cuantitativo preciso del estado del pavimento, ya que permite expresar la extensión de las fallas detectadas en unidades físicas comprensibles y estandarizadas.

Tabla 22
Parámetros de calibración

Parámetro	Valor	Descripción
<code>video_width_px</code>	1920	Ancho del video en píxeles
<code>video_height_px</code>	1080	Alto del video en píxeles
<code>real_width_m</code>	5.30	Ancho real del área evaluada en metros
<code>real_height_m</code>	3.00	Alto real del área evaluada en metros
<code>pixels_to_meters_factor</code>	Calculado	Factor de conversión de píxeles a metros

La Tabla 23 presenta los parámetros fundamentales utilizados en el sistema PAVEMAI para el proceso de detección de fallas en pavimentos flexibles. En la fase inicial, el sistema emplea parámetros generales que garantizan un equilibrio entre precisión y robustez en la identificación de defectos. El parámetro `confidence_threshold` establece el umbral mínimo de confianza requerido para que una detección sea considerada válida, evitando falsos positivos. El `iou_threshold` define el valor de intersección sobre unión (IoU), el cual ayuda a prevenir la duplicación de detecciones al evaluar la superposición entre los cuadros delimitadores. Por su parte, `distance_threshold` regula la distancia mínima en píxeles entre detecciones para evitar múltiples identificaciones de una misma falla en fotogramas cercanos. Finalmente, `temporal_persistence` determina el número mínimo de fotogramas en los que una detección debe persistir para ser validada, asegurando consistencia temporal. Estos valores generales han sido ajustados para optimizar la precisión del sistema y minimizar errores en la identificación de daños en la superficie del pavimento durante la etapa preliminar.

Posteriormente, con base en los resultados del entrenamiento del modelo YOLO, se definieron parámetros específicos para cada tipo de falla (piel de cocodrilo, fisuras, descascaramientos, baches y parches), considerando su severidad (baja o alta) y comportamiento temporal. Esta personalización permite un análisis más preciso, adaptado a las características únicas de cada defecto. La Tabla 24 detalla los parámetros específicos por clase, optimizados para maximizar la precisión en la detección y clasificación de fallas, reduciendo falsos positivos y detecciones duplicadas.

Tabla 23*Parámetros generales de detección*

Parámetro	Valor	Descripción
confidence_threshold	0.30	Umbral de confianza para detecciones válidas
iou_threshold	0.40	Umbral de IoU para evitar duplicaciones
distance_threshold	35	Distancia mínima en píxeles entre detecciones
temporal_persistence	7	Frames mínimos para validar una detección

Tabla 24*Parámetros específicos por clase de falla*

Clase	conf_ threshold	iou_ threshold	distance_ threshold	temporal_ persistence
PC_B	0.32	0.50	45	5
PC_A	0.32	0.50	45	5
FS_B	0.25	0.55	30	3
FS_A	0.25	0.55	30	3
DC_B	0.30	0.45	40	4
DC_A	0.30	0.45	40	4
BCH_B	0.45	0.70	15	3
BCH_A	0.50	0.70	15	3
PCH	0.35	0.50	45	3

3.11.8. Bibliotecas y módulos utilizados

Durante el desarrollo del sistema PAVEMAI, se emplearon diversas bibliotecas y módulos de Python que permitieron implementar las funcionalidades requeridas para la detección,

análisis y presentación de fallas. A continuación, se detallan las más relevantes:

- **tkinter**: Biblioteca principal para la creación de la interfaz gráfica del sistema, que incluye elementos como ventanas, botones y paneles de visualización de videos. También se utilizó su submódulo `messagebox` para proporcionar retroalimentación al usuario mediante mensajes emergentes sobre el estado del análisis y posibles errores.
- **PIL (Pillow)**: Biblioteca especializada en el procesamiento de imágenes, utilizada para manipular y visualizar los *frames* de video en la interfaz gráfica. Incluye los submódulos `Image`, para la carga y transformación de imágenes, y `ImageTk`, para integrar imágenes procesadas en los elementos gráficos de `tkinter`.
- **cv2**: Biblioteca fundamental de OpenCV para el procesamiento de video y detección de objetos, empleada en la captura, lectura y análisis de *frames* de video, así como en la conversión de formatos para la visualización y detección de fallas en el pavimento.
- **ultralytics YOLO: Framework** avanzado de detección de objetos basado en el modelo YOLO, implementado para identificar y clasificar fallas en pavimentos flexibles.
- **numpy**: Biblioteca esencial para el procesamiento numérico, utilizada en cálculos de áreas, distancias y transformaciones geométricas, así como en la manipulación de matrices para el análisis de detecciones y la cuantificación de fallas en el pavimento.
- **pandas**: Biblioteca para el análisis y manejo de datos, empleada en la organización de los resultados de detección y la generación de reportes detallados en formato tabular, que incluyen estadísticas de fallas y condiciones del pavimento para su exportación.
- **defaultdict**: Estructura de datos del módulo `collections`, utilizada para almacenar y gestionar de manera eficiente el historial de detecciones y áreas de fallas, optimizando el seguimiento temporal de los defectos identificados.
- **datetime**: Módulo para la gestión temporal del análisis de video, empleado para registrar marcas de tiempo y calcular intervalos de evaluación.
- **os**: Módulo para la gestión de archivos y directorios, utilizado en la carga de videos, almacenamiento de resultados de detección y exportación de reportes generados durante la evaluación del pavimento.
- **xlsxwriter**: Biblioteca para la creación de reportes en formato Excel, empleada para documentar los resultados de las evaluaciones del pavimento, incluyendo estadísticas detalladas, mediciones de fallas y clasificaciones de condición.

Capítulo IV: Resultados

4.1 Análisis de resultados

4.1.1. Hipótesis específica 1

Hipótesis: El desarrollo de un modelo de visión artificial permite una identificación y clasificación de forma automática diferentes tipos de falla en pavimentos flexibles.


4.1.1.1 Análisis de las curvas de evolución del entrenamiento

Evolución de las funciones de pérdida durante el entrenamiento

El análisis de las curvas de pérdida durante el entrenamiento del modelo YOLOv8n-seg revela un patrón consistente de aprendizaje y optimización. Como se observa en la Figura 42 y 43, el modelo muestra una clara convergencia a lo largo de las 80 épocas de entrenamiento:

Figura 42

Funciones de pérdida en entrenamiento y validación



Aspectos clave observados en estas curvas


1. **Estabilidad del aprendizaje:** Todas las curvas muestran una tendencia descendente estable sin oscilaciones bruscas, indicando un proceso de optimización equilibrado con la tasa de aprendizaje adecuada.

2. **Paralelismo entre entrenamiento y validación:** Las curvas de entrenamiento y validación siguen patrones similares, aunque con valores ligeramente más altos en validación, lo que sugiere una generalización adecuada sin signos evidentes de sobreajuste.
3. **Fase de convergencia:** A partir de la época 50-60, las curvas comienzan a aplanarse, indicando que el modelo está alcanzando su punto de convergencia óptimo. Esto confirma que 80 épocas fueron suficientes para el entrenamiento, y más épocas probablemente no habrían aportado mejoras significativas.
4. **Reducción diferencial:** La pérdida de clasificación (`cls_loss`) muestra la mayor reducción comparativa, seguida por la pérdida de segmentación (`seg_loss`), lo que indica que el modelo mejoró más significativamente en aprender a identificar correctamente los tipos de fallas que en delimitar sus contornos exactos.
5. **Brecha entre entrenamiento y validación:** La diferencia entre las curvas de entrenamiento y validación se mantiene relativamente constante a lo largo del proceso, lo que indica un balance adecuado en la capacidad del modelo para generalizar a nuevos datos.

Esta evolución de las funciones de pérdida confirma el proceso de aprendizaje efectivo del modelo, respaldando los buenos resultados obtenidos en las métricas finales de rendimiento.

Figura 43

Evolución de las métricas de rendimiento durante el entrenamiento



Aspectos clave observados en estas curvas

1. **Crecimiento rápido inicial:** Todas las métricas experimentan un aumento pronunciado durante las primeras 20 épocas, indicando que el modelo aprende rápidamente los patrones más evidentes de las fallas.
2. **Fase de mejora gradual:** Entre las épocas 20 y 60, se observa un crecimiento más moderado pero constante, reflejando el refinamiento progresivo del modelo al aprender patrones más sutiles.
3. **Estabilización final:** A partir de la época 60, las curvas tienden a la estabilización con pequeñas fluctuaciones, confirmando la convergencia del modelo y validando la decisión de detener el entrenamiento en 80 épocas.
4. **Fluctuaciones en precisión y recall:** Estas métricas muestran oscilaciones más pronunciadas que las curvas de mAP, lo que es normal ya que son más sensibles a variaciones en los lotes específicos de evaluación. El mAP, al ser una métrica agregada, presenta un comportamiento más estable.
5. **Brecha entre mAP50 y mAP50-95:** La diferencia significativa entre estas métricas (aproximadamente 0.68 vs. 0.45) indica que el modelo es considerablemente más efectivo con un umbral de IoU de 0.5 que con umbrales más exigentes, sugiriendo cierta limitación en la precisión exacta de las detecciones.
6. **Simetría entre detección y segmentación:** La similitud casi exacta entre las curvas de métricas para bounding boxes (B) y máscaras (M) demuestra que el modelo ha logrado un equilibrio notable entre ambas tareas, sin sacrificar rendimiento en una por mejorar la otra.

El análisis de estas curvas de rendimiento confirma la efectividad del entrenamiento y proporciona una validación cuantitativa del comportamiento del modelo que respalda los hallazgos observados en las funciones de pérdida. La evolución consistente y gradual hacia valores competitivos en todas las métricas principales sustenta la conclusión de que el modelo YOLOv8n-seg ha logrado un nivel de rendimiento técnicamente satisfactorio, aunque con margen de mejora especialmente en la detección precisa a umbrales de IoU elevados.

El rendimiento del modelo experimentó una notable mejora durante las 80 épocas de entrenamiento, como se evidencia en la Tabla 25, que resume las métricas iniciales, finales y el incremento porcentual.

Tabla 25

Evolución de métricas clave durante el entrenamiento.

Métrica	Época 1	Época 80	Incremento (%)
Precision(B)	0.36032	0.68565	90.3%
Recall(B)	0.21945	0.63742	190.4%
mAP50(B)	0.15739	0.68269	333.8%
mAP50-95(B)	0.07923	0.45773	477.9%
Precision(M)	0.37603	0.69924	86.0%
Recall(M)	0.21087	0.64224	204.5%
mAP50(M)	0.14693	0.68158	364.0%
mAP50-95(M)	0.06895	0.42132	510.9%

- **Precisión en detección (B):** Inició en 0.36032 y alcanzó 0.68565, con un incremento del 90.3%. Esto significa que, al final del entrenamiento, el 68.6% de las fallas detectadas son correctas, mostrando una notable mejora en la capacidad del modelo para evitar falsos positivos.
- **Recall en detección (B):** Pasó de 0.21945 a 0.63742, un aumento del 190.4%, indicando que el modelo detecta el 63.7% de las fallas reales. Aunque significativo, este valor refleja que aún se omiten algunas fallas, especialmente a las clases menos representadas.
- **mAP50 en detección (B):** Creció de 0.15739 a 0.68269, un 333.8% de mejora, superando el estándar de 0.5 en visión artificial. Este valor demuestra un equilibrio robusto entre precisión y recall, esencial para la identificación automática de fallas.
- **mAP50-95 en detección (B):** Aumentó de 0.07923 a 0.45773, un 477.9% más, mostrando que el modelo es robusto incluso en umbrales de IoU más estrictos, aunque aún tiene margen de mejora en clases complejas.
- **Precisión en segmentación (M):** Subió de 0.37603 a 0.69924, un 86.0% de incremento, logrando que el 69.9% de las máscaras de segmentación sean correctas, lo que resalta la capacidad del modelo para delinear contornos con precisión.
- **Recall en segmentación (M):** Aumentó de 0.21087 a 0.64224, con un 204.5% de mejora, lo que significa que el 64.2% de las fallas reales son segmentadas.
- **mAP50 en segmentación (M):** Alcanza 0.68158, con un incremento del 364.0%, un valor cercano al mAP50(B), lo que indica una consistencia técnica entre detección y


segmentación a un umbral de 0.5, validando su desempeño dual.

- **mAP50-95 en segmentación (M):** Llega a 0.42132, con un aumento del 510.9%, mostrando un progreso significativo en umbrales altos. No obstante, su valor más bajo que el mAP50-95(B) sugiere mayor dificultad en segmentar contornos complejos con precisión.

La figura 44. muestra la evolución de la precisión y el mAP@0.5 del modelo YOLOv8n-seg durante 80 épocas, con curvas diferenciadas para detección (Bounding Box) y segmentación (Máscara). Se observa un aumento general en el rendimiento, con fluctuaciones notables en las primeras etapas que se estabilizan progresivamente. A partir de la época 60, las curvas alcanzan una meseta, indicando que el modelo ha alcanzado su máximo desempeño, con valores pico de 68.44% en mAP@0.5 (detección) y 69.99% en precisión (segmentación). El cual al entrenar con más épocas no mejorará significativamente los resultados, dado que el modelo ya se ha estabilizado.

Figura 44

Evolución de métricas principales de detección y Segmentación durante el entrenamiento



Desempeño por clase

La Tabla 26 muestra el mAP@0.5 por clase para detección (Bounding Boxes) y segmentación (Máscaras), destacando el rendimiento del modelo PAVEMAI en identificar fallas específicas del pavimento, como piel de cocodrilo, fisuras, descascaramientos, baches y parches, considerando su severidad. Este análisis por clase reveló fortalezas y limitaciones, permitiendo optimizar los parámetros del sistema para cada tipo de falla. Estos ajustes mejoraron la precisión y robustez, asegurando un análisis más confiable y efectivo del estado del pavimento.

Tabla 26

Resultados de mAP50 y condición técnica por clase

Clase	mAP50(B)	mAP50(M)	Condición Técnica
PC_B	0.577	0.622	Rendimiento moderado; las cuarteaduras de severidad baja tienen menor visibilidad y se confunden con otras clases similares.
PC_A	0.794	0.810	Alto desempeño; las cuarteaduras severas tienen patrones claros y buena representación, facilitando su detección.
FS_B	0.276	0.281	Bajo rendimiento; fisuras severas con anchos variables y tamaño pequeño, altamente confundidas con el fondo.
FS_A	0.458	0.464	Rendimiento bajo; principalmente por anchos variables.
DC_B	0.723	0.722	Desempeño aceptable; los deterioros de severidad baja tienen menor visibilidad, lo que genera cierta confusión con el fondo.
DC_A	0.812	0.783	Buen rendimiento; los deterioros severos son más visibles y uniformes, permitiendo una detección y segmentación efectiva.
BCH_B	0.734	0.730	Desempeño aceptable; los baches de severidad baja tienen contornos menos definidos, afectando su precisión.
BCH_A	0.842	0.834	Alto desempeño; los baches severos tienen contornos marcados y buena representación, facilitando su identificación.
PCH	0.879	0.879	Excelente rendimiento; los parches son visualmente distintivos y bien representados, logrando una clasificación precisa.

El modelo destaca en clases como PCH (0.879), BCH_A (0.842), y DC_A (0.812), gracias a su alta representación y características visuales claras, mientras que fisuras como FS_B (0.276) y FS_A (0.458) presentan bajo rendimiento por su tamaño pequeño, variabilidad en anchos, y confusión con el fondo. Clases intermedias como DC_B (0.723) y BCH_B (0.734) son aceptables, pero se ven afectadas por menor severidad.

Análisis de curvas Precision-Recall

Las curvas Precision-Recall presentadas en las Figuras 45 y 46 ofrecen un análisis detallado del rendimiento del modelo PAVEMAI por clase, ilustrando el equilibrio entre precisión (proporción de detecciones correctas entre las predichas) y recall (proporción de fallas reales detectadas entre todas las existentes) para cada tipo de falla en el pavimento. Estas gráficas permiten identificar patrones específicos y evaluar la capacidad del modelo para manejar las características únicas de cada clase, incluyendo fallas como piel de cocodrilo (PC), descascaramientos (DC), fisuras (FS), baches (BCH) y parches (PCH), con subcategorías que reflejan diferentes niveles de severidad.

Figura 45

Curva Precision-Recall para Detección





Figura 46
Curva Precision-Recall para segmentación



En estas curvas se observa claramente la estratificación del rendimiento:

- **Rendimiento superior (PCH, BCH_A, DC_A):** Mantienen precisión alta (> 0.7) incluso con valores de recall elevados (> 0.7), evidenciando la robustez del modelo para detectar estas fallas.
- **Rendimiento intermedio (PC_A, BCH_B, DC_B):** Presentan curvas que mantienen buena precisión hasta recalls moderados, con caídas más pronunciadas al aumentar el recall.
- **Rendimiento deficiente (FS_A, FS_B):** Muestran un deterioro rápido de la precisión incluso con recalls bajos, especialmente FS_B (línea marrón), cuya curva cae por debajo de 0.5 de precisión con apenas 0.2 de recall.

La curva general del modelo (línea azul gruesa) indica un mAP@0.5 promedio de 0.681, confirmando un desempeño global aceptable a pesar de las limitaciones en clases específicas.

Matriz de confusión


permite evaluar la precisión de clasificación por clase, mostrando el número de instancias predichas correctamente (verdaderos positivos), las confundidas con otras clases (falsos negativos), y las clasificadas como fondo (falsos positivos). Este análisis es crucial para identificar patrones de error y fortalezas del modelo. A continuación, se presenta una tabla que resume las predicciones correctas, las confusiones con otras clases, y las confusiones con el fondo

Tabla 27
Resultados de clasificación por clase

Clase	Predicciones Correctas	Confundidas con Otras Clases	Confundidas con Fondo
PC_A	112	11 (principalmente PC_B)	42
PC_B	83	11 (principalmente PC_A)	65
DC_A	67	1 (PC_A)	29
PCH	90	2 (DC_A)	39
FS_A	123	39 (principalmente FS_B)	96
FS_B	67	39 (principalmente FS_A)	122
DC_B	43	1 (DC_A)	78
BCH_B	35	6 (BCH_A)	37
BCH_A	89	8 (BCH_B)	60

El modelo YOLOv8n-seg logra alta precisión en clases bien representadas como PCH (88%), PC_A (82%), DC_A (82%) y BCH_A (81%), gracias a sus características visuales distintivas mientras las clases intermedias como PC_B (64%), DC_B (64%) y BCH_B (66%) tienen un desempeño aceptable, pero muestran confusiones con el fondo (26%, 26% y 18%, respectivamente) por su menor severidad, sin embargo, FS_B (28%) presenta un bajo rendimiento, con un 56% de confusión con el fondo y 16% con FS_A, debido a su tamaño reducido y variabilidad en anchos, el caucual se representa la siguiente figura 47.


Figura 47
Matriz de confusión del modelo8n



Análisis complementario de dos fases visuales

En la Figura 48 muestra la clasificación de deterioros identificados por PAVEMAI, donde cada tipo de falla se representa con un color específico: piel de cocodrilo (PC_A: azul, PC_B: turquesa), fisuras (FS_A: azul oscuro, FS_B: rosa), baches (BCH_A: verde brillante, BCH_B: verde claro), descascaramientos (DC_A/B: rojo) y parches (PCH: turquesa).

Figura 48
Detección y clasificación




La verificación con niveles de confianza se muestra Figura 49, el cual valida las detecciones

anteriores de la Figura 48 añadiendo niveles de confianza (0.3-1.0), revelando mayor certeza en fallas visualmente distintivas como baches (0.7-0.9) y piel de cocodrilo severa (0.7-0.9), mientras las fisuras reciben valores menores (0.3-0.4).

Figura 49

Verificación con niveles de confianza



Análisis del bajo rendimiento de las fisuras

El bajo rendimiento en FS_A (0.458) y FS_B (0.276) es un punto débil que afecta el cumplimiento total de la hipótesis. Este comportamiento se explica por la variabilidad en la distribución de anchos de las fisuras dentro de un mismo fotograma:

- **Variedad de anchos y confusión:** En un fotograma, las fisuras presentan una distribución heterogénea de anchos, que varían entre severidad baja (FS_A) y alta (FS_B). Esta variabilidad genera confusión en el modelo, ya que no puede diferenciar claramente entre FS_A y FS_B, como se observa en la matriz de confusión (Figura 2), donde 39 instancias de FS_B fueron clasificadas como FS_A. Además, 122 instancias de FS_B fueron confundidas con el fondo, lo que sugiere que el modelo no detecta correctamente fisuras de severidad alta debido a su ancho variable.
- **Impacto del aumento de datos:** A pesar de que se agregaron más datos de fisuras para mejorar su representación, el rendimiento no mejoró significativamente (FS_A: 0.458, FS_B: 0.276). Esto se debe a que la variedad de anchos persiste, dificultando al modelo establecer patrones claros para diferenciar entre severidad baja y alta.
- **Casos de ancho constante:** En escenarios donde las fisuras tienen un ancho constante (e.g., fisuras uniformes en imágenes controladas), el modelo realiza una

detección y segmentación correctas. Esto se infiere del hecho de que otras clases con características más uniformes, como PCH (0.879) y BCH_A (0.842), tienen un rendimiento significativamente mejor. La uniformidad en el ancho permite al modelo identificar patrones consistentes, mientras que la variabilidad en las fisuras introduce ruido en el aprendizaje.

- **Limitaciones de Hardware y resolución:** La confusión con el fondo y el bajo rendimiento en fisuras se agravan por hardware limitado, que impide usar modelos avanzados de YOLO (como YOLOv8m o YOLOv8l) capaces de capturar detalles finos. Además, la normalización a 640x640 píxeles reduce la calidad de las imágenes, haciendo que las fisuras se asemejen al fondo y dificultando su detección.

La hipótesis 01 se considera parcialmente cumplida. El modelo YOLOv8n-seg permite la identificación y clasificación automática de diferentes tipos de falla en pavimentos flexibles, como lo demuestran el mAP50(B) de 0.68269, la Precision(B) de 0.68565, y el Recall(B) de 0.63742.

4.1.2. Hipótesis específica 2

El desarrollo de un programa mediante algoritmos de inteligencia artificial permite determinar la calificación de condición del pavimento flexible.

Desarrollo de PAVEMAI

PAVEMAI se diseñó como una solución tecnológica innovadora para la inspección automatizada de pavimentos flexibles, utilizando inteligencia artificial para procesar videos y determinar el índice de condición del pavimento. El programa se desarrolló siguiendo estrictamente los lineamientos del Manual de Carreteras: Mantenimiento o Conservación Vial - 2018 del Ministerio de Transportes y Comunicaciones (MTC), garantizando que la metodología de evaluación sea técnica, estandarizada y aplicable al contexto de la ingeniería civil. Este enfoque normativo asegura que los resultados sean comparables con inspecciones manuales tradicionales, pero con la ventaja de la automatización.

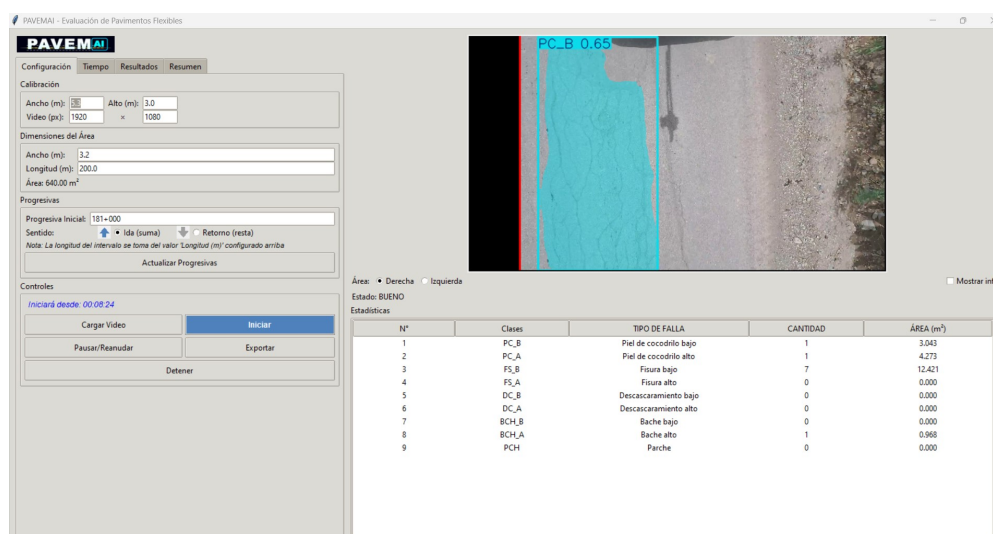
4.1.2.1 Detección y clasificación de fallas mediante Visión Artificial

PAVEMAI utiliza el modelo YOLOv8n-seg para detectar y segmentar fallas en pavimentos flexibles, identificando deterioros clave como piel de cocodrilo, fisuras, descascaramientos, baches y parches, con sus respectivos niveles de severidad (baja y alta). El sistema

procesa fotogramas de video en tiempo real, capturados desde un vehículo en movimiento, identificando anomalías y segmentando las áreas afectadas con alta precisión.

- **Configuración ajustada:** La evaluación se realizó por carril y berma contigua, con un hilo programado que delimita el área de análisis. Las progresivas y dimensiones del área se ajustaron en la pestaña "Configuración" (Figura 50) para adaptarse a tramos asfálticos, considerando el sentido del recorrido (ida y retorno).
- **Detección y segmentación:** La conversión de las áreas detectadas, expresadas en píxeles, a metros cuadrados se realizó de forma automática, utilizando las dimensiones reales representadas por cada fotograma, configuradas previamente en la pestaña "Configuración-calibración" (Figura 50). El área de las fallas se calculó a partir de las cajas delimitadoras (bounding boxes) generadas por el modelo de detección. La segmentación a nivel de píxel sirvió como apoyo visual para validar y respaldar la precisión de las detecciones.
- **Seguimiento avanzado:** PAVEMAI usa un sistema que identifica cada falla de manera única, teniendo en cuenta su lugar, tamaño y tipo, para no contar la misma falla varias veces, el cual se logró con una herramienta llamada BoT-SORT. Además, ajustó el tiempo que necesita para confirmar una falla según su importancia, fue más estricto con fallas como los baches y más flexible con las fisuras, asegurando que las detecciones fueran confiables. La Figura 50 muestra cómo el sistema detectó en tiempo real una piel de cocodrilo de baja severidad (PC_B), marcada claramente en la imagen del pavimento.

Figura 50
Interfaz del programa PAVEMAI



4.1.2.2 Presentación de resultados

PAVEMAI cuenta con una interfaz gráfica compuesta por cuatro pestañas principales: *Configuración*, *Tiempo*, *Resultados* y *Resumen*, cuyo uso detallado se encuentra en el manual de usuario incluido en los anexos de esta investigación. El sistema está programado para evaluar un kilómetro de longitud, segmentado en cinco tramos de 200 metros cada uno. Estos intervalos se configuran en la pestaña *Tiempo* (Figura 51) mediante la asignación de progresivas (formato KM+M) y los tiempos de inicio y fin correspondientes.

Figura 51
Pestaña de tiempo para delimitar tramos de estudios

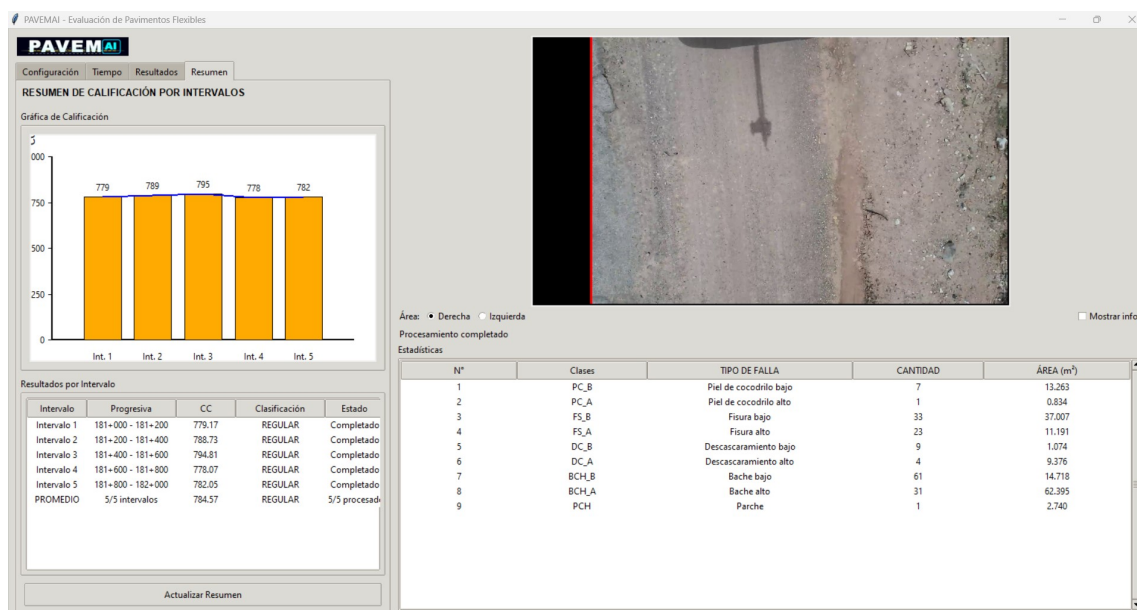
N°	Clases	TIPO DE FALLA	CANTIDAD	ÁREA (m²)
1	PC_B	Piel de cocodrilo bajo	1	4.604
2	PC_A	Piel de cocodrilo alto	0	0.000
3	FS_B	Fisura bajo	28	38.879
4	FS_A	Fisura alto	31	58.851
5	DC_B	Descascaramiento bajo	2	0.289
6	DC_A	Descascaramiento alto	0	0.000
7	BCH_B	Bache bajo	0	0.000
8	BCH_A	Bache alto	0	0.000
9	PCH	Parche	0	0.000

La pestaña *Resumen* (Figura 52) presenta de forma sintetizada los resultados de la evaluación a través de los siguientes elementos:

- **Gráfica de condición del pavimento:** muestra los valores obtenidos en los cinco intervalos analizados.
- **Tabla estadística de deterioros:** detalla las fallas detectadas por tipo y severidad.

Adicionalmente, todos los resultados son exportables a formato Excel mediante el botón *Exportar* (Figura 50), lo que permite facilitar su análisis y respaldo documental. Esta funcionalidad contribuye a una evaluación objetiva del estado del pavimento, clasificándolo en categorías como *Buena*, *Regular* o *Deficiente*, lo cual respalda la hipótesis de investigación.

Figura 52
Pestaña de resumen del programa PAVEMAI.



4.1.3. Hipótesis específica 3

La metodología implementada mediante un modelo de visión artificial es fiable para la evaluación del estado de conservación de pavimentos flexibles en comparación con las metodologías tradicionales.

4.1.3.1 Tramo de evaluación

La implementación de la metodología mediante visión artificial, se llevó a cabo en un tramo específico de la Ruta Nacional PE-26B, que conecta las regiones de Ayacucho y Huancavelica, comprendido entre las progresivas 181+000 y 183+000, con una longitud total de 2 km. La selección de este segmento se fundamenta en diversas características técnicas, logísticas y prácticas que lo convierten en un escenario idóneo para la evaluación del estado de conservación de pavimentos flexibles y la comparación con metodologías tradicionales como el PCI, VIZIR y el método del MTC.

La evaluación se realizó de manera sistemática por carriles, recorriendo ambos sentidos de la vía para garantizar una cobertura completa del tramo. En el primer recorrido, se evaluó el carril en el sentido descendente, desde la progresiva 183+000 hasta la progresiva 181+000. Posteriormente, se retornó por el carril opuesto en el sentido ascendente, desde la progresiva 181+000 hasta la progresiva 183+000, completando así los 2 km de longitud en ambas direcciones. Este enfoque permitió capturar imágenes de alta resolución de ambos

carriles, asegurando que las condiciones del pavimento fueran evaluadas de manera integral y representativa.

1. Baja transitabilidad vehicular:

El tramo seleccionado presenta una baja densidad de tráfico vehicular, lo que facilita la captura de imágenes de alta calidad sin interrupciones significativas. Además, esta condición facilita la realización de inspecciones manuales detalladas para la evaluación por los métodos tradicionales y la integridad de la seguridad del evaluador.

2. Condiciones ambientales y de visibilidad desafiantes:

La Ruta Nacional PE-26B, en el segmento elegido, atraviesa un entorno donde se presentan condiciones variables que afectan la visibilidad del pavimento. Entre estas se encuentran sombras proyectadas por la vegetación circundante y sectores donde el polvo ha invadido la superficie del pavimento, generando ruido visual. Estas características son representativas de los retos que enfrenta la visión artificial en entornos reales, lo que permite poner a prueba la robustez de los algoritmos de PAVEMAI.

3. Presencia de fallas representativas:

El tramo entre las progresivas 181+000 y 183+000 exhibe una amplia variedad de deterioros en el pavimento flexible, incluyendo los cinco tipos de fallas principales que PAVEMAI está diseñado para detectar: piel de cocodrilo, fisuras (longitudinales y transversales), baches, descascaramiento y parches. Esta diversidad asegura que el modelo de inteligencia artificial pueda ser evaluado en un escenario realista, abarcando todas las categorías de deterioro incorporadas en el dataset de entrenamiento.

4. Adecuación para la comparación con métodos tradicionales:

Las características del tramo seleccionado permiten realizar una evaluación exhaustiva utilizando tanto la metodología PAVEMAI como los métodos tradicionales. La longitud de 2 km es manejable para inspecciones manuales detalladas, lo que facilita la comparación directa de los resultados obtenidos por el programa PAVEMAI.

4.1.3.2 Evaluación de la de la vía mediante metodología de visión artificial


La evaluación del estado de conservación del pavimento flexible en el tramo de 2 km de la Ruta Nacional PE-26B se llevó a cabo utilizando la metodología mediante visión artificial. El tramo se dividió en 20 unidades de muestra, tomando 10 muestras en el sentido

descendente (de la progresiva 183+000 a 181+000) y 10 en el sentido ascendente (de 181+000 a 183+000), con una distancia de 200 m entre cada muestra, lo que permitió una evaluación detallada y representativa de ambos carriles.

El programa PAVEMAI procesó las imágenes de las 20 unidades de muestra y detectó las fallas, identificando su tipo y calculando la incidencia de cada una en el tramo evaluado. La distribución de las fallas se presenta en la Figura 53: Porcentaje de extensión por tipos de fallas, que muestra los siguientes resultados:

Figura 53

Porcentaje de extensión por tipo de falla.



El análisis de las fallas detectadas por el programa PAVEMAI , reveló que los baches fueron los más predominantes, con un 38.87% de extensión, seguidos de cerca por las fisuras, que alcanzaron un 33.89%, evidenciando un deterioro significativo en el pavimento. La piel de cocodrilo mostró una incidencia del 15.41%, señalando áreas con degradación avanzada, mientras que los parches y el descascaramiento, con un 6.37% y un 5.46% respectivamente, indicaron una menor presencia. Esta distribución destaca los deterioros más críticos que afectan la vía.

Calificación de los tramos evaluados

Con base en las fallas detectadas, se asignó una calificación de condición (CC) a cada una de las 20 unidades de muestra, siguiendo una metodología adaptada de los criterios del MTC para pavimentos flexibles. La calificación de condición refleja el estado de conservación del pavimento en cada segmento, considerando la severidad y extensión de las fallas

identificadas por PAVEMAI. Los resultados se presentan en la siguiente tabla 28:

Tabla 28

Valores de CC y su clasificación por tramo evaluado

N°	Progresiva	C. de condición	Estado
1	183+000 - 182+800	784.34	Regular
2	182+800 - 182+600	770.02	Regular
3	182+600 - 182+400	789.42	Regular
4	182+400 - 182+200	786.95	Regular
5	182+200 - 182+000	778.51	Regular
6	182+000 - 181+800	776.94	Regular
7	181+800 - 181+600	780.94	Regular
8	181+600 - 181+400	796.72	Regular
9	181+400 - 181+200	785.18	Regular
10	181+200 - 181+000	785.60	Regular
11	181+000 - 181+200	777.28	Regular
12	181+200 - 181+400	785.42	Regular
13	181+400 - 181+600	795.17	Regular
14	181+600 - 181+800	778.52	Regular
15	181+800 - 182+000	780.94	Regular
16	182+000 - 182+200	776.39	Regular
17	182+200 - 182+400	790.42	Regular
18	182+400 - 182+600	785.21	Regular
19	182+600 - 182+800	788.62	Regular
20	182+800 - 183+000	861.66	Bueno


La evaluación de las 20 unidades de muestra procesadas mediante el programa PAVEMAI, presentada en la tabla, muestra la Puntuación de Condición (CC) de cada segmento del tramo de la Ruta Nacional PE-26B. Las CC oscilan entre 795.17 (progresiva 181+400-181+600) y 861.66 (progresiva 182+800-183+000), indicando un estado general que varía de "Regular" a "Bueno". El 95% de la muestra (19 de 20) obtuvieron un estado "Regular", con CC entre 770.02 y 789.42, reflejando un deterioro moderado influenciado por la alta incidencia de baches y fisuras. Solo el tramo final representando un 5% (progresiva 182+800-183+000) alcanzó un estado "Bueno" con 861.66, sugiriendo una mejor conservación en este tramo.

4.1.3.3 Evaluación de la vía mediante la metodología del MTC.

De acuerdo con los cálculos realizados para todas las unidades de muestra, siguiendo las directrices del Manual de Carreteras: Mantenimiento o Conservación Vial del MTC, se elaboró un resumen de los resultados que detalla los tipos de fallas identificados según la figura 54.

En el tramo evaluado presenta

Figura 54
Porcentaje de extensión por tipo de falla.



La falla más predominante fue la peladura y desprendimiento, con un 43.1% de incidencia, lo que indica una pérdida significativa de la capa superficial del pavimento. Le siguieron los daños puntuales en la berma el cual fue continuo en la zona de estudio, con un 13.1%. Los baches (huecos) y el ahuellamiento presentaron una incidencia del 11.7% y 11.2%, respectivamente, señalando problemas estructurales y deformaciones acumuladas por el tráfico. La piel de cocodrilo, con un 8.3%, evidenció fatiga estructural en la capa asfáltica debido a cargas repetitivas de vehículos pesados. Las fisuras longitudinales (7.8%) y transversales (1.2%) indicaron movimientos térmicos y estructurales, mientras que la reparación o parchado (1.9%) mostró intervenciones previas en áreas deterioradas. Por último, la deformación por deficiencia estructural (1.0%) y el desnivel calzada-berma (0.9%) tuvieron una incidencia menor, pero contribuyen al deterioro general del pavimento.

Calificación de los tramos evaluados

Con base en las fallas identificadas, se asignó una Calificación de Condición (CC) a cada una

de las unidades de muestra, siguiendo los criterios del MTC. Para ello, se midió la extensión promedio ponderado de cada tipo de falla tomando en cuenta su grado de severidad (baja, media y alta), y se calcularon la calificación de condición que se muestra en la siguiente tabla 29.

Tabla 29

Calificación de condición y tipo de intervención por tramo evaluado

N°	Progresiva	Calificación	Tipo de Intervención
1	183+000 - 182+800	955.89	Conservación rutinaria
2	182+800 - 182+600	795.08	Conservación periódica
3	182+600 - 182+400	830.44	Conservación rutinaria
4	182+400 - 182+200	793.89	Conservación periódica
5	182+200 - 182+000	781.18	Conservación periódica
6	182+000 - 181+800	767.00	Conservación periódica
7	181+800 - 181+600	780.90	Conservación periódica
8	181+600 - 181+400	826.52	Conservación rutinaria
9	181+400 - 181+200	780.29	Conservación periódica
10	181+200 - 181+000	787.58	Conservación periódica
11	181+000 - 181+200	788.28	Conservación periódica
12	181+200 - 181+400	787.79	Conservación periódica
13	181+400 - 181+600	866.69	Conservación rutinaria
14	181+600 - 181+800	780.02	Conservación periódica
15	181+800 - 182+000	790.90	Conservación periódica
16	182+000 - 182+200	795.56	Conservación periódica
17	182+200 - 182+400	797.29	Conservación periódica
18	182+400 - 182+600	823.26	Conservación rutinaria
19	182+600 - 182+800	788.71	Conservación periódica
20	182+800 - 183+000	919.14	Conservación rutinaria

La distribución de los estados de conservación de las 20 unidades de muestra indica que el 70% de los tramos presentan un estado "Regular", mientras que el 30% se clasifican como "Bueno". Ningún tramo fue calificado como "Malo". Esta representación gráfica destaca que la mayoría del pavimento exhibe un deterioro moderado, influenciado por las fallas predominantes como peladura y desprendimiento, daños puntuales en berma y baches, aunque un tercio de los tramos muestran una condición más favorable. La vía evaluada presenta una condición predominantemente "Regular", según el Manual del MTC, ofreciendo un servicio aceptable pero limitado por deterioros como peladura y baches.

4.1.3.4 Propuesta técnica de intervención

Con base en los resultados obtenidos de la evaluación visual del tramo en estudio, se plantean propuestas técnicas de intervención en concordancia con los lineamientos establecidos por el Manual de Carreteras: mantenimiento o conservación vial. Los cálculos correspondientes a la Calificación de Condición (CC) y la cuantificación de los deterioros identificados se encuentran detallados en el Anexo D.

Progresiva 181+000 - 181+200

La propuesta de conservación periódica contempla un total de 10 tipos de deterioro, distribuidos en diferentes niveles de gravedad, que requieren 7 actividades principales de conservación. Esta propuesta destaca por presentar las fisuras longitudinales más extensas registradas en toda la evaluación. A continuación, en la Tabla 30, se presentan las propuestas de solución correspondientes al tramo evaluado.

Tabla 30

Actividades propuestas: progresiva 181+000 - 181+200

Actividad de conservación	Sección MTC	Unidad	Cantidad total	Deterioros
Fresado de carpeta asfáltica	465	m ²	251.50	Piel de coc. G2-G3, Fisuras long. G3, Deformaciones, Ahuellamiento, Peladura G2-G3, Reparaciones G2
Recapeos asfálticos	460	m ²	251.50	Renovación integral superficie
Parchado profundo en calzada	415	m ²	11.00	Baches G3
Parchado superficial en calzada	410	m ²	29.00	Baches G1-G2
Sellado de fisuras y grietas	401	m	40.76	Fisuras longitudinales G1-G2 y transversales
Reconformación de base granular en bermas	475	m ²	60.80	Daños críticos bermas G3
Nivelación de bermas con material granular	430	m	49.30	Daños bermas G2 + desnivel

Progresiva 181+200 - 181+400

La propuesta de conservación periódica contempla un total de 10 tipos de deterioro, distribuidos en diferentes niveles de gravedad, que requieren 7 actividades principales de conservación, según las especificaciones técnicas del Manual del MTC. A continuación, en la Tabla 31, se presentan las propuestas de solución correspondientes al tramo evaluado.

Tabla 31

Actividades propuestas: progresiva 181+200 - 181+400

Actividad de conservación	Sección MTC	Unidad	Cantidad total	Deterioros atendidos
Fresado de carpeta asfáltica	465	m ²	196	Piel de coc. G2-G3, Fisuras long. G3, Deformaciones G2, Ahuellamiento, Peladura G2-G3, Reparaciones G2
Recapeos asfálticos	460	m ²	196	Renovación integral superficie
Parchado profundo en calzada	415	m ²	6.00	Baches G3
Parchado superficial en calzada	410	m ²	26.00	Baches G1-G2
Sellado de fisuras y grietas	401	m	39.15	Fisuras longitudinales G1-G2 y transversales todos los niveles
Reconformación de base granular en bermas	475	m ²	58.00	Daños críticos bermas G3
Nivelación de bermas con material granular	430	m	54.00	Daños bermas G1-G2 + desnivel

Progresiva 181+400 - 181+600

La propuesta de mantenimiento rutinario contempla un total de 9 tipos de deterioro, distribuidos en diferentes niveles de gravedad, que requieren 6 actividades principales de conservación. A continuación, en la Tabla 32, se presentan las propuestas de solución correspondientes al tramo evaluado.

Tabla 32*Actividades propuestas: progresiva 181+400 - 181+600*

Actividad de mantenimiento	Sección MTC	Unidad	Cantidad total	Deterioros atendidos
Parchado profundo en calzada	415	m ²	2.40	Fisuras longitudinales G3
Parchado superficial en calzada	410	m ²	43.20	Piel de coc. G2, Deformaciones G1, Peladura G2-G3, Baches G1-G2-G3, Reparaciones G2
Sellado de fisuras y grietas	401	m	17.40	Fisuras longitudinales G1-G2, Fisuras transversales G1-G2, Piel de coc. G1
Sellos asfálticos	455	m ²	88.00	Peladura y desprendimiento G1
Parchado profundo de bermas	445	m ²	19.00	Daños puntuales berma G3
Parchado superficial de bermas	435	m ²	35.80	Daños puntuales berma G2

Progresiva 181+600 - 181+800

La propuesta de conservación periódica contempla un total de 10 tipos de deterioro, distribuidos en diferentes niveles de gravedad, que requieren 7 actividades principales de conservación según las especificaciones técnicas del Manual del MTC. Este tramo presenta características particulares que justifican una estrategia de renovación integral, destacando por la diversificación de deterioros en múltiples niveles de severidad y la necesidad de intervenciones coordinadas tanto en calzada como en bermas. La estrategia implementa un enfoque de fresado selectivo (188 m²) seguido de recapeo equivalente, complementado con reconformación integral de bermas (53.80 m²) para restaurar el confinamiento lateral y asegurar la efectividad a largo plazo de la renovación superficial del pavimento. A continuación, en la Tabla 33, se presentan las propuestas de solución correspondientes al tramo evaluado.

Tabla 33*Actividades propuestas: progresiva 181+600 - 181+800*

Actividad de conservación	Sección MTC	Unidad	Cantidad total	Deterioros atendidos
Fresado de carpeta asfáltica	465	m ²	188	Piel de coc. G2-G3, Fisuras long. G3, Deformaciones, Ahuellamiento, Peladura G2-G3, Reparaciones G2
Recapeos asfálticos	460	m ²	188	Renovación integral superficie
Parchado profundo en calzada	415	m ²	16.00	Baches G3
Parchado superficial en calzada	410	m ²	19.00	Baches G1-G2
Sellado de fisuras y grietas	401	m	35.46	Fisuras longitudinales G1-G2 y transversales todos los niveles
Reconformación de base granular en bermas	475	m ²	53.80	Daños críticos bermas G3
Nivelación de bermas con material granular	430	m	86.05	Daños bermas G1-G2 + desnivel G1-G2

Progresiva 181+800 - 182+000

La propuesta de conservación periódica contempla un total de 9 tipos de deterioro que requieren 7 actividades principales de conservación, según las especificaciones técnicas del Manual del MTC. Esta propuesta representa la intervención más extensa y crítica de toda la evaluación realizada, caracterizándose por la máxima reconformación de bermas registrada (71.00 m²) y una estrategia de renovación integral que incluye fresado selectivo de 203 m² con recapeo equivalente. El tramo evidencia un deterioro estructural avanzado que requiere la aplicación coordinada de todas las herramientas de conservación periódica disponibles, desde reparaciones preparatorias hasta reconformación total del sistema de confinamiento lateral. La magnitud de la intervención en bermas (71.00 m² - máximo registrado) refleja la criticidad del compromiso estructural del sistema de pavimentación,

requiriendo un enfoque integral que aborde simultáneamente los deterioros de calzada y la restauración completa del confinamiento lateral para asegurar la efectividad a largo plazo de la renovación superficial. A continuación, en la Tabla 34, se presentan las propuestas de solución correspondientes a dicho tramo.

Tabla 34

Actividades propuestas: progresiva 181+800 - 182+000

Actividad de conservación	Sección MTC	Unidad	Cantidad total	Deterioros atendidos
Fresado de carpeta asfáltica	465	m ²	203	Piel de coc. G2-G3, Fisuras long. G3, Ahuellamiento, Peladura G2-G3, Reparaciones G2
Recapeos asfálticos	460	m ²	203	Renovación integral superficie
Parchado profundo en calzada	415	m ²	15.00	Baches G3
Parchado superficial en calzada	410	m ²	50.80	Baches G1-G2
Sellado de fisuras y grietas	401	m	26.72	Fisuras longitudinales G1-G2 y transversales todos los niveles
Reconformación de base granular en bermas	475	m ²	71.00	Daños críticos bermas G3 (máximo registrado)
Nivelación de bermas con material granular	430	m	37.50	Daños bermas G2 + desnivel

Progresiva 182+000 - 182+200

La propuesta de conservación periódica contempla un total de 10 tipos de deterioro, distribuidos en diferentes niveles de gravedad, que requieren 7 actividades principales de conservación. Esta propuesta implementa una estrategia de fresado-recapeo de 164 m² y reconformación de bermas (50.35 m²), complementada con extensa nivelación granular (63.50 m) que evidencia un deterioro generalizado del sistema de confinamiento lateral que requiere intervención integral. A continuación, en la Tabla 35, se presentan las propuestas

de solución correspondientes a dicho tramo.

Tabla 35

Actividades propuestas: progresiva 182+000 - 182+200

Actividad de conservación	Sección MTC	Unidad	Cantidad total	Deterioros atendidos
Fresado de carpeta asfáltica	465	m ²	164	Piel de coc. G2-G3, Fisuras long. G3, Deformaciones, Ahuellamiento, Peladura G2-G3, Reparaciones G2
Recapeos asfálticos	460	m ²	164	Renovación integral superficie
Parchado profundo en calzada	415	m ²	4.00	Baches G3
Parchado superficial en calzada	410	m ²	29.00	Baches G1-G2
Sellado de fisuras y grietas	401	m	38.02	Fisuras longitudinales G1-G2 y transversales todos los niveles
Reconformación de base granular en bermas	475	m ²	50.35	Daños críticos bermas G3
Nivelación de bermas con material granular	430	m	63.50	Daños bermas G2 + desnivel

Progresiva 182+200 - 182+400

La propuesta de conservación periódica contempla un total de 9 tipos de deterioro, distribuidos en diferentes niveles de gravedad, que requieren 7 actividades principales de conservación. Esta propuesta implementa una estrategia integral de fresado-recapeo de 202 m² complementada con reconformación de bermas de 71.00 m² y parchado superficial significativo de 50.80 m². La intervención requiere un enfoque coordinado que aborda tanto los deterioros estructurales de la calzada como la restauración del sistema de confinamiento lateral mediante trabajos extensos en bermas. A continuación, en la Tabla 36, se presentan las propuestas de solución correspondientes a dicho tramo.

Tabla 36*Actividades propuestas: progresiva 182+200 - 182+400*

Actividad de conservación	Sección MTC	Unidad	Cantidad total	Deterioros atendidos
Fresado de carpeta asfáltica	465	m ²	202	Piel de coc. G2-G3, Fisuras long. G3, Ahuellamiento, Peladura G2-G3, Reparaciones G2
Recapeos asfálticos	460	m ²	202	Renovación integral superficie
Parchado profundo en calzada	415	m ²	15.00	Baches G3
Parchado superficial en calzada	410	m ²	50.80	Baches G1-G2
Sellado de fisuras y grietas	401	m	26.72	Fisuras longitudinales G1-G2 y transversales todos los niveles
Reconformación de base granular en bermas	475	m ²	71.00	Daños críticos bermas G3 (máximo registrado)
Nivelación de bermas con material granular	430	m	37.50	Daños bermas G2 + desnivel

Progresiva 182+400 - 182+600

La propuesta de mantenimiento rutinario contempla un total de 9 tipos de deterioro, distribuidos en diferentes niveles de gravedad, que requieren 6 actividades principales de conservación, según las especificaciones técnicas del Manual del MTC. Esta estrategia se caracteriza por aplicar intervenciones puntuales y preventivas sin requerir renovación superficial masiva, enfocándose en reparaciones localizadas mediante parchado profundo (11.40 m²) y superficial (27.60 m²), complementadas con sellos asfálticos extensos (126.00 m²) para el tratamiento preventivo de peladuras G1. El enfoque rutinario incluye intervenciones significativas en bermas con parchado profundo (35.00 m²) y superficial (13.50 m²) para atender daños puntuales, manteniendo la funcionalidad del sistema sin requerir reconformación estructural completa. A continuación, en la Tabla 37, se presentan

las propuestas de solución correspondientes al tramo evaluado.

Tabla 37

Actividades propuestas: progresiva 182+400 - 182+600

Actividad de mantenimiento	Sección MTC	Unidad	Cantidad total	Deterioros atendidos
Parchado profundo en calzada	415	m ²	11.40	Fisuras longitudinales G3
Parchado superficial en calzada	410	m ²	27.60	Piel de coc. G2, Deformaciones G2, Peladura G2-G3, Baches G1-G2-G3, Reparaciones G2
Sellado de fisuras y grietas	401	m	31.14	Fisuras longitudinales G1-G2, Fisuras transversales G1-G2, Piel de coc. G1
Sellos asfálticos	455	m ²	126.00	Peladura y desprendimiento G1
Parchado profundo de bermas	445	m ²	35.00	Daños puntuales berma G3
Parchado superficial de bermas	435	m ²	13.50	Daños puntuales berma G2

Progresiva 182+600 - 182+800

La propuesta de conservación periódica considera un total de 10 tipos de deterioro que requieren la ejecución de 7 actividades principales de conservación, con énfasis en tratamientos de renovación integral. Esta estrategia implementa un enfoque diferenciado que incluye fresado selectivo de 143.50 m² para eliminar deformaciones, ahuellamiento y peladuras severas, seguido de recapeo integral de 200.00 m² que excede el área fresada para asegurar renovación superficial completa. La propuesta contempla reparaciones preparatorias equilibradas mediante parchado profundo (22.00 m²) y superficial (22.00 m²) para baches, complementadas con reconformación de bermas (58.50 m²) y nivelación granular (21.00 m) que restauran el sistema de confinamiento lateral necesario para la efectividad de la renovación superficial. A continuación, en la Tabla 38, se presentan las propuestas de solución correspondientes al tramo evaluado.

Tabla 38*Actividades propuestas: progresiva 182+600 - 183+800*

Actividad de conservación	Sección MTC	Unidad	Cantidad total	Deterioros atendidos
Fresado de carpeta asfáltica	465	m ²	143.50	Deformaciones, Ahuellamiento, Peladura G2-G3, Reparaciones G2
Recapeos asfálticos	460	m ²	200.00	Renovación integral superficie
Parchado profundo en calzada	415	m ²	22.00	Baches G3
Parchado superficial en calzada	410	m ²	22.00	Baches G1-G2
Sellado de fisuras y grietas	401	m	30.90	Fisuras longitudinales y transversales
Reconformación de base granular en bermas	475	m ²	58.50	Daños críticos bermas G3
Nivelación de bermas con material granular	430	m	21.00	Desnivel + daños G2 bermas

Progresiva 182+800 - 183+000

En base a la evaluación realizada según la metodología del Manual de Carreteras del MTC, el pavimento presenta una Calificación de Condición (CC) de 937.515, clasificándolo en estado BUENO (CC \geq 800). Esta condición determina que el tipo de conservación apropiado es el mantenimiento rutinario, caracterizado por intervenciones puntuales y preventivas para preservar las condiciones favorables del pavimento. La estrategia contempla reparaciones localizadas mediante parchado profundo mínimo (4.20 m²) para piel de cocodrilo G3 y parchado superficial reducido (7.70 m²) para deterioros menores, complementadas con sellado preventivo de fisuras (31.78 m) y sellos asfálticos (96.00 m²) para tratamiento de peladuras G1. Las intervenciones en bermas se limitan a parchados puntuales profundo (10.50 m²) y superficial (12.00 m²) para mantener la funcionalidad del sistema sin requerir reconformación estructural, reflejando el buen estado general del tramo. A continuación, en la Tabla 39, se presentan las propuestas de solución para el tramo evaluado.

Tabla 39*Actividades propuestas: progresiva 182+800 - 183+000*

Actividad de mantenimiento	Sección MTC	Unidad	Cantidad total	Deterioros atendidos
Parchado profundo en calzada	415	m ²	4.20	Piel de cocodrilo G3
Parchado superficial en calzada	410	m ²	7.70	Piel de cocodrilo G2, Baches G1-G2-G3, Peladura G2
Sellado de fisuras y grietas	401	m	31.78	Fisuras longitudinales G1-G2, Fisuras transversales G1-G2, Piel de cocodrilo G1
Sellos asfálticos	455	m ²	96.00	Peladura y desprendimiento G1
Parchado profundo de bermas	445	m ²	10.50	Daños puntuales berma G3
Parchado superficial de bermas	435	m ²	12.00	Daños puntuales berma G2

El análisis integral del tramo de 2.0 km (progresivas 181+000 a 183+000) reveló la necesidad de aplicar conservación periódica en 7 tramos y mantenimiento rutinario en 3 tramos, evidenciando un estado general que requiere renovación programada con intervenciones puntuales complementarias. La estrategia de conservación periódica contempla 1,348 m² de fresado selectivo seguido de 1,405 m² de recapeo integral, complementados con 773 m² de reconformación y nivelación de bermas para restaurar el sistema de confinamiento lateral. Los tramos de mantenimiento rutinario requieren 126 m² de parchados puntuales, 310 m² de sellos asfálticos preventivos, y 80 m de sellado de fisuras, representando intervenciones de preservación localizada. Esta distribución refleja la variabilidad de condiciones del pavimento a lo largo del tramo evaluado, donde sectores con deterioro estructural avanzado requieren renovación integral, mientras que áreas en mejor estado pueden mantenerse mediante reparaciones focalizadas. La propuesta técnica integral contempla una inversión orientada a restaurar las condiciones estructurales y funcionales del pavimento, extendiendo significativamente su vida útil mediante la aplicación coordinada de las metodologías establecidas en el Manual de Carreteras mantenimiento o conservación vial.

4.1.3.5 Comparación del métodos mediante visión artificial y del MTC


Se realizó un análisis por cada tramo de estudio de las fallas, basado en el cálculo de parámetros de área, para comparar los resultados de PAVEMAI y el MTC, y evaluar las deficiencias y discrepancias, que se detallan a continuación:

- Piel de Cocodrilo

La comparación de áreas afectadas por piel de cocodrilo entre los sistemas PAVEMAI (línea azul) y MTC (línea roja) a lo largo de diferentes progresivas (km). Se observa que, aunque los cálculos de área por tramos son relativamente similares, existen diferencias notables en ciertos puntos. Estas discrepancias surgen principalmente en el contexto de fallas continuas, donde el sistema PAVEMAI, que basa su seguimiento de objetos en la geometría, puede no detectar algunas fallas. Por ejemplo, en progresivas como 182+000 y 182+200, PAVEMAI reporta áreas significativamente menores que MTC, lo que sugiere una posible omisión de fallas continuas. Además, PAVEMAI tiende a agrupar fisuras ramificadas y las identifica como piel de cocodrilo, lo que genera variaciones en el cálculo, como se ve en picos discrepantes (182+800 - 182+600), ver Figura 55.

Figura 55

Comparación de áreas afectadas por piel de cocodrilo.




- Fisuras

La metodología PAVEMAI reporta un área de fisuras mayor al emplear cajas

delimitadoras que incluyen zonas sin fisuras, lo que puede sobreestimar el daño. Por otro lado, la metodología del MTC calcula el área de fisuras considerando la longitud de la fisura y un ancho estándar definido según su severidad, ofreciendo una estimación más precisa. Además, PAVEMAI presenta limitaciones para detectar fisuras muy delgadas, ya que normaliza las imágenes a una resolución de 640x640 píxeles, lo que puede reducir la sensibilidad del modelo ante detalles finos, como se muestra en la Figura 56.


Figura 56
Comparación de áreas afectadas por fisuras.



- Descascaramiento vs. Peladura/Desprendimiento

La diferencia fundamental radica en las definiciones empleadas. PAVEMAI sigue el Manual de INVÍAS, que define el descascaramiento con criterios geométricos específicos. El MTC, en cambio, agrupa bajo “peladura y desprendimiento” diversos daños superficiales, como pérdida de ligante, desintegración y meteorización. Esto explica su alta incidencia de la metodología del MTC frente al de PAVEMAI, como se muestra en la Figura 57.


Figura 57
 Comparación de áreas afectadas por Descascaramiento vs. Peladura/Desprendimiento.



- Baches

Las discrepancias entre PAVEMAI y la metodología del MTC en el cálculo del área de los baches se deben principalmente a diferencias en los criterios de conteo y definición. PAVEMAI tiende a contabilizar múltiples veces un mismo objeto, lo que puede inflar los resultados, e identifica baches tanto en la calzada como en la berma. En cambio, el MTC solo considera como baches aquellos ubicados en la calzada, excluyendo los daños en la berma, como se muestra en la Figura 58.


Figura 58
 Comparación de áreas afectadas por baches.



- Parches

La detección de parches muestra mayor coincidencia gracias a sus bordes definidos y alto contraste, que facilitan su identificación por ambos métodos. Sin embargo, PAVEMAI puede fragmentar un mismo parche en múltiples registros si presenta variaciones visuales o durante desplazamientos lentos, como se muestra en la Figura 59.

Figura 59
Comparación de áreas afectadas por parches.



Posteriormente se realizó una comparación entre los resultados obtenidos mediante el método de visión artificial y la metodología tradicional del Manual de Carreteras: Mantenimiento o Conservación Vial del MTC, con el objetivo de evaluar la fiabilidad del método mediante visión artificial en el diagnóstico del estado del pavimento, los resultados se muestran en la La Tabla 40 .


Tabla 40*Valores de PAVEMAI, MTC y su diferencia por tramo evaluado*

N°	Progresiva	PAVEMAI	MTC	Diferencia (MTC - PAVEMAI)
1	183+000 - 182+800	784.34	955.89	171.55
2	182+800 - 182+600	770.02	795.08	25.06
3	182+600 - 182+400	789.42	830.44	41.02
4	182+400 - 182+200	786.59	793.89	7.30
5	182+200 - 182+000	781.51	781.18	-0.33
6	182+000 - 181+800	776.94	767.00	-9.94
7	181+800 - 181+600	780.94	780.90	-0.04
8	181+600 - 181+400	796.72	826.52	29.80
9	181+400 - 181+200	785.18	780.29	-4.89
10	181+200 - 181+000	785.60	787.58	1.98
11	181+000 - 181+200	777.28	788.28	11.00
12	181+200 - 181+400	785.42	787.79	2.37
13	181+400 - 181+600	795.17	866.69	71.52
14	181+600 - 181+800	778.52	780.02	1.50
15	181+800 - 182+000	780.94	790.90	9.96
16	182+000 - 182+200	776.39	795.56	19.17
17	182+200 - 182+400	790.42	797.29	6.87
18	182+400 - 182+600	785.21	823.26	38.05
19	182+600 - 182+800	788.62	788.71	0.09
20	182+800 - 183+000	861.66	919.14	57.48

En la figura 60 revela que la calificación de condición del MTC son consistentemente más altas que las del método mediante visión artificial, en la mayoría de los tramos, con diferencias marcadas en las progresivas 183+000 - 182+800 con una diferencia del 171.55 y 181+400 - 181+600 con una diferencia de 71.52. los resultados del programa Pavemai exhibe una tendencia más estable, con fluctuaciones menores (rango: 770.02 a 861.58), mientras que el MTC presenta mayor variabilidad (rango: 767.00 a 955.89), especialmente en los tramos inicial y final, donde alcanza valores superiores a 900.

Figura 60

Comparativa de calificación de condición entre el método MTC y basada en visión artificial.



Finalmente, en la Tabla 41 se presenta un análisis de confiabilidad del método PAVEMAI respecto al método del MTC. Se observa que en un 75% de los tramos evaluados, la diferencia de calificación es menor o igual a 30 puntos, lo cual se considera un nivel aceptable para fines de diagnóstico superficial. Además, un 55% de los tramos muestran una diferencia inferior a 10 puntos, reflejando una alta precisión del sistema basado en visión artificial.

Tabla 41

Análisis de Confiabilidad por niveles de precisión

Nivel de confiabilidad	Rango Error	Nº Tramos	Porcentaje
Alta Precisión	≤ 10	11	55.0%
Precisión Moderada	11–30	4	20.0%
Baja Precisión	> 30	5	25.0%
Total aceptable	≤ 30	15	75.0%

Para una mejor interpretación, se realiza un análisis estadístico, con las siguientes hipótesis:

- H_0 (hipótesis nula): No existe diferencia significativa entre las calificaciones de

condición (CC) obtenidas por PAVEMAI y el MTC, indicando que PAVEMAI es fiable.

- H_1 (hipótesis alterna): Existe diferencia significativa entre las CC obtenidas por PAVEMAI y el MTC, indicando que PAVEMAI no es fiable.

Se realizaron pruebas no paramétricas para evaluar la fiabilidad del método mediante visión artificial frente al método del MTC, con un nivel de significancia de $\alpha = 0.05$ (5%). La Tabla 42 presenta los resultados:

Tabla 42

Resultados de las pruebas estadísticas de comparación y correlación

Prueba/Métrica	Valor	Valor p
Shapiro-Wilk	0.6846	0.0001
Prueba de Wilcoxon (W)	18.00	0.0005
Correlación de Spearman (ρ)	0.532	0.0156
Correlación de Kendall (τ)	0.396	0.0149
Coefficiente de Concordancia de Lin (CCC)	0.21	-
Coefficiente de Correlación Intraclass (ICC)	0.33	-

- **Prueba de normalidad:** El test de Shapiro-Wilk ($W = 0.6846$, $p = 0.0001$) confirmó que las diferencias no siguen una distribución normal, justificando el uso de métodos no paramétricos.
- **Prueba de Wilcoxon:** El estadístico $W = 18.00$ ($p = 0.0005$) rechazó H_0 , indicando diferencias significativas entre los métodos. El tamaño del efecto ($r = 3.80$) sugiere un efecto grande, con el MTC asignando CC más altas que PAVEMAI.
- **Correlación:** La correlación de Spearman ($\rho = 0.532$, $p = 0.0156$) y Kendall ($\tau = 0.396$, $p = 0.0149$) mostraron una asociación y concordancia moderadas, indicando cierta relación entre los métodos, pero no suficiente para considerarlos equivalentes.
- **Concordancia:** El CCC (0.21) y el ICC (0.33, IC 95%: [-0.06, 0.65]) indican una concordancia pobre, reflejando discrepancias sistemáticas entre PAVEMAI y el MTC.

Las diferencias entre el método mediante visión artificial (PAVEMAI) y el enfoque del MTC se deben principalmente al alcance de detección. PAVEMAI identifica solo 5 tipos de fallas, mientras que el MTC considera 11, permitiendo una evaluación más completa e integral. Además, PAVEMAI presenta limitaciones en la precisión del conteo, pudiendo generar falsos positivos, negativos o duplicar detecciones, lo que afecta la calificación final del estado del pavimento.

Decisión sobre las hipótesis: La prueba de Wilcoxon ($p = 0.0004 < \alpha = 0.05$) rechaza H_0 , indicando que las CC de PAVEMAI y MTC son significativamente diferentes. Además, la pobre concordancia (CCC = 0.21, ICC = 0.33) confirma que PAVEMAI no es equivalente al MTC. Por lo tanto, se acepta H_1 , concluyendo que PAVEMAI no es fiable frente al MTC.

4.1.4. Hipótesis general

hipótesis: La implementación de un método mediante visión artificial es fiable en la evaluación del estado de conservación superficial de pavimentos flexibles, Ayacucho 2024.

La implementación de PAVEMAI se realizó en un tramo representativo de la Ruta PE-26B, caracterizado por baja transitabilidad, condiciones ambientales desafiantes (sombras y polvo), y una variedad de fallas (Figura 53). La adaptabilidad a tramos asfálticos y la automatización son fortalezas, pero la falta de equivalencia con métodos tradicionales indica que requiere mejoras para ser considerado plenamente confiable.

La hipótesis general no se cumple de manera plena. Aunque la implementación de PAVEMAI mediante visión artificial permitió evaluar el estado de conservación superficial de pavimentos flexibles en Ayacucho 2024, los resultados muestran que no es suficientemente confiable en comparación con las metodologías tradicionales del MTC. A pesar de ello, se identificaron resultados alentadores, el análisis de confiabilidad mostró que el 75 % de los tramos evaluados presentó diferencias iguales o menores a 30 puntos en la calificación de condición, lo cual se considera aceptable para fines de diagnóstico superficial. Este porcentaje constituye un respaldo clave al potencial del sistema, ya que refleja que tres de cada cuatro tramos presentan una coincidencia razonable con la evaluación convencional. Además, el 55 % de los tramos mostró una diferencia menor a 10 puntos, lo que representa un nivel de precisión alto en más de la mitad del tramo evaluado. Estos porcentajes respaldan el buen desempeño general del método, aunque con limitaciones que deben ser mejoradas en trabajos futuros. Las métricas de rendimiento (mAP50, precisión, recuperación) y la capacidad de clasificación automática son prometedoras, pero las discrepancias estadísticas y las limitaciones en la detección de ciertas fallas sugieren que el método necesita optimizaciones, como mayor resolución de imágenes, validación exhaustiva y expansión del alcance de fallas detectadas, para garantizar su confiabilidad en este contexto.

Capítulo V: Conclusiones

5.1 Conclusiones

- La implementación del programa PAVEMAI, basado en visión artificial, representa un avance significativo en la automatización del análisis del estado de conservación superficial de pavimentos flexibles. Este enfoque permitió identificar y clasificar fallas de manera automática. Si bien alcanzó un nivel aceptable de confiabilidad operativa, el análisis estadístico evidenció una correspondencia moderada con la metodología del Ministerio de Transportes y Comunicaciones (MTC), lo que indica que el sistema aún no alcanza la fiabilidad necesaria para su aplicación definitiva en la gestión vial.
- Se desarrolló un modelo de visión artificial utilizando la arquitectura YOLOv8n-seg, identificando cinco tipos de fallas en pavimentos flexibles (piel de cocodrilo, fisuras, descascaramiento, baches y parches), con dos niveles de severidad. Tras 80 épocas de entrenamiento, se alcanzó una precisión media de 68.27%.
- El programa PAVEMAI fue desarrollado en Python, bajo una arquitectura Modelo-Vista-Controlador (MVC), integrando algoritmos de inteligencia artificial para el cálculo de la Calificación de Condición (CC) conforme al Manual de Carreteras: Mantenimiento y Conservación Vial (MTC, 2018). Su diseño incluye una interfaz gráfica intuitiva con cuatro módulos (Configuración, Tiempo, Resultados y Resumen).
- La comparación con la metodología del MTC evidenció limitaciones en la cobertura de fallas, ya que PAVEMAI detecta solo cinco tipos frente a los once considerados por el MTC. El análisis estadístico reveló diferencias y correlaciones moderadas, lo que indica una correspondencia parcial entre ambos métodos. A pesar de ello, el sistema alcanzó un nivel aceptable de confiabilidad operativa, lo que demuestra su potencial como herramienta tecnológica para la evaluación superficial, aunque requiere mejoras para ampliar su alcance y precisión en la gestión vial real.

5.2 Recomendaciones

1. **Ampliar el dataset:** Expandir la cantidad y diversidad de imágenes para el entrenamiento, incorporando una amplia gama de fallas en diferentes condiciones ambientales y de iluminación, con especial énfasis en fisuras de diferentes anchos y contrastes, para optimizar la precisión y adaptabilidad del sistema en diversos entornos viales.
2. **Mejorar la calidad de imágenes:** Incrementar la resolución y calidad de las imágenes capturadas, junto con una normalización optimizada para el entrenamiento, para detectar con mayor precisión fallas pequeñas o difusas, como fisuras, mejorando la captura de datos en campo.
3. **Optimizar modelos de visión artificial:** Explorar modelos avanzados y técnicas de ajuste fino para perfeccionar la detección de fallas complejas, asegurando un desempeño más robusto y confiable en condiciones variadas.
4. **Fortalecer la detección de fallas complejas:** Desarrollar métodos avanzados de procesamiento de imágenes, enfocados en fallas variables como fisuras, para mejorar su identificación y clasificación en escenarios reales.
5. **Entrenar en condiciones ambientales diversas:** Incluir imágenes capturadas bajo distintos climas y niveles de iluminación para robustecer el sistema, garantizando un funcionamiento eficaz en entornos viales desafiantes.
6. **Validar frente a métodos tradicionales:** Realizar comparaciones exhaustivas con enfoques convencionales en diversos tramos viales, identificando áreas de mejora para alinear los resultados con estándares establecidos.

5.3 Trabajos futuros

1. **Evaluar en otras regiones:** Aplicar PAVEMAI en distintas zonas del Perú, como la costa, la sierra y la selva, para verificar su desempeño en diferentes condiciones climáticas, tipos de pavimento y niveles de tránsito. Esto permitirá ajustar el sistema y mejorar su precisión en contextos diversos.
2. **Desarrollar monitoreo en tiempo real:** Implementar una plataforma que permita el seguimiento continuo del estado superficial de los pavimentos, detectando fallas de manera inmediata para facilitar un mantenimiento preventivo más eficiente.
3. **Integrar con sistemas de gestión vial:** Conectar PAVEMAI con sistemas del

Ministerio de Transportes y Comunicaciones (MTC) o de gobiernos locales, con el fin de apoyar la planificación del mantenimiento vial y optimizar la toma de decisiones técnicas y presupuestales.

4. **Diseñar una aplicación móvil:** Desarrollar una app para dispositivos móviles que permita capturar imágenes y ejecutar evaluaciones rápidas directamente desde el campo, haciendo que el sistema sea más accesible para personal técnico y operativos.
5. **Analizar viabilidad económica:** Realizar un estudio de costos y beneficios que compare el uso de PAVEMAI con los métodos tradicionales, para determinar su rentabilidad y justificar su implementación a gran escala en proyectos públicos y privados.
6. **Adaptar a metodologías reconocidas:** Ajustar y validar los resultados de PAVEMAI en función de metodologías estándares como el PCI (Pavement Condition Index) y VIZIR, con el objetivo de asegurar compatibilidad con sistemas de evaluación ya existentes y facilitar su aceptación institucional.
7. **Mejorar el rendimiento del modelo:** Explorar el uso de arquitecturas más avanzadas y robustas de inteligencia artificial, tanto en el entrenamiento como en el seguimiento de objetos, con el fin de aumentar la precisión en la detección de deterioros y reducir los errores en condiciones reales de operación.

Referencias bibliográficas

- American Society for Testing and Materials. (2020). *Standard Practice for Roads and Parking Lots Pavement Condition Index Surveys (ASTM D6433-20)*. ASTM International.
- Andriluka, M., Roth, S., & Schiele, B. (2008). People-tracking-by-detection and people-detection-by-tracking. *Proceedings of the 2008 IEEE Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/CVPR.2008.4587583>
- ASTM, A. (2020). D6433-20; Standard Practice for Roads and Parking Lots Pavement Condition Index Surveys. *ASTM International: West Conshohocken, PA, USA*.
- Ataiwe, T. N. (2023). Using Image Processing for Automatic Detection of Pavement Surface Distress. *Al-Salam Journal for Engineering and Technology*, 2(1).
- Aurélien, G. (2022). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media, Inc.
- Autret, P., & Brousse, J.-L. (1992). *VIZIR: Método con ayuda de computador para la estimación de necesidades en el mantenimiento de una red carretera* [Versión española de la edición de octubre de 1992]. Laboratoire Central des Ponts et Chaussées.
- Becerra Salas, M. (2012). *Tópicos de Pavimentos de concreto: Diseño, construcción y supervisión*. Flujo Libre.
- Bewley, A., Ge, Z., ... Upcroft, B. (2016). Simple online and realtime tracking. *2016 IEEE international conference on image processing (ICIP)*.
- Caballero, R. A. (2014). *Metodología integral innovadora para planes y tesis*. CENGAGE Learning.
- Castillo, E. (n.d.). *Construyendo modelos de programación matemática en ingeniería y ciencia* (4a ed.). Departamento de Matemática Aplicada y Ciencias de la Computación Universidad de Cantabria Universidad de Castilla-La Mancha.
- Centeno, F. A. (2019). *Deep Learning*.
- Chávez, C. N. S., & Reyes, V. J. F. (2019). *Implementar un sistema de visión computacional para identificar fallas superficiales en el pavimento flexible haciendo uso del procesamiento digital de imágenes* [Universidad Nacional de Trujillo].
- Condori Quispe, W. (2019). Introduction to Convolutional. *Universidad Nacional de San Agustín*.

- Danelljan, M., Bhat, G., ... Felsberg, M. (2019). Atom: Accurate tracking by overlap maximization. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*.
- Deeksha, A., Hiroya, M., ... Yoshihide, S. (2021, March). *An Image Dataset for Smartphone-based Road Damage Detection and Classification*. RDD2020. Mendeley Data. <https://data.mendeley.com/datasets/5ty2wb6gvg/1>
- Esplana, C. K. M., & Pérez, T. C. (2021). *Influencia de la rigidez del pavimento en la condición superficial del pavimento utilizando técnicas de inteligencia artificial en la vía nacional PE-26B* [Universidad Nacional de Huancavelica].
- Everingham, M., Van Gool, L., ... Zisserman, A. (2010). The Pascal Visual Object Classes (VOC) challenge. *International Journal of Computer Vision*, 88.
- Fang, Q., Li, H., ... An, W. (2018). Detecting non-hardhat-use by a deep learning method from far-field surveillance videos. *Automation in construction*, 85.
- Gamboa, K. P. (2019). *Cálculo del Índice de Condición aplicado en el Pavimento Flexible en la Av. Las Palmeras de Piura* [Tesis de pregrado, Universidad de Piura].
- Garcés, V. D. P. (2017). Evaluación vial y plan de rehabilitación y mantenimiento de la vía azogues-cojitambo-deleg-la raya.
- Ghrib, F., Lger, P., ... Veilleux, M. (1998). A progressive methodology for seismic safety evaluation of gravity dams: from preliminary screening to non-linear finite element analysis A progressive methodology for seismic safety evaluation of gravity dams: from preliminary screening to non-linear finite element analysis. *The International Journal of Hydropower and Dams*.
- González, A., Martínez, F., ... Vergara, E. (2006). *Técnicas y algoritmos básicos de visión artificial*. Universidad de La Rioja.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. The MIT Press.
- Guerrieri, M., & Parla, G. (2022). Flexible and stone pavements distress detection and measurement by deep learning and low-cost detection devices. *Engineering Failure Analysis*, 141. <https://doi.org/https://doi.org/10.1016/j.engfailanal.2022.106714>
- He, K., Gkioxari, G., ... Girshick, R. (2017). Mask r-cnn. *Proceedings of the IEEE international conference on computer vision*.
- Hernández, R., Fernández, C., & Baptista, P. (2014). *Metodología de la investigación* (6th ed.). McGraw-Hill Education.
- Hernández, S. R., Fernández, C. C., & Baptista, L. M. d. P. (2014). *Metodología de la investigación* (Quinta edición). Interamericana editores S.A.

- Huang, Y. H. (2004). *Pavement analysis and design* (2da edition). Prentice–Hall.
- INVIAS. (2006). *Estudio y investigación del estado actual de las obras de la red nacional de carreteras*. <https://www.invias.gov.co/index.php/archivo-ydocumentos/documentos-tecnicos/manuales-de-inspeccion-de-obras/974-manualpara-la-inspeccion-visual-de-pavimentos-flexibles/file>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Fundamentals*.
- Khan, S., Rahmani, H., ... Bennamoun, M. (2018). *A Guide to Convolutional Neural Networks for Computer Vision*. Synthesis Lectures on Computer Vision. <https://doi.org/10.2200/S00822ED1V01Y201712COV015>
- Kheradmandi, N., & Mehranfar, V. (2022). A critical review and comparative study on image segmentation-based techniques for pavement crack detection. *Construction and Building Materials*, 321.
- Kirillov, A., He, K., ... Dollár, P. (2019). Panoptic segmentation. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*.
- Kotsiantis, S. B., Zaharakis, I. D., & Pintelas, P. E. (2006). *Machine learning: a review of classification and combining techniques*. *Artif. Intell. Rev.*
- Kristan, M., Matas, J., ... Berg, A., et al. (2019). The seventh visual object tracking VOT2019 challenge results. *Proceedings of the IEEE/CVF international conference on computer vision workshops*.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553).
- Leguía, P., & Pacheco, H. (2016). *Evaluación superficial del pavimento flexible por el método Pavement Condition Index (PCI) en las vías arteriales: Cincuentenario, Colón y Miguel Grau (Huacho-Huaura-Lima)*. Lima [Universidad San Martín de Porres].
- Li, B., Wu, W., ... Yan, J. (2019). Siamrpn++: Evolution of siamese visual tracking with very deep networks. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*.
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Luo, W., Xing, J., ... Kim, T.-K. (2022). Multiple Object Tracking: A Literature Review. <https://arxiv.org/pdf/1409.7618.pdf>
- Marsland, S. (2009). *Machine Learning: An Algorithmic Perspective* (1st ed.). Chapman; Hall/CRC. <https://doi.org/10.1201/9781420067194>

- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*.
- Menéndez, J. R. (2003). Manual Técnico. *Mantenimiento Rutinario de Caminos con Microempresas, Lima*.
- Milan, A., Leal-Taixé, L., ... Schindler, K. (2016). MOT16: A benchmark for multi-object tracking. *arXiv preprint arXiv:1603.00831*.
- Ministerio de Economía y Finanzas. (2015). *Pautas metodológicas para el desarrollo de alternativas de pavimentos en la formulación y evaluación social de proyectos de inversión pública de carreteras* (Primera edición). Dirección General de Inversión Pública-DGIP.
- Ministerio de Transportes y Comunicaciones. (2013). *Manual de carreteras "Suelos, geología, geotecnia y pavimentos", sección: suelos y pavimentos*.
- Ministerio de Transportes y Comunicaciones. (2023). *Política Nacional Multisectorial de Seguridad Vial 2023 – 2030*. <https://doi.org/https://www.gob.pe/institucion/mtc/informes-publicaciones/4463063-politica-nacional-multisectorial-de-seguridad-vial-2023-2030>
- Ministerio de Transportes y Comunicaciones. (2024). *Boletín anual 2024*. Dirección de Seguridad Vial.
- Ministerio de Transportes y Comunicaciones del Perú. (2018). *Manual de carreteras: Mantenimiento o conservación vial* [R.D. N.º 08-2014-MTC/14, Incorporación de Parte IV, R.D. N.º 05-2016-MTC/14]. Ministerio de Transportes y Comunicaciones, Dirección General de Caminos y Ferrocarriles.
- Morales, P., Chávez, O., & López, L. (2009). *Efectos de la alta compactación de la capa de base en pavimentos flexibles*. Universidad nacional de ingeniería, Facultad de la Tecnología de la Contrucción.
- Nandal, A., Zhou, L., ... Nait-Abdesselam, F. (2023). *Machine Learning in medical imaging and computer vision*. The Institution of Engineering; Technology.
- Papagiannakis, A. T., & Masad, E. A. (2024). *Pavement design and materials*. John Wiley & Sons.
- Patel, S., & Pingel, J. (2019). Introduction to deep learning: What are convolutional neural networks.
- Paytán, J. (2018). *Estimación del índice de regularidad internacional en pavimentos flexibles usando redes neuronales artificiales* [Universidad Nacional de Huancavelica].

- Pouyanfar, S., Sadiq, S., ... Iyengar, S. S. (2018). A Survey on Deep Learning: Algorithms, Techniques, and Applications. *ACM Computing Surveys (CSUR)*. <https://doi.org/10.1145/3234150>
- Redmon, J., & A, F. (2017). Yolo9000: Better, faster, stronger. *In Computer Vision and Pattern Recognition (CVPR)*, 88.
- Redmon, J., Divvala, S., ... Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. <https://arxiv.org/abs/1506.02640>
- Reyes, O. O., Mejia, M., & Useche, C. J. (2019). Técnicas de inteligencia artificial utilizadas en el procesamiento de imágenes y su aplicación en el análisis de pavimentos. *Revista EIA*, 16(31).
- Romer, P., & Yanina, S. (2016). Evaluación y comparación de metodologías índice de condición de pavimentos (PCI) y visión e inspección de zonas e itinerarios en riesgo (VIZIR) en la avenida Mariscal Castilla.
- Sánchez, R. J. (2017). *Evaluación del estado del pavimento de la Av. Ramón Castilla, Chulucanas, mediante el método PCI*.
- Setyawana, A., Nainggolanb, J., & Budiarto, A. (2015). Predicting the remaining service life of road using pavement condition index. *Procedia engineering*. <https://doi.org/10.1016/j.proeng.2015.11.108>
- Shah, T. (2018). *Measuring Object Detection models mAP - What is Mean Average Precision?* [Recuperado el 25 de agosto de 2021]. <https://tarangshah.com/blog/2018-01-27/what-is-map-understanding-the-statistic-of-choice-for-comparing-object-detection-models/>
- Shahnazari, H., Tutunchian, M., ... Amini, A. (2012). Application of soft computing for prediction of pavement condition index. *Journal of transportation engineering*. [https://doi.org/10.1061/\(ASCE\)TE](https://doi.org/10.1061/(ASCE)TE)
- Solminihac, H. d., & Chamorro, A. (2001). Gestión de infraestructura vial.
- Stauffer, C., & Grimson, W. E. L. (1999). Adaptive background mixture models for real-time tracking. *Proceedings of the 1999 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2. <https://doi.org/10.1109/CVPR.1999.784637>
- Sucar, L. E., & Gómez, G. (2011). Visión computacional. *Instituto Nacional de Astrofísica, Óptica y Electrónica. México*.
- Supo, J., & Zacarías, H. (2020). Metodología de la investigación científica. *Lima, Perú: Sociedad Hispana de Investigadores Científicos*.
- Szeliski, R. (2022). *Computer vision: algorithms and applications*. Springer Nature.

- Tello, C. L., Aguirre, S. M., ... Hernández, F. (2021). Evaluación de daños en pavimento usando fotogrametría terrestre y neuronales. *Revista EIA*, 16(31).
- Torres, J. (2018). *Deep Learning: Introducción práctica con Keras*. WATCH THIS SPACE.
- Valdivia, G. J. L. (2023). *Análisis comparativo de los métodos PCI, VIZIR y MTC en la evaluación del pavimento flexible de la Av. B del distrito de Comas en 2023*.
- Valladares, S. J. (2018). *Determinación del Deterioro del Pavimento Flexible de la Avenida Nicolás de Piérola Del Distrito de Casma*.
- Vásquez, V. L. (2002). Pavement condition index (PCI). *Para pavimentos asfálticos y de concreto en carreteras. Ingeniería de pavimentos (ingepav)(digital)*, Manizales, Universidad Nacional de Colombia.
- Yilmaz, A., Javed, O., & Shah, M. (2006). Object tracking: A survey. *ACM Computing Surveys (CSUR)*, 38.
- Zakeri, H., Nejad, F. M., & Fahimifar, A. (2017). Image based techniques for crack detection, classification and quantification in asphalt pavement: a review. *Archives of Computational Methods in Engineering*, 24.
- Zhang, Y., & Ling, C. (2018). A strategy to apply machine learning to small datasets in materials science. *npj Computational Materials*. <https://doi.org/10.1038/s41524-018-0081-z>
- Zhao, Z.-Q., Zheng, P., ... Wu, X. (2019). Object detection with deep learning: A review. *IEEE transactions on neural networks and learning systems*, 30.
- Zheng, L., Xiao, J., ... Jiang, W. (2024). Deep learning-based intelligent detection of pavement distress. *Automation in Construction*, 168.
- Zhou, X., Wang, D., & Krähenbühl, P. (2019). Objects as points. *arXiv preprint arXiv:1904.07850*.

Glosario de términos

Término	Descripción
Ahuellamiento	Deformación longitudinal en la calzada, formando un canal en las zonas de mayor tránsito de vehículos, producto de la acumulación de deformaciones permanentes en las capas del pavimento.
Aprendizaje automático	Rama de la inteligencia artificial enfocada en el desarrollo de técnicas que permiten a las computadoras aprender a partir de datos sin ser explícitamente programadas.
Aprendizaje evolutivo	Enfoque de aprendizaje automático inspirado en el proceso de evolución biológica, donde los modelos se adaptan para mejorar su rendimiento basándose en medidas de aptitud.
Aprendizaje no supervisado	Técnica de aprendizaje automático donde no se proporcionan salidas predefinidas y el objetivo es identificar patrones o similitudes entre los datos de entrada.
Aprendizaje por refuerzo	Tipo de aprendizaje automático donde el algoritmo recibe notificaciones cuando la respuesta es incorrecta, debiendo explorar diferentes alternativas hasta aprender a obtener la respuesta correcta.
Aprendizaje profundo (Deep Learning)	Subconjunto del aprendizaje automático basado en redes neuronales artificiales con múltiples capas que permiten aprender representaciones de datos con múltiples niveles de abstracción.
Aprendizaje supervisado	Técnica de aprendizaje automático donde se proporciona un conjunto de ejemplos con las salidas correctas, permitiendo al algoritmo aprender a generalizar para responder correctamente a nuevas entradas.
Área de sección evaluada	Superficie total inspeccionada en un segmento de carretera, generalmente medida en metros cuadrados, considerando el ancho del carril más la berma contigua.

Baches	Deterioros o huecos en la superficie del pavimento que resultan del desgaste o daño progresivo en la capa de rodadura, generalmente de forma redondeada y con bordes bien definidos.
Berma	Franja longitudinal pavimentada o no, comprendida entre el borde exterior de la calzada y la cuneta o talud, que sirve como zona de seguridad para estacionamiento de vehículos en emergencia.
Calificación de condición del pavimento (CC)	Sistema de puntuación utilizado para evaluar el estado general de un pavimento basado en la presencia, severidad y extensión de varios tipos de fallas. En el método MTC, se calcula como 1000 menos la suma de los puntos de condición (PC).
Carreteras departamentales	Vías que unen las capitales de departamento con las capitales de provincia o estas entre sí, formando una red dentro del sistema nacional de carreteras.
Capa convolucional	Componente fundamental en las redes neuronales convolucionales donde se aplican filtros para extraer características de los datos de entrada, realizando operaciones matemáticas específicas.
Capa de pooling	Capa en una red neuronal convolucional que reduce la dimensionalidad espacial de la representación, disminuyendo el costo computacional sin perder información relevante.
Capa totalmente conectada	Capa final en una red neuronal convolucional donde cada neurona se conecta con todas las activaciones de la capa anterior, transformando las características extraídas en predicciones específicas.
Coefficiente de Concordancia de Lin (CCC)	Medida estadística que evalúa el grado de acuerdo entre dos métodos de medición, combinando precisión y exactitud.
Coefficiente de Correlación Intraclase (ICC)	Índice estadístico que evalúa la concordancia entre diferentes mediciones de una misma variable, utilizado para valorar la fiabilidad de las mediciones.
Convolución	Operación matemática que consiste en aplicar un filtro o kernel sobre una matriz de entrada para resaltar ciertas características, fundamental en el procesamiento de imágenes y visión artificial.

Conservación rutinaria	Mantenimiento regular y continuo que se realiza para preservar las condiciones de una vía en buen estado, incluyendo limpieza, desbroce y reparaciones menores.
Conservación vial	Conjunto de actividades técnicas destinadas a preservar en buen estado las condiciones físicas de los diferentes elementos que constituyen la vía.
Daños puntuales en berma	Deterioros localizados en la franja adyacente a la calzada, que incluyen deformaciones, desprendimientos o hundimientos que afectan la integridad estructural de la berma.
Deep Learning	Campo del aprendizaje automático que utiliza redes neuronales con múltiples capas (redes neuronales profundas) para modelar abstracciones de alto nivel en los datos.
Descascaramiento	Tipo de deterioro en el pavimento asfáltico que involucra la pérdida superficial de material debido a la desintegración de la capa asfáltica, ya sea por el desprendimiento del ligante bituminoso o de los agregados.
Desnivel calzada-berma	Diferencia de elevación entre el borde del pavimento y la berma, que puede generar riesgos de seguridad y problemas de drenaje superficial.
Deterioro vial	Proceso de degradación y pérdida de las propiedades físicas y funcionales de un pavimento debido al uso, envejecimiento y factores ambientales.
Detección de objetos	Técnica de visión artificial que permite identificar y ubicar objetos específicos dentro de imágenes o videos, trazando cuadros delimitadores alrededor de ellos.
Estado de conservación superficial	Condición física visible de la superficie de un pavimento que indica su nivel de deterioro y necesidad de mantenimiento.
Etiquetado de imágenes	Proceso de marcar o anotar manualmente las áreas de interés en imágenes para entrenar modelos de aprendizaje automático, identificando y clasificando objetos para su posterior reconocimiento.

Evaluación de pavimentos	Proceso mediante el cual se determina el estado físico y funcional de un pavimento para establecer acciones de mantenimiento o rehabilitación.
Extensión de Fenómeno Patológico (EFP)	Medida que cuantifica el porcentaje del área total del pavimento afectada por un tipo específico de falla.
Fallas en pavimentos flexibles	Deterioros o daños que se presentan en la superficie de rodadura de un pavimento asfáltico, como fisuras, deformaciones, desprendimientos y baches.
Falso negativo	En detección de objetos, ocurre cuando el sistema no detecta un objeto que existe realmente en la imagen.
Falso positivo	En detección de objetos, ocurre cuando el sistema detecta un objeto que no existe realmente en la imagen o clasifica incorrectamente un objeto existente.
Filtro (kernel)	Matriz numérica utilizada en la operación de convolución para extraer características específicas de una imagen, como bordes, texturas o patrones.
Fisuras	Grietas en el pavimento que pueden ser longitudinales (paralelas al eje de la carretera) o transversales (perpendiculares al eje) y que indican problemas en la capa asfáltica.
Fotogramas	Imágenes individuales capturadas de una secuencia de video o fotografías que representan un instante específico.
Función de activación	Componente en redes neuronales que determina si una neurona debe activarse, introduciendo no linealidad al sistema. Ejemplos comunes incluyen ReLU, sigmoid y tanh.
Índice de Condición del Pavimento (PCI)	Metodología estandarizada para evaluar y calificar objetivamente la condición de pavimentos flexibles y rígidos, con valores entre 0 (fallado) y 100 (excelente).
Inteligencia artificial	Capacidad de las máquinas para realizar tareas que normalmente requieren inteligencia humana, como percepción visual, reconocimiento de voz y toma de decisiones.
Intersección sobre la unión (IoU)	Métrica utilizada en detección de objetos para medir el grado de superposición entre dos cuadros delimitadores, calculada como el área de intersección dividida por el área de unión.

Mantenimiento correctivo	Intervenciones realizadas después de que se ha producido un deterioro o falla para restablecer las condiciones originales del pavimento.
Mantenimiento preventivo	Conjunto de actividades programadas antes de que ocurra un deterioro significativo, con el objetivo de preservar las condiciones de servicio del pavimento.
Matriz de confusión	Tabla utilizada en aprendizaje automático que muestra el desempeño de un modelo de clasificación, comparando las predicciones con los valores reales y mostrando verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos.
Mean Average Precision (mAP)	Métrica utilizada para evaluar el rendimiento de modelos de detección de objetos, calculada como el promedio de precisiones para diferentes umbrales de IoU.
Método tradicional de evaluación	Procedimientos convencionales basados en inspección visual manual y recopilación de datos en campo para evaluar la condición del pavimento.
Modelo RGB	Sistema de representación del color basado en la combinación de los tres colores primarios: rojo (R), verde (G) y azul (B).
Modelo HSI	Sistema de representación del color que codifica la información mediante tres componentes: tono (H), saturación (S) e intensidad (I), aproximándose mejor a la percepción humana del color.
Modelo-Vista-Controlador (MVC)	Patrón de diseño de software que separa la lógica de la aplicación (modelo), la interfaz de usuario (vista) y la lógica de control (controlador) en componentes distintos, facilitando el mantenimiento y la escalabilidad.
Padding	Técnica utilizada en redes neuronales convolucionales que consiste en agregar valores (generalmente ceros) alrededor de la matriz de entrada para preservar las dimensiones espaciales durante la operación de convolución.
Parches	Reparaciones realizadas en el pavimento, donde se ha retirado y sustituido material para restaurar su funcionalidad. Pueden ser un indicativo de problemas subyacentes.

PAVEMAI	Programa de software desarrollado para la evaluación automatizada del estado de conservación de pavimentos flexibles mediante técnicas de visión artificial e inteligencia artificial.
Pavimento flexible	Estructura de pavimento compuesta principalmente por capas de material asfáltico y materiales granulares, que se caracteriza por su capacidad de deflexión al paso de las cargas.
Peladura y desprendimiento	Deterioro del pavimento caracterizado por la pérdida del material superficial de la capa asfáltica, ya sea por desprendimiento del ligante bituminoso o de los agregados.
Persistencia temporal	Concepto utilizado en procesamiento de video que valida la consistencia de un objeto detectado a lo largo de múltiples fotogramas consecutivos, reduciendo falsos positivos.
Piel de cocodrilo	Tipo de falla en pavimentos flexibles caracterizada por fisuras interconectadas que forman polígonos irregulares similares a la piel de un cocodrilo, indicando fatiga del pavimento.
Precisión	Métrica de evaluación en sistemas de detección de objetos que mide la proporción de detecciones correctas respecto al total de detecciones realizadas por el sistema.
Precisión media (mAP)	Métrica utilizada para evaluar el rendimiento global de sistemas de detección de objetos, basada en el cálculo del área bajo la curva precisión-recall.
Prueba de Shapiro-Wilk	Test estadístico utilizado para evaluar la normalidad de una distribución de datos, verificando si una muestra proviene de una población normalmente distribuida.
Prueba de Wilcoxon	Prueba estadística no paramétrica utilizada para comparar muestras pareadas o relacionadas, determinando si existen diferencias significativas entre ellas.
Procesamiento de imágenes	Técnicas utilizadas para manipular y analizar imágenes digitales con el fin de extraer información útil.
Progresiva	Punto de referencia kilométrico específico a lo largo de una carretera que indica la distancia desde un punto de origen.

Puntaje de Condición (PC)	Valor numérico asignado a cada tipo de falla en el pavimento según su extensión y severidad, utilizado para calcular la Calificación de Condición (CC).
Recall (Sensibilidad)	Métrica de evaluación en sistemas de detección de objetos que mide la proporción de objetos reales correctamente identificados por el sistema.
Reconstrucción/ Rehabilitación	Intervención mayor en un pavimento deteriorado para restablecer su capacidad estructural, funcionalidad y nivel de servicio original.
Red neuronal convolucional (CNN)	Arquitectura de red neuronal especializada en procesamiento de datos con estructura de cuadrícula (como imágenes), caracterizada por el uso de operaciones de convolución para extraer características.
ReLU (Rectified Linear Unit)	Función de activación definida como $f(x) = \max(0, x)$, que introduce no linealidad en redes neuronales, activando solo neuronas con entradas positivas.
Ruta Nacional	Vía que forma parte del Sistema Nacional de Carreteras (SINAC) y conecta las principales ciudades del país, puertos y fronteras.
Segmentación de imágenes	Proceso de dividir una imagen en regiones significativas, asignando cada píxel a una categoría específica para facilitar el análisis y la interpretación.
Seguridad vial	Conjunto de acciones y mecanismos que garantizan el buen funcionamiento de la circulación del tránsito, mediante la prevención de accidentes en las vías.
Seguimiento de objetos (Object Tracking)	Técnica de visión artificial que permite monitorear la posición y movimiento de objetos a lo largo de una secuencia de video.
Siniestros viales	Eventos que producen daños a personas o bienes involucrados en la circulación en las vías y que tiene su origen en un hecho de tránsito.
Softmax	Función de activación utilizada en la capa final de redes neuronales para clasificación multiclase, que transforma valores numéricos en una distribución de probabilidades.
Stride	Parámetro que define el desplazamiento del filtro durante la operación de convolución en redes neuronales convolucionales.

Verdadero negativo	En detección de objetos, ocurre cuando el sistema correctamente no detecta un objeto que no existe en la imagen.
Verdadero positivo	En detección de objetos, ocurre cuando el sistema detecta correctamente un objeto que existe realmente en la imagen y lo clasifica adecuadamente.
Vida útil de pavimentos	Período durante el cual el pavimento mantiene un nivel de servicio adecuado antes de requerir una rehabilitación mayor o reconstrucción.
VIZIR	Metodología francesa para la evaluación de pavimentos flexibles que clasifica los daños en dos categorías (A y B) según afecten la estructura o solo la funcionalidad.
Visión artificial	Campo de la inteligencia artificial que entrena a las computadoras para interpretar y comprender el mundo visual mediante el análisis y procesamiento de imágenes o videos.
YOLO (You Only Look Once)	Arquitectura de red neuronal para detección de objetos en tiempo real que procesa la imagen completa en una sola pasada, prediciendo simultáneamente cuadros delimitadores y probabilidades de clase.
YOLOv8	Versión avanzada del modelo YOLO que combina precisión y velocidad, introduciendo optimizaciones en su arquitectura de tres componentes: backbone (CSPDarknet), neck (PANet) y head (cabeza dual para detección y segmentación).
YOLOv8n-seg	Versión nano de YOLOv8 con capacidades de segmentación, optimizada para ofrecer un equilibrio entre precisión y velocidad en dispositivos con recursos limitados.

Lista de acrónimos

Acrónimo	Descripción
BCH	Baches
BoT-SORT	Byte-track and Strong-Sort (Algoritmo de seguimiento de objetos)
CC	Calificación de Condición
CCC	Coefficiente de Concordancia de Lin
CNN	Red Neuronal Convolucional (Convolutional Neural Network)
CSPDarknet	Cross Stage Partial Darknet (Backbone utilizado en YOLOv8)
CV	Visión por Computadora (Computer Vision)
DC	Descascaramiento
DL	Aprendizaje Profundo (Deep Learning)
EF	Extensión de Falla
EFP	Extensión del Fenómeno Patológico
FN	Falso Negativo (False Negative)
FP	Falso Positivo (False Positive)
FS	Fisuras
GPS	Sistema de Posicionamiento Global (Global Positioning System)
HSI	Tono, Saturación, Intensidad (Hue, Saturation, Intensity)
IA	Inteligencia Artificial
ICC	Coefficiente de Correlación Intraclase
If	Índice de Fisuración (metodología VIZIR)
Id	Índice de Deformación (metodología VIZIR)
IoU	Intersección sobre la Unión (Intersection over Union)
IP	Procesamiento de Imágenes (Image Processing)
IS	Índice de Deterioro Superficial (metodología VIZIR)
LCPC	Laboratorio Central de Puentes y Carreteras de Francia (Laboratoire Central des Ponts et Chaussées)
mAP	Precisión Media (mean Average Precision)

mAP50	Precisión Media con umbral IoU de 0.5
mAP50-95	Precisión Media promediada sobre umbrales de IoU de 0.5 a 0.95
ML	Aprendizaje Automático (Machine Learning)
MOT	Seguimiento de Múltiples Objetos (Multiple Object Tracking)
MTC	Ministerio de Transportes y Comunicaciones
MVC	Modelo-Vista-Controlador
NMS	Supresión de No Máximos (Non-Maximum Suppression)
PANet	Red de Agregación de Caminos
PAVEMAI	Programa de Asistencia en la Verificación y Evaluación del Mantenimiento de Infraestructura vial con Inteligencia Artificial
PC	Piel de Cocodrilo o Puntaje de Condición
PCH	Parches
PCI	Índice de Condición del Pavimento (Pavement Condition Index)
PE-26B	Código de identificación de la Ruta Nacional Peruana analizada
PE-28A	Código de identificación de la Ruta Nacional Peruana Los Libertadores
PE-28B	Código de identificación de la Ruta Nacional Peruana hacia Cusco
PE-3S	Código de identificación de la Ruta Nacional Peruana hacia Junín
PEF	Porcentaje de Extensión de Falla
PIL	Biblioteca de Procesamiento de Imágenes de Python
R-CNN	Regiones con características CNN (Regions with CNN features)
ReLU	Unidad Lineal Rectificada (Rectified Linear Unit)

Lista de símbolos

Símbolo	Descripción
I	Matriz bidimensional o tridimensional que representa una imagen digital
K	Filtro utilizado para extraer características de una imagen
S	Matriz resultante de una operación de convolución
p	Cantidad de ceros añadidos alrededor de una imagen
s	Número de píxeles que el kernel se desplaza en cada paso
f	Dimensión del filtro usado en la convolución
n	Tamaño de la matriz de entrada en una convolución
σ	Función matemática que introduce no linealidad en redes neuronales
α	Umbral usado en pruebas estadísticas para determinar significancia (normalmente 0.05)
H_0	Suposición de que no hay diferencia significativa entre variables o grupos estudiados
H_1	Suposición de que existe una diferencia significativa entre variables o grupos estudiados
ρ	Coefficiente que mide la asociación monótonica entre variables (Spearman)
τ	Coefficiente que mide la concordancia entre rankings de variables (Kendall)
p	Probabilidad de obtener resultados tan extremos como los observados, bajo H_0
r	Medida de la magnitud de un efecto observado, independiente del tamaño muestral
W	Estadístico usado en la prueba de rangos con signo de Wilcoxon para muestras pareadas
$lr / pg0$	Parámetro que controla los ajustes en los pesos del modelo durante el entrenamiento

L_{box}	Función de pérdida que mide la precisión de las coordenadas de las cajas delimitadoras
L_{seg}	Función de pérdida que evalúa la exactitud de la segmentación de objetos
L_{cls}	Función de pérdida que mide la exactitud en la clasificación de clases de objetos
L_{DFL}	Función de pérdida especializada que optimiza la confianza de las predicciones
%	Representa una proporción por cada cien unidades
Km	Unidad de longitud equivalente a mil metros
K+MMM	Formato para indicar distancias en carreteras (K=kilómetro, MMM=metros)
m	Unidad básica de longitud en el Sistema Internacional
m ²	Unidad de área en el Sistema Internacional
px	Unidad mínima de una imagen digital

Convenciones tipográficas

En el presente documento se utilizan las siguientes convenciones tipográficas:

Estilo	Uso
Monoespaciado	Se utiliza para representar código fuente, comandos, variables, funciones, nombres de archivos y otros elementos relacionados con la programación, siguiendo las convenciones académicas establecidas en ciencias de la computación e ingeniería de software. Esta distinción tipográfica permite identificar rápidamente referencias a elementos técnicos y mejora la legibilidad del documento.
<i>Cursiva</i>	Se utiliza para términos técnicos específicos cuando se introducen por primera vez, títulos de libros y revistas, nombres científicos de especies, letras utilizadas como símbolos estadísticos o variables, y para palabras de otros idiomas, conforme a lo establecido por la normativa APA.
Negrita	Se utiliza para encabezados, títulos y para resaltar información particularmente relevante dentro del texto.

ANEXOS

- **ANEXO A:** Matriz de consistencia
- **ANEXO B:** Panel fotográfico
- **ANEXO C:** Manual de usuario del programa PAVEMAI
- **ANEXO D:** Cálculo de condición mediante la metodología del MTC
- **ANEXO E:** Cálculo de condición mediante la metodología basada en visión artificial (PAVEMAI)

Anexo A: Matriz de consistencia

Implementación de un método mediante visión artificial para la evaluación del estado de conservación superficial de pavimentos flexibles, Ayacucho 2024

PROBLEMA	OBJETIVO	HIPOTESIS	VARIABLES	METODOLOGÍA	POBLACIÓN Y MUESTRA
¿De qué manera se implementa un método mediante visión artificial para la evaluación del estado de conservación superficial del pavimento flexible, Ayacucho 2024?	Implementar un método mediante visión artificial para evaluar el estado de conservación superficial de pavimentos flexibles, Ayacucho 2024.	La implementación de un método mediante visión artificial es fiable en la evaluación del estado de conservación superficial de pavimentos flexibles, Ayacucho 2024.	<p>Calibración</p> <p>Método mediante visión artificial</p> <p>Dimensiones</p> <ul style="list-style-type: none"> ▪ Parámetros de entrenamiento ▪ Precisión de detección y segmentación ▪ Adaptabilidad a normativas ▪ Fiabilidad <p>Evaluativa</p> <p>Estado de conservación superficial del pavimento.</p> <p>Dimensiones</p> <ul style="list-style-type: none"> ▪ Tipos de falla ▪ Nivel de severidad de fallas ▪ Calificación de condición del pavimento 	<p>Método: Deductivo</p> <p>Orientación de investigación: Aplicada.</p> <p>Enfoque: Cuantitativo</p> <p>Nivel: Aplicativo</p> <p>Diseño:</p> <p>Según propósito: Cuasiexperimental.</p> <p>Según N° mediciones: transversal</p> <p>Según cronología observaciones: Prospectivo</p>	<p>Población: constituida por 20000 imágenes digitales de pavimentos flexibles que presentan fallas superficiales, capturadas en las principales carreteras nacionales de Ayacucho (Rutas PE-28A, PE-26B, PE-3S y PE-28B)</p> <p>Muestra: Constituido por 3.020 imágenes (853x480 píxeles), seleccionadas mediante un muestreo no probabilístico e intencional.</p> <p>Técnicas e instrumentos de recolección de datos:</p> <p>Técnica:</p> <ul style="list-style-type: none"> ▪ Observación directa ▪ Procesamiento digital de imágenes ▪ Análisis automatizado <p>Instrumento:</p> <ul style="list-style-type: none"> ▪ Guía de observación ▪ Lenguaje de programación Python ▪ Software LabelMe
Problemas Específicos:	Objetivos Específicos:	Hipótesis Específicas:			
<p>1. ¿De qué manera se desarrolla un modelo de visión artificial que permita identificar y clasificar de forma automatizada diferentes tipos de fallas en pavimentos flexibles?</p> <p>2. ¿De qué manera se desarrolla un programa mediante algoritmos de inteligencia artificial para calcular la calificación de condición del pavimento flexible?</p> <p>3. ¿De qué manera se determina la fiabilidad de la metodología mediante visión artificial desarrollada para evaluar el estado de conservación superficial de pavimentos flexibles, en comparación con los métodos tradicionales?</p>	<p>1. Desarrollar un modelo de visión artificial que permita identificar y clasificar de forma automatizada diferentes tipos de fallas en pavimentos flexibles.</p> <p>2. Desarrollar un programa mediante algoritmos de inteligencia artificial para calcular la calificación de condición del pavimento flexible.</p> <p>3. Determinar la fiabilidad de la metodología implementada mediante visión artificial para evaluar el estado de conservación superficial de pavimentos flexibles, en comparación con las metodologías tradicionales.</p>	<p>1.El desarrollo de un modelo de visión artificial permite una identificación y clasificación de forma automática diferentes tipos de falla en pavimentos flexibles.</p> <p>2. El desarrollo de un programa mediante algoritmos de inteligencia artificial permite determinar la calificación de condición del pavimento flexible.</p> <p>3. La metodología implementada mediante un modelo de visión artificial es fiable para la evaluación del estado de conservación de pavimentos flexibles en comparación con las metodologías tradicionales.</p>			

Anexo B: Panel fotográfico

Figura 61

Soporte prototípico instalado en vehículo para adquisición de imágenes del estado de la vía



Figura 62

Recolección de imágenes de la carretera PE-28A (vía Libertadores)



Figura 63

Marcado de progresivas en calzada de carretera para el control de intervalos de tiempo



Nota. La actividad se realizó con el objetivo de controlar los tiempos de recorrido en los tramos de estudio, a fin de ingresar estos datos al programa PAVEMAI para la evaluación del estado del pavimento.

Figura 64

Deterioro severo de la plataforma vial por formación de baches.



Anexo C: Manual de usuario del programa PAVEMAI

Sistema de evaluación de pavimentos flexibles



INTRODUCCIÓN

PAVEMAI es un programa especializado para la evaluación automatizada de pavimentos flexibles mediante análisis de video. Utiliza inteligencia artificial y el modelo YOLO para detectar diversos tipos de fallos en el pavimento, calcular su extensión y determinar la calificación de condición del pavimento evaluado.

El software permite dividir el análisis en intervalos, gestionar progresivas y exportar informes detallados con estadísticas y clasificación del pavimento según su estado.

CARACTERÍSTICAS PRINCIPALES

- **Análisis por carril:** El software está diseñado para analizar un carril a la vez mediante un delimitador ajustable en la interfaz
- **Evaluación por tramos:** PAVEMAI evalúa el pavimento típicamente cada 1 km, permitiendo el análisis de vías extensas
- **Sincronización con progresivas:** El sistema relaciona los tiempos del video con las progresivas reales de la carretera
- **Detección automática de fallos:** Identifica y clasifica múltiples tipos de deterioros en el pavimento

REQUISITOS DEL SISTEMA

- **Sistema operativo:** Windows 10 o superior
- **Memoria RAM:** Mínimo 8GB, recomendado 16GB
- **Procesador:** Intel Core i5 o superior
- **Tarjeta gráfica:** Se recomienda NVIDIA para un mejor rendimiento
- **Espacio en disco:** Mínimo 2GB libres

- **Software adicional:** Python 3.8 o superior, con las siguientes librerías:
 - OpenCV
 - Tkinter
 - PIL
 - NumPy
 - Pandas
 - Ultralytics (YOLO)

INSTALACIÓN

1. Asegúrese de tener instalado Python 3.8 o superior.
2. Instale las dependencias necesarias ejecutando en línea de comandos:


```
pip install opencv-python pillow numpy pandas ultralytics
```
3. Descargue el archivo del modelo `best.pt` y colóquelo en la misma carpeta que el programa principal.
4. Ejecute el programa principal `pavemai.py` o el ejecutable `PAVEMAI.exe` si dispone de la versión compilada.

```

1  import tkinter as tk
2  from tkinter import ttk, filedialog, messagebox
3  from PIL import Image, ImageTk
4  import cv2
5  import os
6  import json
7  import logging
8  import threading
9  import queue
10 import numpy as np
11 from collections import defaultdict
12 import pandas as pd
13 from datetime import datetime, timedelta
14 from concurrent.futures import ThreadPoolExecutor
15 import time
16
17 # Configuración de logging
18 logging.basicConfig(
19     level=logging.INFO,
20     format='%(asctime)s - %(name)s - %(levelname)s - %(message)s',
21     filename='pavemai.log'
22 )
23 logger = logging.getLogger('PAVEMAI')
24
25 # Implementación del patrón MVC
26 # =====
27
28 # Modelo - Maneja los datos y la lógica de negocio
29 class PavementModel:
30     def __init__(self):
  
```

INTERFAZ DE USUARIO

La interfaz de PAVEMAI está dividida en dos secciones principales:

- Panel izquierdo

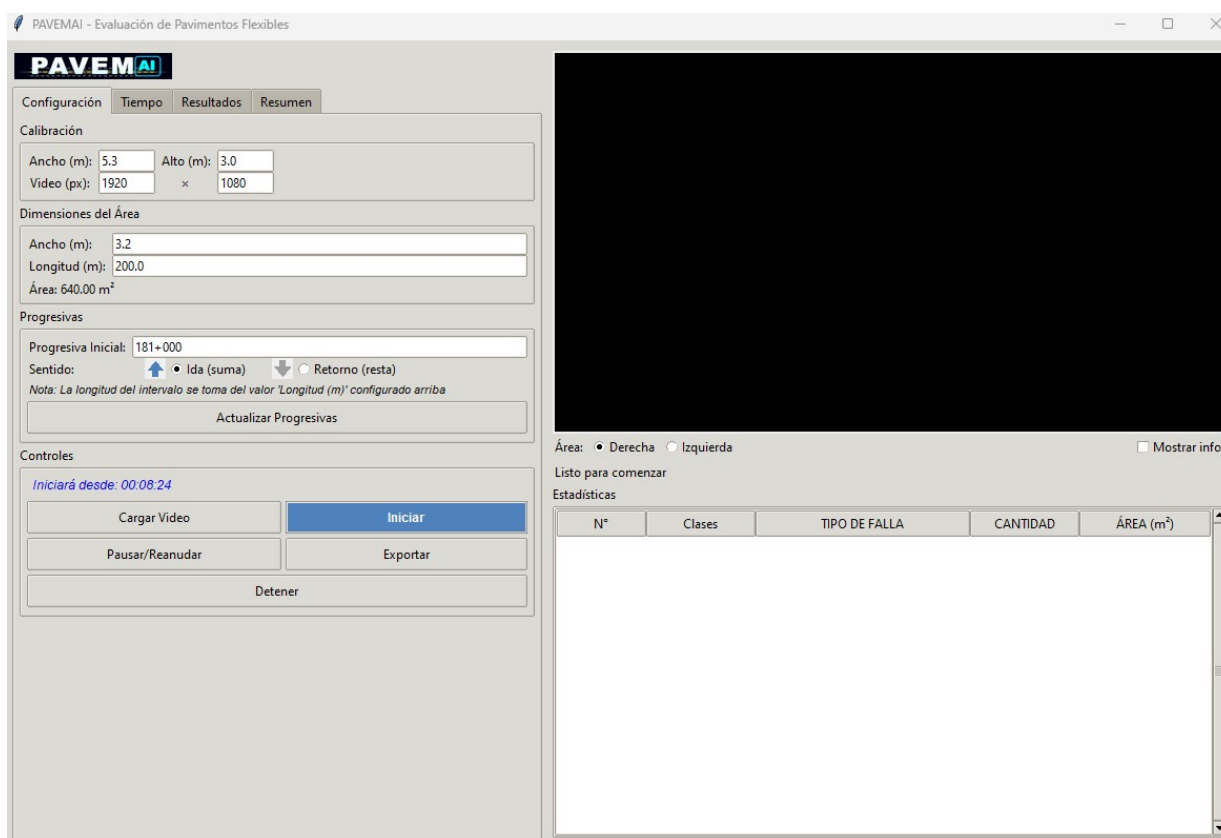
Contiene pestañas para:

- **Configuración:** Calibración, dimensiones del área y controles principales

- **Tiempo:** Configuración de intervalos de evaluación
 - **Resultados:** Visualización de condición del pavimento
 - **Resumen:** Resumen de calificación de condición por intervalos
- Panel derecho

Muestra:

- **Visualización de Video:** Área principal de visualización con detecciones
- **Control de Área:** Selección del lado a evaluar (izquierda/derecha)
- **Estadísticas:** Tabla detallada de fallos detectados



CONFIGURACIÓN INICIAL

1. Calibración

La calibración permite establecer la relación entre píxeles y medidas reales:

- En la pestaña "Configuración", encuentre la sección "Calibración".

- Ingrese el **Ancho (m)** y **Alto (m)** reales del área visible en el video.
- El programa mostrará automáticamente las dimensiones del video en píxeles.

The screenshot shows the PAVEM AI software interface. At the top, there is a logo for PAVEM AI. Below the logo, there are four tabs: Configuración, Tiempo, Resultados, and Resumen. The 'Configuración' tab is selected. Underneath, there is a section titled 'Calibración'. This section contains four input fields: 'Ancho (m):' with the value 5.3, 'Alto (m):' with the value 3.0, 'Video (px):' with the value 1920, and a second 'Video (px):' field with the value 1080, separated by a multiplication sign (×).

2. Dimensiones del área

Configure las dimensiones del área a evaluar:

- (a) En la sección "Dimensiones del Área", ingrese:
- **Ancho (m)**: Ancho del carril a evaluar
 - **Longitud (m)**: Longitud del tramo a evaluar
- (b) El programa calculará automáticamente el área total en metros cuadrados.

The screenshot shows a dialog box titled 'Dimensiones del Área'. It contains three input fields: 'Ancho (m):' with the value 3.2, 'Longitud (m):' with the value 200.0, and 'Área: 640.00 m²'.

3. Progresivas

Las progresivas permiten referenciar geoméricamente los intervalos evaluados:

- (a) En la sección "Progresivas", configure:
- Progresiva Inicial: En formato "K+MMM" (ej: "0+000", "1+250")
 - Sentido: Seleccione "Ida" (suma) o "Retorno" (resta)
- (b) Pulse el botón "Actualizar Progresivas" para aplicar los cambios.

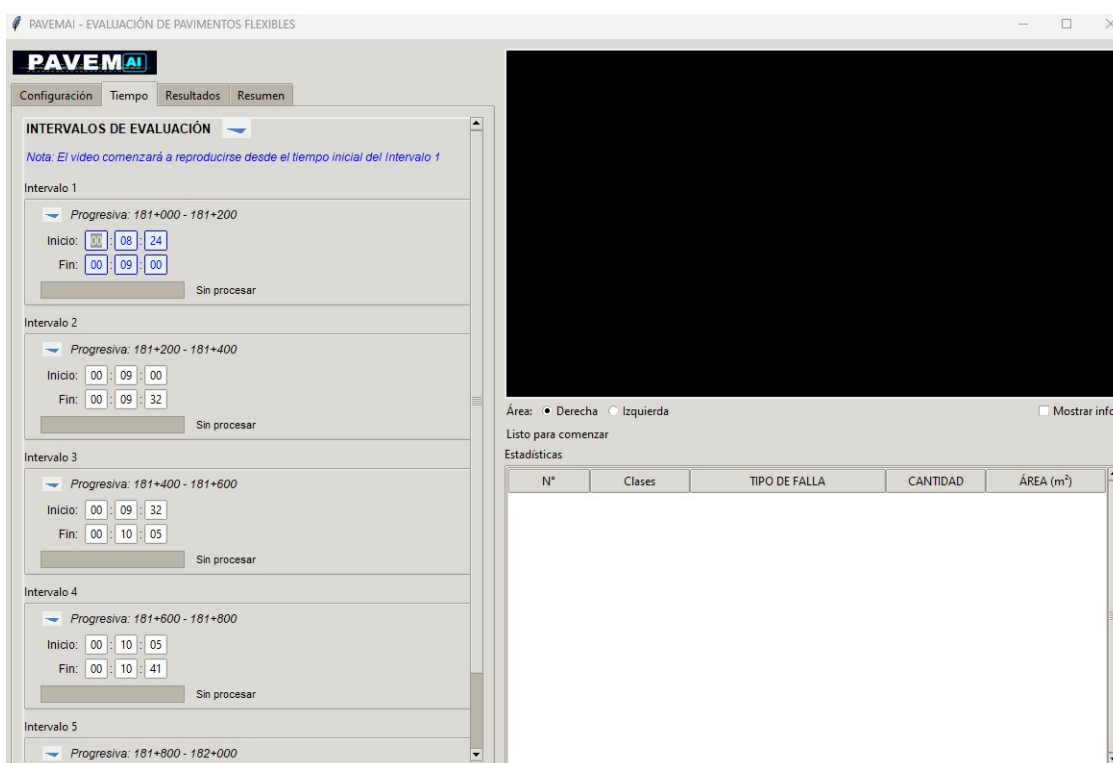
The screenshot shows a dialog box titled 'Progresivas'. It contains an input field for 'Progresiva Inicial:' with the value 181+000. Below this, there are two radio buttons for 'Sentido:'. The first is 'Ida (suma)' with an upward arrow icon and is selected. The second is 'Retorno (resta)' with a downward arrow icon. Below the radio buttons, there is a note: 'Nota: La longitud del intervalo se toma del valor 'Longitud (m)' configurado arriba'. At the bottom of the dialog, there is a button labeled 'Actualizar Progresivas'.

La longitud de cada intervalo se toma del valor "Longitud (m)" configurado en las dimensiones del área.

CONFIGURACIÓN DE TIEMPO

La pestaña "Tiempo" permite configurar hasta 5 intervalos de evaluación:

1. Para cada intervalo, configure:
 - **Tiempo de Inicio:** Horas, minutos y segundos
 - **Tiempo de Fin:** Horas, minutos y segundos
2. Observe que cada intervalo muestra sus progresivas asociadas y una flecha que indica el sentido.



El video comenzará a reproducirse desde el tiempo inicial del Intervalo 1. Asegúrese de configurar correctamente este valor.

PROCESAMIENTO DE VIDEO

1. Cargar video
 - (a) Haga clic en el botón "Cargar Video" en la sección de Controles.
 - (b) Seleccione el archivo de video (formato .mp4, .avi o .mov).

(c) El programa mostrará las dimensiones del video en la sección de Calibración.

2. Iniciar procesamiento

Antes de iniciar el procesamiento, asegúrese de haber configurado:

- Calibración
- Dimensiones del área
- Al menos el Intervalo 1 con tiempos de inicio y fin

Para iniciar:


- Haga clic en el botón "Iniciar".
- El programa mostrará un mensaje indicando que comenzará desde el tiempo del Intervalo 1.
- El procesamiento comenzará y el video se mostrará en el panel derecho con las detecciones superpuestas.

3. Pausar y reanudar

- Haga clic en el botón "Pausar/Reanudar" para detener temporalmente el procesamiento.
- Haga clic nuevamente para continuar.

4. Detener procesamiento

- Haga clic en el botón "Detener" para finalizar el procesamiento.
- Si detiene el procesamiento antes de completar todos los intervalos, solo aquellos que hayan alcanzado el 100% se considerarán procesados.



VISUALIZACIÓN DE RESULTADOS

1. Estadísticas

Durante y después del procesamiento, el panel derecho muestra:

- Una tabla con el conteo de cada tipo de fallo
- El área afectada por cada tipo de fallo

2. Evaluación de condición

La pestaña "Resultados" muestra:

- Valores de EFP (Extensión del Fenómeno Patológico) para cada tipo de fallo
- Valores de PC (Puntos de Condición) para cada tipo de fallo
- La suma total de PC y la Calificación de Condición (CC)

PAVEMAI - EVALUACIÓN DE PAVIMENTOS FLEXIBLES

Configuración | Tiempo | Resultados | Resumen

Evaluación

Categoría	EFP	PC
Piel de Cocodrilo	0.28	1.14
Fisuras	8.53	34.13
Descascaramiento	0.04	0.08
Baches	0.00	0.00
Parques	0.00	0.00

Suma de PC: 35.35 CC: 964.65

Resumen de Detecciones

Detecciones únicas: 110
Detecciones duplicadas evitadas: 0

Área: Derecha Izquierda Mostrar info

Estado: BUENO

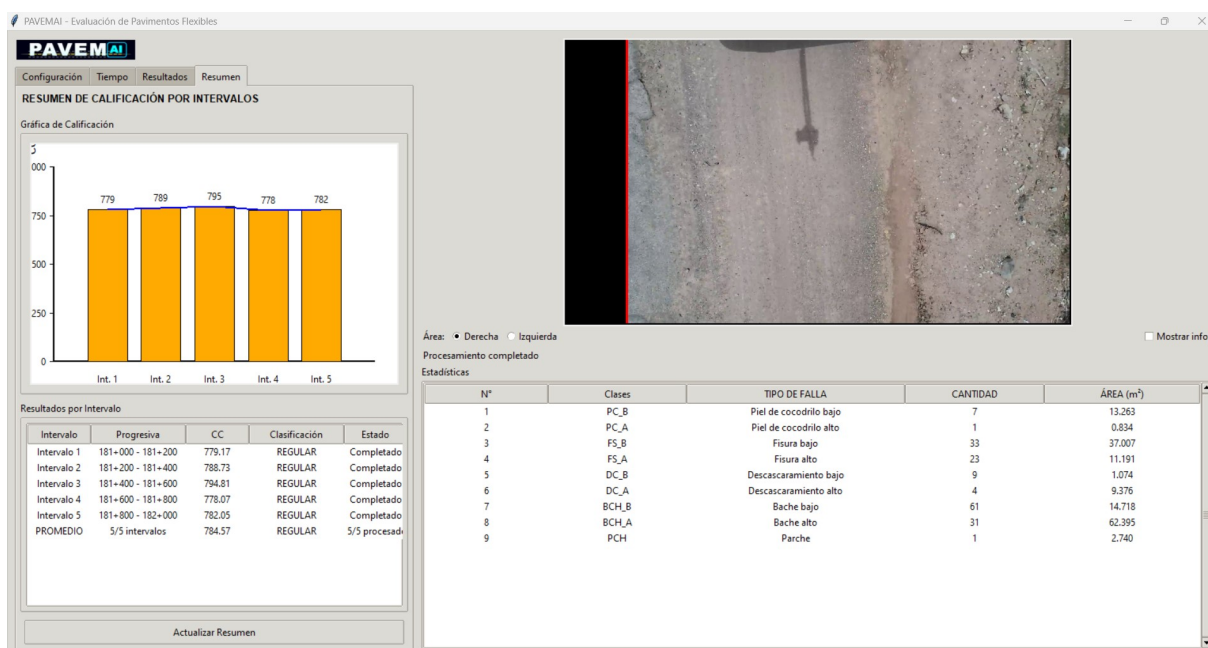
Estadísticas

N°	Clases	TIPO DE FALLA	CANTIDAD	ÁREA (m ²)
1	PC_B	Piel de cocodrilo bajo	2	3.644
2	PC_A	Piel de cocodrilo alto	0	0.000
3	FS_B	Fisura bajo	56	83.006
4	FS_A	Fisura alto	48	70.059
5	DC_B	Descascaramiento bajo	4	0.502
6	DC_A	Descascaramiento alto	0	0.000
7	BCH_B	Bache bajo	0	0.000
8	BCH_A	Bache alto	0	0.000
9	PCH	Parque	0	0.000

3. Resumen de calificación

- La pestaña "Resumen" proporciona:
 - Una gráfica de barras con la Calificación de Condición (CC) de cada intervalo
 - Una tabla con el resumen de resultados por intervalo
 - La clasificación de cada intervalo (BUENO, REGULAR o DEFICIENTE)
 - El promedio de CC para todos los intervalos procesados


- Para actualizar el resumen después de procesar nuevos intervalos:
 - (a) Haga clic en el botón "Actualizar Resumen" en la parte inferior de la pestaña.



EXPORTACIÓN DE RESULTADOS

Para exportar los resultados a Excel:

1. Asegúrese de haber procesado al menos un intervalo.
2. Haga clic en el botón "Exportar" en la sección de Controles.
3. Seleccione la carpeta donde desea guardar los resultados.
4. El programa creará una carpeta con la fecha y hora actuales.
5. Los resultados se guardarán en un archivo Excel con múltiples hojas:
 - **Resumen:** Información general y resultados por intervalo
 - **Intervalo X:** Una hoja detallada para cada intervalo procesado
 - **Detalles de Detección:** Estadísticas detalladas sobre las detecciones



RESUMEN DE EVALUACIÓN POR INTERVALOS							
INFORMACIÓN GENERAL							
Archivo de Video:	compañiaVAL.mp4						
Dimensiones (px):	1920 x 1080						
Calibración (m):	5.3 x 3.0						
Ancho de Carril (m):	3.2						
Longitud Evaluada (m):	200.0						
Área Total (m²):	640.00						
Lado Evaluado:	Derecha						
Progresiva Inicial:	183+000						
Sentido de Progresiva:	Retorno (Izquierda)						
Longitud por Intervalo (m):	200.0						
RESULTADOS POR INTERVALOS							
Intervalo	Progresiva	Tiempo Inicio	Tiempo Fin	Suma PC	CC	Clasificación	Estado
Intervalo 1	183+000 - 182+800	00:00:05	00:00:40	215.66	784.34	REGULAR	Completado
Intervalo 2	182+800 - 182+600	00:00:40	00:01:18	229.98	770.02	REGULAR	Completado
Intervalo 3	182+600 - 182+400	00:01:18	00:01:57	210.58	789.42	REGULAR	Completado
Intervalo 4	182+400 - 182+200	00:01:57	00:02:37	213.05	786.95	REGULAR	Completado
Intervalo 5	182+200 - 182+000	00:02:37	00:03:10	221.49	778.51	REGULAR	Completado
ESTADÍSTICAS DE DETECCIÓN							
Detecciones Únicas:	415.00						
Detecciones Duplicadas Evitadas:	1.00						
Total Firmas Registradas:	415.00						
Eficiencia del Tracking (%):	0.24						

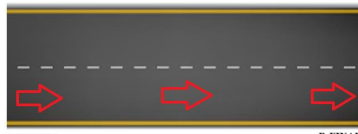
SOLUCIÓN DE PROBLEMAS

- El programa no carga el modelo
 - Verifique que el archivo `best.pt` esté en la misma carpeta que el programa.
 - Si no está allí, el programa le pedirá seleccionar la ubicación del modelo.
- El video no se reproduce
 - Verifique que el formato del video sea compatible (.mp4, .avi, .mov).
 - Asegúrese de que el Intervalo 1 tenga tiempos de inicio y fin correctamente configurados.
- Las detecciones no aparecen
 - Verifique que ha seleccionado correctamente el lado a evaluar (izquierda/derecha).
 - Ajuste la posición del delimitador arrastrando la línea vertical en la visualización del video.
- Errores al exportar resultados
 - Asegúrese de que tiene permisos de escritura en la carpeta seleccionada.
 - Verifique que no hay ningún archivo Excel abierto con el mismo nombre.

Anexo D: Cálculo de condición mediante la metodología del MTC

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)	
--	---

Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido decreciente de progresiva (Ayacucho → Huancavelica) Longitud de calzada: 200 Inicial: 183 + 000
 Fecha: 12/12/2024 Área de estudio (m²): 600 Final: 182 + 800

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformación por deficiencia Estructural 4 Ahuellamiento 5 Reparación o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																					
CANT	1			2			3			4			5			6			7		
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)
1	8.00			4.20	0.44					10.80			1.20			36.00	0.50		1.00		
2				0.80												48.00					
3																					
4																					
TOTAL	8.00			5.00			0.00			10.80			1.20			84.00			1.00		
G (1)	8.00			5.00			0.00			10.80			1.20			84.00			1.00		
G (2)	0.00			0.44			0.00			0.00			0.00			0.50			0.00		
G (3)	0.00			0.00			0.00			0.00			0.00			0.00			0.00		

CANT	8			9			10			11								
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)						
1	1.06	0.68							6.00									
2	0.40																	
3																		
4																		
TOTAL	1.46			0.00			0.00			0.00								
G (1)	1.46			0.00			0.00			0.00								
G (2)	0.68			0.00			6.00			0.00								
G (3)	0.00			0.00			0.00			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICIÓN
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP= MAYOR A 30%	
1	1.33		5.34			5.34
2	0.77		1.54			1.54
3	0.00		0			0.00
4	1.80		3.6			3.60
5	0.20		0.4			0.40
6	13.92			17.83		17.83
7	1.00		5			5.00
8	0.20		0.4			0.40
9	0.00		0			0.00
10	10.00			10		10.00
11	0.00		0			0.00
SUMA DE PUNTAJE DE CONDICIÓN (PC):						44.11

CALIFICACION DE CONDICION: CC=1000-PC =

CONDICIÓN DEL PAVIMENTO:

Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					CONSERVACION RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril + berma contigua: 3 Progresiva de estudio:
 Sentido decreciente de progresiva (Ayacucho → Huancavelica) Longitud de calzada: 188 Inicial: 182 + 800
 Fecha: 12/12/2024 Área de estudio (m²): 564 Final: 182 + 600

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformación por deficiencia Estructural 4 Ahuellamiento 5 Reparación o parchado 6 Peladura y desprendimiento	
7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	18.00			2.80	4.00		9.60			12.00			2.80	1.10		54.00		39.60	4.00	3.00	6.00	
2				4.20	2.80					19.20						56.00		32.00	6.00	2.00	5.00	
3																						
4																						
TOTAL	G (1)	18.00			7.00			9.60			31.20			2.80			110.00			10.00		
	G (2)	0.00			6.80			0.00			0.00			1.10			0.00			5.00		
	G (3)	0.00			0.00			0.00			0.00			0.00			71.60			11.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1	2.40	1.80						4.00	9.60										
2									11.40										
3																			
4																			
TOTAL	G (1)	2.40			0.00			0.00			0.00								
	G (2)	1.80			0.00			4.00			0.00								
	G (3)	0.00			0.00			21.00			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSION DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP= MENOR A 10%	2: MODERADO EFP= ENTRE 10% Y 30%	3: SEVERO EFP= MAYOR A 30%	
1	3.19		12.78			12.78
2	1.22		2.45			2.45
3	1.70		3.41			3.41
4	5.53		11.07			11.07
5	0.41		0.82			0.82
6	16.82			23.63		23.63
7	26.00				100.00	100.00
8	0.38		0.76			0.76
9	0.00		0			0.00
10	32.41				50	50.00
11	0.00		0			0.00
SUMA DE PUNTAJE DE CONDICION (PC):						204.92


CALIFICACION DE CONDICION: CC=1000-PC =

CONDICIÓN DEL PAVIMENTO:

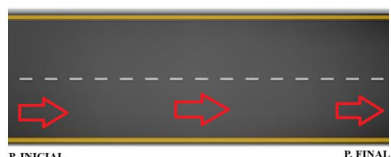
Tipo de conservación según calificación de condición.

RECONSTRUCCION REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)	
--	---

Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido decreciente de progresiva (Ayacucho → Huancavelica) Longitud de calzada: 200 Inicial: 182 + 600
 Fecha: 12/12/2024 Área de estudio (m²): 600 Final: 182 + 400

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformación por deficiencia Estructural 4 Ahuellamiento 5 Reparación o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																							
CANT	1			2			3			4			5			6			7				
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)		
1	1.20	0.60		4.80		0.60				7.80			1.20	4.00		36.00	2.20	0.20	3.00	2.00			
2				1.60	1.20	8.40				6.00			2.20	1.00		31.20	1.20		5.00				
3																							
4																							
TOTAL	G (1)	1.20			6.40			0.00			13.80			3.40			67.20			8.00			
	G (2)	0.60			1.20			0.00			0.00			5.00			3.40			2.00			
	G (3)	0.00			9.00			0.00			0.00			0.00			0.20			0.00			

CANT	8			9			10			11								
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)						
1	0.12									12.00								
2										10.50								
3																		
4																		
TOTAL	G (1)	0.12			0.00			0.00			0.00							
	G (2)	0.00			0.00			0.00			0.00							
	G (3)	0.00			0.00			22.50			0.00							

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICIÓN
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	0.17		0.67			0.67
2	1.24		2.48			2.48
3	0.00		0			0.00
4	2.30		4.6			4.60
5	0.73		1.45			1.45
6	10.66			11.32		11.32
7	10.00			99.00		99.00
8	0.02		0.04			0.04
9	0.00		0			0.00
10	37.50				50	50.00
11	0.00		0			0.00
SUMA DE PUNTAJE DE CONDICIÓN (PC):						169.56

CALIFICACION DE CONDICION: CC=1000-PC = 830.44

CONDICIÓN DEL PAVIMENTO: CONDICIÓN BUENO

Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CONSERVACION RUTINARIA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido decreciente de progresiva (Ayacucho → Huancavelica) Longitud de calzada: 200 Inicial: 182 + 400
 Fecha: 12/12/2024 Área de estudio (m²): 600 Final: 182 + 200

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformación por deficiencia Estructural 4 Ahuellamiento 5 Reparación o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1		2.96	3.20	1.80	6.80	2.40				24.00			4.60	8.80		33.60		1.20	6.00	2.00		
2		2.08		0.64	4.00					18.00						62.40			5.00	4.00	2.00	
3																						
4																						
TOTAL	G (1)	0.00			2.44			0.00			42.00			4.60			96.00			11.00		
	G (2)	5.04			10.80			0.00			0.00			8.80			0.00			6.00		
	G (3)	3.20			2.40			0.00			0.00			0.00			1.20			2.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1	1.20							2.40	9.00	12.00									
2									24.00										
3																			
4																			
TOTAL	G (1)	1.20			0.00			0.00			12.00								
	G (2)	0.00			0.00			2.40			0.00								
	G (3)	0.00			0.00			33.00			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICIÓN
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	0.72		2.89			2.89
2	1.37		2.74			2.74
3	0.00		0			0.00
4	7.00		14.01			14.01
5	1.23		2.45			2.45
6	15.80			21.61		21.61
7	19.00				100.00	100.00
8	0.20		0.4			0.40
9	0.00		0			0.00
10	51.54				50	50.00
11	6.00		12.01			12.01
SUMA DE PUNTAJE DE CONDICIÓN (PC):						206.11

CALIFICACION DE CONDICION: CC=1000-PC =

CONDICIÓN DEL PAVIMENTO:

Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho)

Ancho de carril 3

Progresiva de estudio:

Sentido decreciente de progresiva (Ayacucho → Huancavelica)

Longitud de calzada: 200

Inicial: 182 + 200

Fecha: 12/12/2024

Área de estudio (m²): 600

Final: 181 + 000

TIPOS DE FALLAS											GRÁFICO					
1 Piel de cocodrilo	2 Fisuras Longitudinales	3 Deformación por deficiencia Estructural	4 Ahuellamiento	5 Reparación o parchado	6 Peladura y desprendimiento	7 Baches (Huecos)	8 Fisuras transversales	9 Exudación	10 Daños puntuales	11 Desnivel Calzada - Berma						

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	2.40	0.80		4.80	10.40	5.40	19.20			21.00			0.50	1.30		38.40	3.20	2.62	6.00	4.00	1.00	
2	22.80	6.80		0.86	3.20	9.00								2.84		57.60	2.45	3.20	7.00	3.00	2.00	
3																						
4																						
TOTAL	G (1)	25.20			5.66			19.20			21.00			0.50			96.00			13.00		
	G (2)	7.60			13.60			0.00			0.00			4.14			5.65			7.00		
	G (3)	0.00			14.40			0.00			0.00			0.00			5.82			3.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1		1.24						18.00	6.00	10.00	20.00								
2									27.60										
3																			
4																			
TOTAL	G (1)	0.00			0.00			0.00			10.00								
	G (2)	1.24			0.00			18.00			20.00								
	G (3)	0.00			0.00			33.60			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICIÓN
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	3.52		14.09			14.09
2	2.10		4.2			4.20
3	3.20		6.4			6.40
4	3.50		7			7.00
5	0.62		1.25			1.25
6	14.39			18.79		18.79
7	23.00				100.00	100.00
8	0.21		0.41			0.41
9	0.00		0			0.00
10	46.93				50	50.00
11	8.33		16.68			16.68
SUMA DE PUNTAJE DE CONDICIÓN (PC):						218.82

CALIFICACION DE CONDICION: CC=1000-PC = **781.18**
CONDICIÓN DEL PAVIMENTO: **CONDICIÓN REGULAR**

Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:
CONSERVACION PERIODICA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido decreciente de progresiva (Ayacucho → Huancavelica) Longitud de calzada: 188 Inicial: 182 + 000
 Fecha: 12/12/2024 Área de estudio (m²): 564 Final: 181 + 800

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformación por deficiencia Estructural 4 Ahuellamiento 5 Reparación o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	<p>P. INICIAL P. FINAL</p>

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	2.20	6.60		1.80	1.60	7.80				24.00			1.40	0.80		62.40	37.50	18.00	5.00	2.00	6.00	
2	1.80	16.40		1.60	5.60	6.00										48.00	8.20		1.00			
3																						
4																						
TOTAL	G (1)	4.00			3.40			0.00			24.00			1.40			110.40			6.00		
	G (2)	23.00			7.20			0.00			0.00			0.80			45.70			2.00		
	G (3)	0.00			13.80			0.00			0.00			0.00			18.00			6.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1		1.20								30.00	30.00	6.00							
2		1.60								21.00									
3																			
4																			
TOTAL	G (1)	0.00			0.00			0.00			30.00								
	G (2)	2.80			0.00			0.00			6.00								
	G (3)	0.00			0.00			51.00			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICIÓN
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	3.58		14.33			14.33
2	1.84		3.69			3.69
3	0.00		0			0.00
4	4.26		8.51			8.51
5	0.21		0.42			0.42
6	14.87			19.74		19.74
7	14.00				100.00	100.00
8	0.50		0.99			0.99
9	0.00		0			0.00
10	90.43				50	50.00
11	13.83			35.32		35.32
SUMA DE PUNTAJE DE CONDICIÓN (PC):						233.00

CALIFICACION DE CONDICION: CC=1000-PC =

CONDICIÓN DEL PAVIMENTO:

Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION	CONSERVACION PERIODICA CONSERVACION							ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido decreciente de progresiva (Ayacucho → Huancavelica) Longitud de calzada: 188 Inicial: 181 + 800
 Fecha: 12/12/2024 Área de estudio (m²): 564 Final: 181 + 600

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformación por deficiencia Estructural 4 Ahuellamiento 5 Reparación o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	9.40	6.60	2.40	1.80	6.40		3.60	0.40		12.00				2.86		57.60	11.20		3.00	2.00	4.00	
2	5.80			2.40	4.40					19.20						28.00			3.00	1.00	1.00	
3																						
4																						
TOTAL	G (1)	15.20			4.20			3.60			31.20			0.00			85.60			6.00		
	G (2)	6.60			10.80			0.40			0.00			2.86			11.20			3.00		
	G (3)	2.40			0.00			0.00			0.00			0.00			0.00			5.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1	0.48	1.20						4.00	22.80	22.00									
2									7.50										
3																			
4																			
TOTAL	G (1)	0.48			0.00			0.00			22.00								
	G (2)	1.20			0.00			4.00			0.00								
	G (3)	0.00			0.00			30.30			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICIÓN
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	2.05		8.22			8.22
2	1.59		3.18			3.18
3	0.58		1.16			1.16
4	5.53		11.07			11.07
5	0.51		1.01			1.01
6	13.65			17.3		17.30
7	14.00				100.00	100.00
8	0.18		0.35			0.35
9	0.00		0			0.00
10	48.29				50	50.00
11	11.70			26.81		26.81
SUMA DE PUNTAJE DE CONDICIÓN (PC):						219.10

CALIFICACION DE CONDICION: CC=1000-PC =

CONDICIÓN DEL PAVIMENTO:

Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION	CONSERVACION PERIODICA CONSERVACION							ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido decreciente de progresiva (Ayacucho → Huancavelica) Longitud de calzada: 200 Inicial: 182 + 600
 Fecha: 12/12/2024 Área de estudio (m²): 600 Final: 181 + 400

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformación por deficiencia Estructural 4 Ahuellamiento 5 Reparación o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1		4.30		0.60	2.80	2.40	6.00			6.00			0.68	0.20		20.00	15.00		2.00	2.00	7.00	
2				2.80						6.60						60.00						
3																						
4																						
TOTAL	G (1)	0.00			3.40			6.00			12.60			0.68			80.00			2.00		
	G (2)	4.30			2.80			0.00			0.00			0.20			15.00			2.00		
	G (3)	0.00			2.40			0.00			0.00			0.00			0.00			7.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1								12.00	3.00										
2								10.00	6.00										
3																			
4																			
TOTAL	G (1)	0.00			0.00			0.00			0.00								
	G (2)	0.00			0.00			22.00			0.00								
	G (3)	0.00			0.00			9.00			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICIÓN
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	0.72		2.87			2.87
2	0.49		0.98			0.98
3	1.00		2			2.00
4	2.10		4.2			4.20
5	0.10		0.19			0.19
6	11.62			13.24		13.24
7	11.00				100.00	100.00
8	0.00		0			0.00
9	0.00		0			0.00
10	30.38				50	50.00
11	0.00		0			0.00
SUMA DE PUNTAJE DE CONDICIÓN (PC):						173.48

CALIFICACION DE CONDICION: CC=1000-PC = 826.52

CONDICIÓN DEL PAVIMENTO: CONDICIÓN BUENO

Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CONSERVACION RUTINARIA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho)

Ancho de carril 3

Progresiva de estudio:

Sentido decreciente de progresiva (Ayacucho → Huancavelica)

Longitud de calzada: 200

Inicial: 182 + 400

Fecha: 12/12/2024

Área de estudio (m²): 600

Final: 181 + 200

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformación por deficiencia Estructural 4 Ahuellamiento 5 Reparación o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	8.24	0.84		3.20	7.60	1.26				7.20				0.90		60.00		0.90	8.00	2.00	3.00	
2	2.50	20.60		6.40	6.40	2.40				9.60			1.40	2.80		88.00	40.00		4.00	2.00	2.00	
3																						
4																						
TOTAL	G (1)	10.74			9.60			0.00			16.80			1.40			148.00			12.00		
	G (2)	21.44			14.00			0.00			0.00			3.70			40.00			4.00		
	G (3)	0.00			3.66			0.00			0.00			0.00			0.90			5.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1							8.00	18.00	16.00										
2							5.00	18.00											
3																			
4																			
TOTAL	G (1)	0.00			0.00			0.00			16.00								
	G (2)	0.00			0.00			13.00			0.00								
	G (3)	0.00			0.00			36.00			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAYOR A 30%	
1	2.98		11.92			11.92
2	1.84		3.69			3.69
3	0.00		0			0.00
4	2.80		5.6			5.60
5	0.51		1.02			1.02
6	20.74			31.47		31.47
7	21.00				100.00	100.00
8	0.00		0			0.00
9	0.00		0			0.00
10	49.83				50	50.00
11	8.00		16.01			16.01
SUMA DE PUNTAJE DE CONDICION (PC):						219.71

CALIFICACION DE CONDICION: CC=1000-PC = **780.29**
CONDICIÓN DEL PAVIMENTO: **CONDICIÓN REGULAR**

Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION		CONSERVACION PERIODICA CONSERVACION						ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:
CONSERVACION PERIODICA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho)

Ancho de carril 3

Progresiva de estudio:

Sentido decreciente de progresiva (Ayacucho → Huancavelica)

Longitud de calzada: 200

Inicial: 182 + 200

Fecha: 12/12/2024

Área de estudio (m²): 600

Final: 181 + 000

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformacion por deficiencia Estructural 4 Ahuellamiento 5 Reparacion o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	9.60	14.20		5.60	5.60	4.20		0.80		24.00				4.00		57.60	50.00	2.80	8.00	4.00	3.00	
2	6.80			3.40	4.40	9.60										36.00	39.60					
3																						
4																						
TOTAL	G (1)	16.40			9.00			0.00			24.00			0.00			93.60			8.00		
	G (2)	14.20			10.00			0.80			0.00			4.00			89.60			4.00		
	G (3)	0.00			13.80			0.00			0.00			0.00			2.80			3.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1	1.20	2.40						4.00	24.00	18.00									
2								6.40	16.80										
3																			
4																			
TOTAL	G (1)	1.20			0.00			0.00			18.00								
	G (2)	2.40			0.00			10.40			0.00								
	G (3)	0.00			0.00			40.80			0.00								

CONDICIÓN DE PAVIMENTO


TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAYOR A 30%	
1	2.56		10.26			10.26
2	1.89		3.78			3.78
3	0.13		0.27			0.27
4	4.00		8			8.00
5	0.67		1.33			1.33
6	15.05			20.1		20.10
7	15.00				100.00	100.00
8	0.33		0.67			0.67
9	0.00		0			0.00
10	57.71				50	50.00
11	9.00		18.01			18.01
SUMA DE PUNTAJE DE CONDICION (PC):						212.42

CALIFICACION DE CONDICION: CC=1000-PC = **787.58**
CONDICIÓN DEL PAVIMENTO: **CONDICIÓN REGULAR**

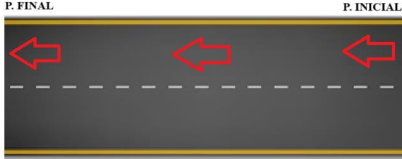
Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					CONSERVACION RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:
CONSERVACION PERIODICA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)	
--	---

Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido creciente de progresiva (Huancavelica→Ayacucho) Longitud de calzada: 200 Inicial: 181 + 000
 Fecha: 12/12/2024 Área de estudio (m²): 600 Final: 181 + 200

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformacion por deficiencia Estructural 4 Ahuellamiento 5 Reparacion o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																							
CANT	1			2			3			4			5			6			7				
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)		
1	2.30	17.60	1.80	1.60	10.96	8.40	1.20				12.00				3.10	0.80		39.60	12.80	3.20	3.00	2.00	1.00
2	5.20	9.50	2.10	1.10	2.20	10.80					12.00				2.80			36.00	8.50	4.50	5.00	7.00	7.00
3																							
4																							
TOTAL	G (1)	7.50			2.70			1.20			24.00			5.90			75.60			8.00			
	G (2)	27.10			13.16			0.00			0.00			0.80			21.30			9.00			
	G (3)	3.90			19.20			0.00			0.00			0.00			7.70			8.00			

CANT	8			9			10			11												
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)										
1	0.50	1.80						4.40	8.00	12.00												
2								4.50	12.00													
3																						
4																						
TOTAL	G (1)	0.50			0.00			0.00			12.00											
	G (2)	1.80			0.00			8.90			0.00											
	G (3)	0.00			0.00			20.00			0.00											

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSION DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAYOR A 30%	
1	3.49		13.96			13.96
2	2.61		5.22			5.22
3	0.20		0.4			0.40
4	4.00		8			8.00
5	0.88		1.76			1.76
6	9.92		19.86			19.86
7	25.00				100.00	100.00
8	0.25		0.51			0.51
9	0.00		0			0.00
10	33.16				50	50.00
11	6.00		12.01			12.01
SUMA DE PUNTAJE DE CONDICION (PC):						211.72

CALIFICACION DE CONDICION: CC=1000-PC = 788.28

CONDICIÓN DEL PAVIMENTO: CONDICIÓN REGULAR

Tipo de conservacion según calificacion de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CONSERVACION PERIODICA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho)

Ancho de carril 3

Progresiva de estudio:

Sentido creciente de progresiva (Huancavelica→Ayacucho)

Longitud de calzada: 200

Inicial: 181 + 200

Fecha: 12/12/2024

Área de estudio (m²): 600

Final: 181 + 400

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformacion por deficiencia Estructural 4 Ahuellamiento 5 Reparacion o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	5.20	16.80	0.20	3.10	2.56	0.85		1.20		12.00			0.60	1.20		68.40	24.00	4.40	5.00	2.00	1.00	
2	6.80	3.80		2.20	4.80	8.40				12.60			0.80	1.10		61.20	18.00	4.80	2.00	1.00		
3																						
4																						
TOTAL	G (1)	12.00			5.30			0.00			24.60			1.40			129.60			7.00		
	G (2)	20.60			7.36			1.20			0.00			2.30			42.00			3.00		
	G (3)	0.20			9.25			0.00			0.00			0.00			9.20			1.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1	0.28	0.76	1.86					3.00	12.50	14.00									
2							2.00	6.00	9.50										
3																			
4																			
TOTAL	G (1)	0.28			0.00			2.00			14.00								
	G (2)	0.76			0.00			9.00			0.00								
	G (3)	1.86			0.00			22.00			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAYOR A 30%	
1	2.89		11.56			11.56
2	1.28		2.55			2.55
3	0.20		0.4			0.40
4	4.10		8.2			8.20
5	0.33		0.65			0.65
6	17.19			24.37		24.37
7	11.00				100.00	100.00
8	0.24		0.47			0.47
9	0.00		0			0.00
10	34.48				50	50.00
11	7.00		14.01			14.01
SUMA DE PUNTAJE DE CONDICION (PC):						212.21

CALIFICACION DE CONDICION: CC=1000-PC = **787.79**
CONDICIÓN DEL PAVIMENTO: **CONDICIÓN REGULAR**

Tipo de conservacion según calificacion de condición.

RECONSTRUCCION - REHABILITACION		CONSERVACION PERIODICA CONSERVACION						ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:
CONSERVACION PERIODICA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho)

Ancho de carril 3

Progresiva de estudio:

Sentido creciente de progresiva (Huancavelica→Ayacucho)

Longitud de calzada: 200

Inicial: 181 + 400

Fecha: 12/12/2024

Área de estudio (m²): 600

Final: 181 + 600

TIPOS DE FALLAS											GRÁFICO					
1 Piel de cocodrilo																
2 Fisuras Longitudinales																
3 Deformacion por deficiencia Estructural																
4 Ahuellamiento																
5 Reparacion o parchado																
6 Peladura y desprendimiento																
7 Baches (Huecos)																
8 Fisuras transversales																
9 Exudación																
10 Daños puntuales																
11 Desnivel Calzada - Berma																

TIPOS DE FALLAS																							
CANT	1			2			3			4			5			6			7				
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)		
1	2.80			3.20	3.00					6.00					0.50			8.00		8.20	4.00	2.00	3.00
2				1.20																			
3																							
4																							
TOTAL	G (1)	2.80			4.40			0.00			6.00			0.00			8.00			4.00			
	G (2)	0.00			3.00			0.00			0.00			0.50			0.00			2.00			
	G (3)	0.00			0.00			0.00			0.00			0.00			8.20			3.00			

CANT	8			9			10			11													
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)											
1	1.20	1.60						3.00	10.00														
2								10.80															
3																							
4																							
TOTAL	G (1)	1.20			0.00			0.00			0.00												
	G (2)	1.60			0.00			13.80			0.00												
	G (3)	0.00			0.00			10.00			0.00												

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	0.47		1.87			1.87
2	0.64		1.28			1.28
3	0.00		0			0.00
4	1.00		2			2.00
5	0.08		0.17			0.17
6	1.35		2.7			2.70
7	9.00			86.00		86.00
8	0.24		0.48			0.48
9	0.00		0			0.00
10	24.41			38.81		38.81
11	0.00		0			0.00
SUMA DE PUNTAJE DE CONDICION (PC):						133.31

CALIFICACION DE CONDICION: CC=1000-PC =
CONDICIÓN DEL PAVIMENTO:

Tipo de conservacion según calificacion de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho)

Ancho de carril 3

Progresiva de estudio:

Sentido creciente de progresiva (Huancavelica→Ayacucho)

Longitud de calzada: 188

Inicial: 181 + 600

Fecha: 12/12/2024

Área de estudio (m²): 564

Final: 181 + 800

TIPOS DE FALLAS											GRÁFICO					
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformacion por deficiencia Estructural 4 Ahuellamiento 5 Reparacion o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma																

TIPOS DE FALLAS																											
CANT	1			2			3			4			5			6			7								
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)						
1	4.80	4.40	3.40	2.80	1.36	1.86	2.40			24.00	18.00		1.20	0.80		52.80	15.80	4.80	1.00	3.00	5.00						
2	4.20	0.80		4.68	3.72	12.84	2.00			24.00	18.00		2.40	0.60		63.00	2.00		2.00	4.00	6.00						
3																											
4																											
TOTAL	G (1)			G (2)			G (3)			G (1)			G (2)			G (3)			G (1)			G (2)			G (3)		
	9.00			7.48			4.40			48.00			3.60			115.80			3.00								
	5.20			5.08			0.00			36.00			1.40			17.80			7.00								
3.40			14.70			0.00			0.00			0.00			4.80			11.00									

CANT	8			9			10			11								
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)						
1	2.40	1.60	0.36				2.30	3.75	12.25	16.00								
2	1.86						0.20	1.80	11.25									
3																		
4																		
TOTAL	G (1)			G (2)			G (3)			G (1)			G (2)			G (3)		
	4.26			0.00			2.50			16.00								
	1.60			0.00			5.55			0.00								
0.36			0.00			23.50			0.00									

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	1.20		4.82			4.82
2	1.94		3.88			3.88
3	0.78		1.56			1.56
4	7.60		15.21			15.21
5	0.53		1.06			1.06
6	17.61			25.23		25.23
7	21.00				100.00	100.00
8	0.59		1.19			1.19
9	0.00		0			0.00
10	39.74				50	50.00
11	8.51		17.03			17.03
SUMA DE PUNTAJE DE CONDICION (PC):						219.98

CALIFICACION DE CONDICION: CC=1000-PC =
CONDICIÓN DEL PAVIMENTO:

Tipo de conservacion según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho)

Ancho de carril 3

Progresiva de estudio:

Sentido creciente de progresiva (Huancavelica→Ayacucho)

Longitud de calzada: 188

Inicial: 181 + 800

Fecha: 12/12/2024

Área de estudio (m²): 564

Final: 182 + 000

TIPOS DE FALLAS											GRÁFICO					
1 Piel de cocodrilo																
2 Fisuras Longitudinales																
3 Deformación por deficiencia Estructural																
4 Ahuellamiento																
5 Reparación o parchado																
6 Peladura y desprendimiento																
7 Baches (Huecos)																
8 Fisuras transversales																
9 Exudación																
10 Daños puntuales																
11 Desnivel Calzada - Berma																

TIPOS DE FALLAS																											
CANT	1			2			3			4			5			6			7								
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)						
1	9.20	1.20	0.82	0.48	4.00	8.40				21.00			2.80	0.80		24.00	3.20	0.80	2.00	1.00	9.00						
2	6.40	12.40	0.68	0.84	3.20	2.04				42.00						76.00		23.20	37.80	2.00							
3																											
4																											
TOTAL	G (1)			G (2)			G (3)			G (1)			G (2)			G (3)			G (1)			G (2)			G (3)		
	15.60			1.32			0.00			63.00			2.80			100.00			39.80								
	13.60			7.20			0.00			0.00			0.80			3.20			3.00								
G (3)			1.50			10.44			0.00			0.00			0.00			24.00			9.00						

CANT	8			9			10			11										
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)								
1	0.28	0.80	2.76						3.00	2.50										
2			0.96						4.50	17.50										
3																				
4																				
TOTAL	G (1)			G (2)			G (3)			G (1)			G (2)			G (3)				
	0.28			0.00			0.00			0.00										
	0.80			0.00			7.50			0.00										
G (3)			3.72			0.00			20.00			0.00								

CONDICIÓN DE PAVIMENTO


TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICIÓN
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	2.49		9.95			9.95
2	1.52		3.04			3.04
3	0.00		0			0.00
4	11.17			24.68		24.68
5	0.42		0.84			0.84
6	14.76			19.51		19.51
7	51.80				100.00	100.00
8	0.54		1.08			1.08
9	0.00		0			0.00
10	35.30				50	50.00
11	0.00		0			0.00
SUMA DE PUNTAJE DE CONDICIÓN (PC):						209.10

CALIFICACION DE CONDICION: CC=1000-PC =
CONDICIÓN DEL PAVIMENTO:

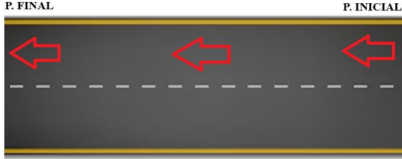
Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)	
--	---

Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido creciente de progresiva (Huancavelica→Ayacucho) Longitud de calzada: 200 Inicial: 182 + 000
 Fecha: 12/12/2024 Área de estudio (m²): 600 Final: 182 + 200

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformacion por deficiencia Estructural 4 Ahuellamiento 5 Reparacion o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	6.20	15.20	9.80	1.28	3.64	12.42				18.00			1.58	0.80		3.00	1.80	0.40	2.00	1.00	1.00	
2	4.80	6.40	0.60	0.42	7.68	9.60				15.00			1.38	0.98		5.00		0.50	4.00	2.00		
3																						
4																						
TOTAL	G (1)	11.00			1.70			0.00			33.00			2.96			8.00			6.00		
	G (2)	21.60			11.32			0.00			0.00			1.78			1.80			3.00		
	G (3)	10.40			22.02			0.00			0.00			0.00			0.90			1.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1	0.48	0.44	0.72					6.00	6.25	22.00									
2		0.40	2.46					7.50	10.50										
3			-																
4																			
TOTAL	G (1)	0.48			0.00			0.00			22.00								
	G (2)	0.84			0.00			13.50			0.00								
	G (3)	3.18			0.00			16.75			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	2.70		10.79			10.79
2	2.93		5.86			5.86
3	0.00		0			0.00
4	5.50		11.01			11.01
5	0.42		0.84			0.84
6	1.06		2.12			2.12
7	10.00			99.00		99.00
8	0.41		0.82			0.82
9	0.00		0			0.00
10	30.60				50	50.00
11	11.00			24		24.00
SUMA DE PUNTAJE DE CONDICION (PC):						204.44

CALIFICACION DE CONDICION: CC=1000-PC = 795.56


CONDICIÓN DEL PAVIMENTO: CONDICIÓN REGULAR

Tipo de conservacion según calificación de condición.

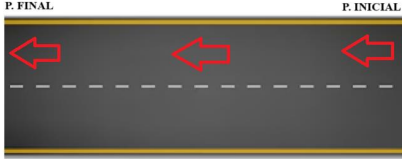
RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CONSERVACION PERIODICA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)	
--	---

Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido creciente de progresiva (Huancavelica→Ayacucho) Longitud de calzada: 200 Inicial: 182 + 200
 Fecha: 12/12/2024 Área de estudio (m²): 600 Final: 182 + 400

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformacion por deficiencia Estructural 4 Ahuellamiento 5 Reparacion o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	7.80	1.80		1.62	2.40	1.56				24.00			3.80	1.36		24.00	3.30	0.40	3.00	2.00	1.00	
2	5.20			1.20	1.20	1.26							4.20	3.20		33.60	1.20	1.20	2.00	1.00	1.00	
3																						
4																						
TOTAL	G (1)	13.00			2.82			0.00			24.00			8.00			57.60			5.00		
	G (2)	1.80			3.60			0.00			0.00			4.56			4.50			3.00		
	G (3)	0.00			2.82			0.00			0.00			0.00			1.60			2.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1	0.30	3.20	2.70				4.00	3.00	15.00	16.00									
2	0.40	1.20						4.50	7.50										
3																			
4																			
TOTAL	G (1)	0.70			0.00			4.00			16.00								
	G (2)	4.40			0.00			7.50			0.00								
	G (3)	2.70			0.00			22.50			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	1.94		7.76			7.76
2	0.52		1.04			1.04
3	0.00		0			0.00
4	4.00		8			8.00
5	1.13		2.25			2.25
6	8.74		17.49			17.49
7	10.00			99.00		99.00
8	0.58		1.16			1.16
9	0.00		0			0.00
10	34.03				50	50.00
11	8.00		16.01			16.01
SUMA DE PUNTAJE DE CONDICION (PC):						202.71

CALIFICACION DE CONDICION: CC=1000-PC = 797.29


CONDICIÓN DEL PAVIMENTO: CONDICIÓN REGULAR

Tipo de conservacion según calificacion de condición.

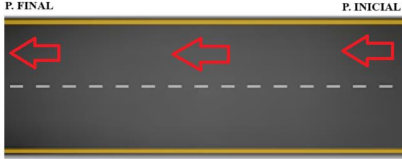
RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CONSERVACION PERIODICA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)	
--	---

Carretera: Ruta Nacional PE-26B (Ayacucho) Ancho de carril 3 Progresiva de estudio:
 Sentido creciente de progresiva (Huancavelica→Ayacucho) Longitud de calzada: 200 Inicial: 182 + 400
 Fecha: 12/12/2024 Área de estudio (m²): 600 Final: 182 + 600

TIPOS DE FALLAS	GRÁFICO
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformación por deficiencia Estructural 4 Ahuellamiento 5 Reparación o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma	

TIPOS DE FALLAS																						
CANT	1			2			3			4			5			6			7			
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	
1	3.20	4.60		2.40	2.40	2.40		0.80		12.00			1.40	2.80		33.60	1.20	1.00	3.00	1.00	2.00	
2	9.64	2.60		1.20	0.80					9.00			0.90	2.00		25.20	2.40	0.80	2.00	1.00	1.00	
3																						
4																						
TOTAL	G (1)	12.84			3.60			0.00			21.00			2.30			58.80			5.00		
	G (2)	7.20			3.20			0.80			0.00			4.80			3.60			2.00		
	G (3)	0.00			2.40			0.00			0.00			0.00			1.80			3.00		

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1	0.42	2.40						4.50	10.00										
2	1.80							9.00	2.50										
3																			
4																			
TOTAL	G (1)	2.22			0.00			0.00			0.00								
	G (2)	2.40			0.00			13.50			0.00								
	G (3)	0.00			0.00			12.50			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICIÓN
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	1.80		7.21			7.21
2	0.52		1.05			1.05
3	0.13		0.27			0.27
4	3.50		7			7.00
5	0.67		1.33			1.33
6	9.02		18.04			18.04
7	10.00			99.00		99.00
8	0.39		0.77			0.77
9	0.00		0			0.00
10	26.04			42.07		42.07
11	0.00		0			0.00
SUMA DE PUNTAJE DE CONDICIÓN (PC):						176.74

CALIFICACION DE CONDICION: CC=1000-PC = 823.26

CONDICIÓN DEL PAVIMENTO: CONDICIÓN BUENO

Tipo de conservación según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CONSERVACION RUTINARIA

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho)

Ancho de carril 3

Progresiva de estudio:

Sentido creciente de progresiva (Huancavelica→Ayacucho)

Longitud de calzada: 188

Inicial: 182 + 600

Fecha: 12/12/2024

Área de estudio (m²): 564

Final: 182 + 800

TIPOS DE FALLAS											GRÁFICO					
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformacion por deficiencia Estructural 4 Ahuellamiento 5 Reparacion o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma																

TIPOS DE FALLAS																							
CANT	1			2			3			4			5			6			7				
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)		
1	2.80			2.60	1.36				1.20						1.20			53.20	2.00	2.50	2.00	1.00	5.00
2	0.20			1.80	3.20													90.00	5.80	4.20	2.00	2.00	6.00
3																							
4																							
TOTAL	G (1)	3.00			4.40			0.00			22.20			0.00			143.20			4.00			
	G (2)	0.00			4.56			1.20			0.00			1.20			7.80			3.00			
	G (3)	0.00			0.00			0.00			0.00			0.00			6.70			11.00			

CANT	8			9			10			11									
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)							
1	0.40	2.64							4.80	13.50	11.00								
2	0.90								1.20	24.00									
3																			
4																			
TOTAL	G (1)	1.30			0.00			0.00			11.00								
	G (2)	2.64			0.00			6.00			0.00								
	G (3)	0.00			0.00			37.50			0.00								

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	0.53		2.13			2.13
2	0.79		1.59			1.59
3	0.21		0.43			0.43
4	3.94		7.88			7.88
5	0.21		0.43			0.43
6	23.17			36.34		36.34
7	18.00				100.00	100.00
8	0.39		0.78			0.78
9	0.00		0			0.00
10	70.54				50	50.00
11	5.85		11.71			11.71
SUMA DE PUNTAJE DE CONDICION (PC):						211.29

CALIFICACION DE CONDICION: CC=1000-PC =
CONDICIÓN DEL PAVIMENTO:

Tipo de conservacion según calificación de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CALIFICACIÓN DE CONDICIÓN DE PAVIMENTOS FLEXIBLES SEGÚN EL MINISTERIO DE TRANSPORTES Y COMUNICACIONES (MTC)


Carretera: Ruta Nacional PE-26B (Ayacucho)

Ancho de carril 3

Progresiva de estudio:

Sentido creciente de progresiva (Huancavelica→Ayacucho)

Longitud de calzada: 200

Inicial: 182 + 800

Fecha: 12/12/2024

Área de estudio (m²): 600

Final: 183 + 000

TIPOS DE FALLAS											GRÁFICO					
1 Piel de cocodrilo 2 Fisuras Longitudinales 3 Deformacion por deficiencia Estructural 4 Ahuellamiento 5 Reparacion o parchado 6 Peladura y desprendimiento 7 Baches (Huecos) 8 Fisuras transversales 9 Exudación 10 Daños puntuales 11 Desnivel Calzada - Berma																

TIPOS DE FALLAS																													
CANT	1			2			3			4			5			6			7										
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)								
1	5.34	6.80	4.20	3.60	1.20					23.20			2.80	0.36		12.00	0.40		1.00	1.00	2.00								
2	8.82			1.40	17.20					7.20									1.00										
3																													
4																													
TOTAL	G (1)			G (2)			G (3)			G (1)			G (2)			G (3)			G (1)			G (2)			G (3)				
	14.16			5.00			0.00			30.40			2.80			12.00			2.00										
	6.80			18.40			0.00			0.00			0.36			0.40			1.00										
G (3)			4.20			0.00			0.00			0.00			0.00			0.00			0.00			2.00					

CANT	8			9			10			11																	
	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)	G (1)	G (2)	G (3)															
1		0.80							3.60	6.00																	
2									2.40	4.50																	
3																											
4																											
TOTAL	G (1)			G (2)			G (3)			G (1)			G (2)			G (3)			G (1)			G (2)			G (3)		
	0.00			0.00			0.00			0.00																	
	0.80			0.00			6.00			0.00																	
G (3)			0.00			0.00			10.50			0.00															

CONDICIÓN DE PAVIMENTO

TIPO DE FALLA	EXTENSIÓN PROMEDIO PONDERADA	PUNTAJE DE CONDICIÓN SEGÚN EXTENSIÓN DE CADA TIPO DE DETERIORO O FALLA				PUNTAJE DE CONDICION
		0: SIN DETERIORO O SIN FALLA	1: LEVE EFP=MENOR A 10%	2: MODERADO EFP=ENTRE 10% Y 30%	3: SEVERO EFP=MAJOR A 30%	
1	1.75		7.01			7.01
2	2.59		5.18			5.18
3	0.00		0			0.00
4	5.07		10.14			10.14
5	0.42		0.84			0.84
6	1.94		3.88			3.88
7	5.00			34.00		34.00
8	0.13		0.27			0.27
9	0.00		0			0.00
10	14.77			19.54		19.54
11	0.00		0			0.00
SUMA DE PUNTAJE DE CONDICION (PC):						80.86

CALIFICACION DE CONDICION: CC=1000-PC = 919.14

CONDICIÓN DEL PAVIMENTO: CONDICIÓN BUENO

Tipo de conservacion según calificacion de condición.

RECONSTRUCCION - REHABILITACION			CONSERVACION PERIODICA CONSERVACION					ON RUTINARIA	
100	200	300	400	500	600	700	800	900	1000

TIPO DE INTERVENCION SEGÚN C. CONDICION:

CONSERVACION RUTINARIA

Anexo E: Cálculo de condición mediante la metodología de visión artificial (PAVEMAI)

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:00:05	hasta	00:00:40
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañíaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:25:17		
Progresiva:	183+000 - 182+800	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	0.00	0.00	0.00	0.00
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	25.00	31.05	1.24	4.85
4.00	FS_A	Fisura alto	Alto	0.00	0.00	0.00	0.00
5.00	DC_B	Descascaramiento bajo	Bajo	0.00	0.00	0.00	0.00
6.00	DC_A	Descascaramiento alto	Alto	1.00	1.05	1.05	0.16
7.00	BCH_B	Bache bajo	Bajo	12.00	1.19	0.10	0.19
8.00	BCH_A	Bache alto	Alto	6.00	10.80	1.80	1.69
9.00	PCH	Parche	N/A	3.00	17.97	5.99	2.81

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	0.00	0.00	0.00
Fisuras	2.43	9.71	4.50
Descascaramiento	0.16	0.33	0.15
Baches	18.00	200.00	92.74
Parches	2.81	5.62	2.60

RESULTADOS FINALES

Suma Total de PC:	215.66
Calificación de Condición (CC):	784.34
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:00:40	hasta	00:01:18
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:25:17		
Progresiva:	182+800 - 182+600	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	5.00	21.91	4.38	3.42
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	38.00	61.13	1.61	9.55
4.00	FS_A	Fisura alto	Alto	1.00	2.53	2.53	0.40
5.00	DC_B	Descascaramiento bajo	Bajo	0.00	0.00	0.00	0.00
6.00	DC_A	Descascaramiento alto	Alto	5.00	6.56	1.31	1.02
7.00	BCH_B	Bache bajo	Bajo	22.00	4.13	0.19	0.65
8.00	BCH_A	Bache alto	Alto	37.00	75.07	2.03	11.73
9.00	PCH	Parche	N/A	1.00	8.50	8.50	1.33

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.71	6.85	2.98
Fisuras	4.60	18.42	8.01
Descascaramiento	1.02	2.05	0.89
Baches	59.00	200.00	86.96
Parches	1.33	2.66	1.16

RESULTADOS FINALES

Suma Total de PC:	229.98
Calificación de Condición (CC):	770.02
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:01:18	hasta	00:01:57
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:25:17		
Progresiva:	182+600 - 182+400	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	1.00	2.60	2.60	0.41
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	15.00	27.17	1.81	4.25
4.00	FS_A	Fisura alto	Alto	1.00	0.05	0.05	0.01
5.00	DC_B	Descascaramiento bajo	Bajo	6.00	0.73	0.12	0.11
6.00	DC_A	Descascaramiento alto	Alto	0.00	0.00	0.00	0.00
7.00	BCH_B	Bache bajo	Bajo	23.00	4.07	0.18	0.64
8.00	BCH_A	Bache alto	Alto	8.00	13.54	1.69	2.12
9.00	PCH	Parche	N/A	3.00	3.74	1.25	0.58

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	0.20	0.81	0.39
Fisuras	2.12	8.48	4.03
Descascaramiento	0.06	0.11	0.05
Baches	31.00	200.00	94.98
Parques	0.58	1.17	0.55

RESULTADOS FINALES

Suma Total de PC:	210.58
Calificación de Condición (CC):	789.42
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:01:57	hasta	00:02:37
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:25:17		
Progresiva:	182+400 - 182+200	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	1.00	5.36	5.36	0.84
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	17.00	11.19	0.66	1.75
4.00	FS_A	Fisura alto	Alto	0.00	0.00	0.00	0.00
5.00	DC_B	Descascaramiento bajo	Bajo	0.00	0.00	0.00	0.00
6.00	DC_A	Descascaramiento alto	Alto	3.00	7.28	2.43	1.14
7.00	BCH_B	Bache bajo	Bajo	14.00	2.70	0.19	0.42
8.00	BCH_A	Bache alto	Alto	22.00	35.15	1.60	5.49
9.00	PCH	Parche	N/A	7.00	17.91	2.56	2.80

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	0.42	1.68	0.79
Fisuras	0.87	3.50	1.64
Descascaramiento	1.14	2.28	1.07
Baches	36.00	200.00	93.87
Parches	2.80	5.60	2.63

RESULTADOS FINALES

Suma Total de PC:	213.05
Calificación de Condición (CC):	786.95
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:02:37	hasta	00:03:10
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:25:17		
Progresiva:	182+200 - 182+000	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	7.00	26.75	3.82	4.18
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	44.00	33.22	0.76	5.19
4.00	FS_A	Fisura alto	Alto	2.00	1.12	0.56	0.18
5.00	DC_B	Descascaramiento bajo	Bajo	21.00	1.98	0.09	0.31
6.00	DC_A	Descascaramiento alto	Alto	11.00	8.44	0.77	1.32
7.00	BCH_B	Bache bajo	Bajo	37.00	6.03	0.16	0.94
8.00	BCH_A	Bache alto	Alto	14.00	17.50	1.25	2.73
9.00	PCH	Parche	N/A	2.00	2.74	1.37	0.43

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	2.09	8.36	3.78
Fisuras	2.52	10.07	4.55
Descascaramiento	1.10	2.20	0.99
Baches	51.00	200.00	90.30
Parches	0.43	0.86	0.39

RESULTADOS FINALES

Suma Total de PC:	221.49
Calificación de Condición (CC):	778.51
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:03:10	hasta	00:03:45
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:40:43		
Progresiva:	182+000 - 181+800	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	5.00	17.57	3.51	2.74
2.00	PC_A	Piel de cocodrilo alto	Alto	1.00	2.21	2.21	0.35
3.00	FS_B	Fisura bajo	Bajo	42.00	47.12	1.12	7.36
4.00	FS_A	Fisura alto	Alto	10.00	16.52	1.65	2.58
5.00	DC_B	Descascaramiento bajo	Bajo	8.00	1.01	0.13	0.16
6.00	DC_A	Descascaramiento alto	Alto	8.00	11.74	1.47	1.83
7.00	BCH_B	Bache bajo	Bajo	31.00	6.96	0.22	1.09
8.00	BCH_A	Bache alto	Alto	28.00	59.81	2.14	9.35
9.00	PCH	Parche	N/A	1.00	3.35	3.35	0.52

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.26	5.03	2.26
Fisuras	3.40	13.59	6.09
Descascaramiento	1.69	3.39	1.52
Baches	59.00	200.00	89.66
Parches	0.52	1.05	0.47

RESULTADOS FINALES

Suma Total de PC:	223.06
Calificación de Condición (CC):	776.94
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:03:45	hasta	00:04:18
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:40:43		
Progresiva:	181+800 - 181+600	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	6.00	14.26	2.38	2.23
2.00	PC_A	Piel de cocodrilo alto	Alto	1.00	4.03	4.03	0.63
3.00	FS_B	Fisura bajo	Bajo	40.00	35.85	0.90	5.60
4.00	FS_A	Fisura alto	Alto	6.00	18.17	3.03	2.84
5.00	DC_B	Descascaramiento bajo	Bajo	19.00	1.42	0.07	0.22
6.00	DC_A	Descascaramiento alto	Alto	7.00	9.72	1.39	1.52
7.00	BCH_B	Bache bajo	Bajo	46.00	7.62	0.17	1.19
8.00	BCH_A	Bache alto	Alto	24.00	38.74	1.61	6.05
9.00	PCH	Parche	N/A	1.00	3.48	3.48	0.54

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.01	4.03	1.84
Fisuras	2.81	11.26	5.14
Descascaramiento	1.34	2.68	1.22
Baches	70.00	200.00	91.30
Parches	0.54	1.09	0.50

RESULTADOS FINALES

Suma Total de PC:	219.06
Calificación de Condición (CC):	780.94
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:04:18	hasta	00:04:49
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:40:43		
Progresiva:	181+600 - 181+400	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	1.00	3.05	3.05	0.48
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	4.00	3.13	0.78	0.49
4.00	FS_A	Fisura alto	Alto	9.00	2.57	0.29	0.40
5.00	DC_B	Descascaramiento bajo	Bajo	1.00	0.06	0.06	0.01
6.00	DC_A	Descascaramiento alto	Alto	1.00	1.03	1.03	0.16
7.00	BCH_B	Bache bajo	Bajo	2.00	0.64	0.32	0.10
8.00	BCH_A	Bache alto	Alto	12.00	26.98	2.25	4.22
9.00	PCH	Parche	N/A	2.00	2.41	1.20	0.38

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	0.24	0.95	0.47
Fisuras	0.32	1.26	0.62
Descascaramiento	0.15	0.31	0.15
Baches	14.00	200.00	98.39
Parques	0.38	0.75	0.37

RESULTADOS FINALES

Suma Total de PC:	203.28
Calificación de Condición (CC):	796.72
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:04:49	hasta	00:05:18
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:40:43		
Progresiva:	181+400 - 181+200	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	6.00	19.81	3.30	3.10
2.00	PC_A	Piel de cocodrilo alto	Alto	1.00	0.85	0.85	0.13
3.00	FS_B	Fisura bajo	Bajo	25.00	19.56	0.78	3.06
4.00	FS_A	Fisura alto	Alto	2.00	0.69	0.34	0.11
5.00	DC_B	Descascaramiento bajo	Bajo	27.00	2.62	0.10	0.41
6.00	DC_A	Descascaramiento alto	Alto	3.00	2.76	0.92	0.43
7.00	BCH_B	Bache bajo	Bajo	37.00	4.72	0.13	0.74
8.00	BCH_A	Bache alto	Alto	11.00	12.90	1.17	2.02
9.00	PCH	Parche	N/A	2.00	7.34	3.67	1.15

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.49	5.96	2.78
Fisuras	1.48	5.92	2.76
Descascaramiento	0.32	0.64	0.30
Baches	48.00	200.00	93.10
Parches	1.15	2.30	1.07

RESULTADOS FINALES

Suma Total de PC:	214.82
Calificación de Condición (CC):	785.18
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:05:18	hasta	00:05:49
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 22:40:43		
Progresiva:	181+200 - 181+000	Sentido:	Retorno (resta)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	4.00	14.58	3.64	2.28
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	23.00	20.02	0.87	3.13
4.00	FS_A	Fisura alto	Alto	1.00	1.01	1.01	0.16
5.00	DC_B	Descascaramiento bajo	Bajo	23.00	2.21	0.10	0.35
6.00	DC_A	Descascaramiento alto	Alto	8.00	6.05	0.76	0.95
7.00	BCH_B	Bache bajo	Bajo	56.00	9.24	0.16	1.44
8.00	BCH_A	Bache alto	Alto	22.00	14.89	0.68	2.33
9.00	PCH	Parche	N/A	1.00	7.59	7.59	1.19

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.14	4.56	2.13
Fisuras	1.50	5.99	2.79
Descascaramiento	0.74	1.48	0.69
Baches	78.00	200.00	93.28
Parches	1.19	2.37	1.11

RESULTADOS FINALES

Suma Total de PC:	214.40
Calificación de Condición (CC):	785.60
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:08:24	hasta	00:09:00
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:00:45		
Progresiva:	181+000 - 181+200	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	7.00	28.57	4.08	4.46
2.00	PC_A	Piel de cocodrilo alto	Alto	1.00	4.00	4.00	0.63
3.00	FS_B	Fisura bajo	Bajo	25.00	30.75	1.23	4.80
4.00	FS_A	Fisura alto	Alto	2.00	0.93	0.47	0.15
5.00	DC_B	Descascaramiento bajo	Bajo	19.00	1.70	0.09	0.27
6.00	DC_A	Descascaramiento alto	Alto	3.00	7.28	2.43	1.14
7.00	BCH_B	Bache bajo	Bajo	91.00	18.59	0.20	2.91
8.00	BCH_A	Bache alto	Alto	34.00	35.09	1.03	5.48
9.00	PCH	Parche	N/A	2.00	10.65	5.33	1.66

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	2.03	8.14	3.66
Fisuras	2.34	9.35	4.20
Descascaramiento	0.95	1.89	0.85
Baches	125.00	200.00	89.80
Parques	1.66	3.33	1.50

RESULTADOS FINALES

Suma Total de PC:	222.72
Calificación de Condición (CC):	777.28
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:09:00	hasta	00:09:32
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:00:45		
Progresiva:	181+200 - 181+400	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	8.00	23.35	2.92	3.65
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	20.00	19.26	0.96	3.01
4.00	FS_A	Fisura alto	Alto	1.00	0.74	0.74	0.12
5.00	DC_B	Descascaramiento bajo	Bajo	9.00	1.37	0.15	0.21
6.00	DC_A	Descascaramiento alto	Alto	2.00	4.29	2.15	0.67
7.00	BCH_B	Bache bajo	Bajo	54.00	9.79	0.18	1.53
8.00	BCH_A	Bache alto	Alto	22.00	26.14	1.19	4.08
9.00	PCH	Parche	N/A	1.00	1.27	1.27	0.20

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.82	7.30	3.40
Fisuras	1.45	5.82	2.71
Descascaramiento	0.53	1.07	0.50
Baches	76.00	200.00	93.20
Parches	0.20	0.40	0.18

RESULTADOS FINALES

Suma Total de PC:	214.58
Calificación de Condición (CC):	785.42
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:09:32	hasta	00:10:05
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:00:45		
Progresiva:	181+400 - 181+600	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	1.00	2.92	2.92	0.46
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	10.00	8.59	0.86	1.34
4.00	FS_A	Fisura alto	Alto	15.00	3.29	0.22	0.51
5.00	DC_B	Descascaramiento bajo	Bajo	6.00	0.63	0.11	0.10
6.00	DC_A	Descascaramiento alto	Alto	3.00	5.02	1.67	0.78
7.00	BCH_B	Bache bajo	Bajo	21.00	3.86	0.18	0.60
8.00	BCH_A	Bache alto	Alto	11.00	17.60	1.60	2.75
9.00	PCH	Parche	N/A	0.00	0.00	0.00	0.00

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	0.23	0.91	0.45
Fisuras	0.63	2.51	1.23
Descascaramiento	0.70	1.41	0.69
Baches	32.00	200.00	97.64
Parches	0.00	0.00	0.00

RESULTADOS FINALES

Suma Total de PC:	204.83
Calificación de Condición (CC):	795.17
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:10:05	hasta	00:10:41
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:00:45		
Progresiva:	181+600 - 181+800	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	7.00	14.11	2.02	2.20
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	33.00	51.83	1.57	8.10
4.00	FS_A	Fisura alto	Alto	15.00	12.15	0.81	1.90
5.00	DC_B	Descascaramiento bajo	Bajo	14.00	1.50	0.11	0.23
6.00	DC_A	Descascaramiento alto	Alto	6.00	4.85	0.81	0.76
7.00	BCH_B	Bache bajo	Bajo	73.00	13.72	0.19	2.14
8.00	BCH_A	Bache alto	Alto	32.00	56.73	1.77	8.86
9.00	PCH	Parche	N/A	3.00	4.08	1.36	0.64

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.10	4.41	1.99
Fisuras	3.64	14.57	6.58
Descascaramiento	0.61	1.21	0.55
Baches	105.00	200.00	90.30
Parches	0.64	1.27	0.58

RESULTADOS FINALES

Suma Total de PC:	221.48
Calificación de Condición (CC):	778.52
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:10:41	hasta	00:11:15
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:00:45		
Progresiva:	181+800 - 182+000	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	8.00	21.49	2.69	3.36
2.00	PC_A	Piel de cocodrilo alto	Alto	1.00	0.83	0.83	0.13
3.00	FS_B	Fisura bajo	Bajo	32.00	35.81	1.12	5.60
4.00	FS_A	Fisura alto	Alto	22.00	10.38	0.47	1.62
5.00	DC_B	Descascaramiento bajo	Bajo	8.00	0.82	0.10	0.13
6.00	DC_A	Descascaramiento alto	Alto	5.00	5.54	1.11	0.87
7.00	BCH_B	Bache bajo	Bajo	59.00	14.59	0.25	2.28
8.00	BCH_A	Bache alto	Alto	37.00	62.00	1.68	9.69
9.00	PCH	Parche	N/A	1.00	2.89	2.89	0.45

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.62	6.49	2.96
Fisuras	2.53	10.14	4.63
Descascaramiento	0.76	1.52	0.70
Baches	96.00	200.00	91.30
Parches	0.45	0.90	0.41

RESULTADOS FINALES

Suma Total de PC:	219.06
Calificación de Condición (CC):	780.94
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:11:15	hasta	00:11:49
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:16:39		
Progresiva:	182+000 - 182+200	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	8.00	21.36	2.67	3.34
2.00	PC_A	Piel de cocodrilo alto	Alto	3.00	8.04	2.68	1.26
3.00	FS_B	Fisura bajo	Bajo	33.00	49.74	1.51	7.77
4.00	FS_A	Fisura alto	Alto	5.00	1.80	0.36	0.28
5.00	DC_B	Descascaramiento bajo	Bajo	23.00	3.66	0.16	0.57
6.00	DC_A	Descascaramiento alto	Alto	1.00	2.27	2.27	0.35
7.00	BCH_B	Bache bajo	Bajo	33.00	5.18	0.16	0.81
8.00	BCH_A	Bache alto	Alto	11.00	25.34	2.30	3.96
9.00	PCH	Parche	N/A	3.00	5.45	1.82	0.85

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.56	6.23	2.79
Fisuras	3.76	15.05	6.73
Descascaramiento	0.31	0.63	0.28
Baches	44.00	200.00	89.44
Parches	0.85	1.70	0.76

RESULTADOS FINALES

Suma Total de PC:	223.61
Calificación de Condición (CC):	776.39
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:11:49	hasta	00:12:28
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:16:39		
Progresiva:	182+200 - 182+400	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	5.00	9.25	1.85	1.45
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	11.00	11.07	1.01	1.73
4.00	FS_A	Fisura alto	Alto	6.00	0.99	0.17	0.15
5.00	DC_B	Descascaramiento bajo	Bajo	8.00	1.02	0.13	0.16
6.00	DC_A	Descascaramiento alto	Alto	0.00	0.00	0.00	0.00
7.00	BCH_B	Bache bajo	Bajo	35.00	8.90	0.25	1.39
8.00	BCH_A	Bache alto	Alto	14.00	22.71	1.62	3.55
9.00	PCH	Parche	N/A	5.00	10.54	2.11	1.65

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	0.72	2.89	1.38
Fisuras	0.81	3.23	1.54
Descascaramiento	0.08	0.16	0.08
Baches	49.00	200.00	95.43
Parches	1.65	3.30	1.57

RESULTADOS FINALES

Suma Total de PC:	209.58
Calificación de Condición (CC):	790.42
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:12:28	hasta	00:13:06
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:16:39		
Progresiva:	182+400 - 182+600	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	4.00	18.08	4.52	2.83
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	16.00	22.69	1.42	3.55
4.00	FS_A	Fisura alto	Alto	0.00	0.00	0.00	0.00
5.00	DC_B	Descascaramiento bajo	Bajo	3.00	0.64	0.21	0.10
6.00	DC_A	Descascaramiento alto	Alto	0.00	0.00	0.00	0.00
7.00	BCH_B	Bache bajo	Bajo	9.00	1.79	0.20	0.28
8.00	BCH_A	Bache alto	Alto	7.00	29.97	4.28	4.68
9.00	PCH	Parche	N/A	3.00	6.18	2.06	0.97

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.41	5.65	2.63
Fisuras	1.77	7.10	3.30
Descascaramiento	0.05	0.10	0.05
Baches	16.00	200.00	93.12
Parches	0.97	1.93	0.90

RESULTADOS FINALES

Suma Total de PC:	214.79
Calificación de Condición (CC):	785.21
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:13:06	hasta	00:13:42
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:16:39		
Progresiva:	182+600 - 182+800	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	3.00	7.93	2.64	1.24
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	26.00	27.97	1.08	4.37
4.00	FS_A	Fisura alto	Alto	6.00	6.61	1.10	1.03
5.00	DC_B	Descascaramiento bajo	Bajo	2.00	0.16	0.08	0.02
6.00	DC_A	Descascaramiento alto	Alto	2.00	1.69	0.84	0.26
7.00	BCH_B	Bache bajo	Bajo	25.00	6.02	0.24	0.94
8.00	BCH_A	Bache alto	Alto	19.00	58.74	3.09	9.18
9.00	PCH	Parche	N/A	1.00	1.74	1.74	0.27

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	0.62	2.48	1.17
Fisuras	1.97	7.87	3.72
Descascaramiento	0.24	0.48	0.23
Baches	44.00	200.00	94.62
Parches	0.27	0.55	0.26

RESULTADOS FINALES

Suma Total de PC:	211.38
Calificación de Condición (CC):	788.62
Clasificación del Pavimento:	REGULAR

REPORTE DE EVALUACIÓN DE PAVIMENTO

Intervalo de tiempo:	00:13:42	hasta	00:14:11
----------------------	----------	-------	----------

INFORMACIÓN GENERAL

Video Analizado:	compañiaVAL.mp4		
Fecha de Evaluación:	2025-04-15 23:16:39		
Progresiva:	182+800 - 183+000	Sentido:	Ida (suma)
Ancho de Carril:	3.2 m	Longitud de Intervalo:	200.0 m
Área Total:	640.00 m ²		

DETECCIÓN DE FALLAS

Nº	Código	Tipo de Falla	Severidad	Cantidad	Área (m ²)	Área Promedio (m ²)	% del Área Total
1.00	PC_B	Piel de cocodrilo bajo	Bajo	3.00	13.86	4.62	2.16
2.00	PC_A	Piel de cocodrilo alto	Alto	0.00	0.00	0.00	0.00
3.00	FS_B	Fisura bajo	Bajo	19.00	37.80	1.99	5.91
4.00	FS_A	Fisura alto	Alto	1.00	10.47	10.47	1.64
5.00	DC_B	Descascaramiento bajo	Bajo	0.00	0.00	0.00	0.00
6.00	DC_A	Descascaramiento alto	Alto	1.00	1.66	1.66	0.26
7.00	BCH_B	Bache bajo	Bajo	5.00	0.61	0.12	0.10
8.00	BCH_A	Bache alto	Alto	2.00	4.03	2.01	0.63
9.00	PCH	Parche	N/A	3.00	9.00	3.00	1.41

EVALUACIÓN DE CONDICIÓN

Tipo de Falla	EFP	PC	Contribución al PC Total (%)
Piel de Cocodrilo	1.08	4.33	3.13
Fisuras	2.67	10.68	7.72
Descascaramiento	0.26	0.52	0.38
Baches	7.00	120.00	86.74
Parches	1.41	2.81	2.03

RESULTADOS FINALES

Suma Total de PC:	138.34
Calificación de Condición (CC):	861.66
Clasificación del Pavimento:	BUENO



UNSCH

FACULTAD DE
INGENIERÍA
DE MINAS, GEOLOGÍA Y CIVIL

ACTA DE SUSTENTACIÓN DE TESIS N° 017-2025-FIMGC

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO CIVIL

En la Universidad Nacional de San Cristóbal de Huamanga, en la ciudad de Ayacucho, en cumplimiento a la **Resolución Decanal N° 134-2025-FIMGC-D**, a los **veintitrés días del mes de junio de 2025**, siendo las **10:00 a.m.**, reunidos en el **Auditorio de la Escuela Profesional de Ingeniería Civil**, bajo la presidencia del **Mg. Ing. José Ernesto ESTRADA CÁRDENAS**, y los miembros: **MSc. Ing. Edmundo CANCHARI GUTIERREZ**, **Dr. Ing. Hemerson LIZARBE ALARCON** y **Mg. Ing. Rocky Giban AYALA BIZARRO**, actuando como secretario docente el **MSc. Ing. Saul Walter RETAMOZO FERNÁNDEZ**, para proceder a la sustentación de tesis para optar el **Título Profesional de Ingeniero Civil**, del bachiller en Ciencias de la Ingeniería Civil:

JHON ARNOLD TORRES GASTELU

Quien presentó la tesis denominada:

“IMPLEMENTACIÓN DE UN MÉTODO MEDIANTE VISIÓN ARTIFICIAL PARA LA EVALUACIÓN DEL ESTADO DE CONSERVACIÓN SUPERFICIAL DE PAVIMENTOS FLEXIBLES, AYACUCHO 2024”

Los señores miembros del jurado luego de expuesta la tesis y absueltas las preguntas, deliberaron y declararon:

Aprobado con diecisiete (17)

Siendo las **11:30 a.m.** del día **23 de junio del 2025**, culmina el acto de sustentación de tesis, y en conformidad lo actuado los miembros del jurado firmamos al pie del presente.

Mg. Ing. José Ernesto ESTRADA CÁRDENAS
Presidente

MSc. Ing. Edmundo CANCHARI GUTIERREZ
Miembro

Dr. Ing. Hemerson LIZARBE ALARCON
Miembro
Mg. Ing. Rocky Giban AYALA BIZARRO
Miembro - Asesor
MSc. Ing. Saul Walter RETAMOZO
FERNÁNDEZ
Secretario docente de la FIMGC

FACULTAD DE INGENIERÍA
DE MINAS Y CIVIL
Av. Independencia S/N
Ciudad Universitaria
Central Tel. 066 312510
Anexo 151



CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 013-2025-FIMGC/ASIH

El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado con el software Turnitin, de la Escuelas Profesional de **Ingeniería Civil** de la **Facultad de Ingeniería de Minas, Geología y Civil**; en cumplimiento a la **Resolución de Consejo Universitario N° 039-2021-UNSCH-CU**, Reglamento de Originalidad de Trabajos de Investigación de la Universidad Nacional San Cristóbal de Huamanga y **Resolución Decanal N° 697-2024-FIMGC-UNSCH-D**, dejo constancia de originalidad de trabajo de investigación, que el/la Sr./Srta.

Apellidos y Nombres : JHON ARNOLD TORRES GASTELU
Escuela Profesional : INGENIERÍA CIVIL
Título de la Tesis : "IMPLEMENTACIÓN DE UN MÉTODO MEDIANTE VISIÓN ARTIFICIAL PARA LA EVALUACIÓN DEL ESTADO DE CONSERVACIÓN SUPERFICIAL DE PAVIMENTOS FLEXIBLES, AYACUCHO 2024"
Evaluación de la Originalidad : 14 % Índice de Similitud
Identificador de la entrega : 2739543715

Por tanto, según los Artículos 12, 13 y 17 del Reglamento de Originalidad de Trabajos de Investigación, es **PROCEDENTE** otorgar la **Constancia de Originalidad** para los fines que crea conveniente.

En señal de conformidad y verificación se firma la presente constancia

Ayacucho, 1 de setiembre del 2025



UNIVERSIDAD NACIONAL DE
SAN CRISTÓBAL DE HUAMANGA
Facultad de Ingeniería de Minas, Geología y Civil

Mg. Ing. Alex Sander IRCAÑAUPA HUAMANI
Verificador de Originalidad de Trabajos de Tesis de Pregrado
Escuela de Formación Profesional de Ingeniería Civil

“IMPLEMENTACIÓN DE UN MÉTODO MEDIANTE VISIÓN ARTIFICIAL PARA LA EVALUACIÓN DEL ESTADO DE CONSERVACIÓN SUPERFICIAL DE PAVIMENTOS FLEXIBLES, AYACUCHO 2024”

por Jhon Arnold Torres Gastelu

Fecha de entrega: 01-sept-2025 09:45a. m. (UTC-0500)

Identificador de la entrega: 2739543715

Nombre del archivo: Te_Jhon_Arnold_Torres_Gastelu.pdf (3.3M)

Total de palabras: 58193

Total de caracteres: 291854

"IMPLEMENTACIÓN DE UN MÉTODO MEDIANTE VISIÓN ARTIFICIAL PARA LA EVALUACIÓN DEL ESTADO DE CONSERVACIÓN SUPERFICIAL DE PAVIMENTOS FLEXIBLES, AYACUCHO 2024"

INFORME DE ORIGINALIDAD

14%

INDICE DE SIMILITUD

14%

FUENTES DE INTERNET

1%

PUBLICACIONES

8%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1

repositorio.ucv.edu.pe

Fuente de Internet

2%

2

Submitted to uncedu

Trabajo del estudiante

2%

3

hdl.handle.net

Fuente de Internet

1%

4

repositorio.unap.edu.pe

Fuente de Internet

1%

5

repositorio.unsaac.edu.pe

Fuente de Internet

1%

6

repositorio.urp.edu.pe

Fuente de Internet

1%

7

Submitted to Universidad Nacional de San Cristóbal de Huamanga

Trabajo del estudiante

1%

8

Submitted to Universidad Cesar Vallejo

Trabajo del estudiante

1%

9

repositorio.unab.edu.pe

Fuente de Internet

<1%

10

repositorio.unj.edu.pe

Fuente de Internet

<1%

11

repositorio.upn.edu.pe

Fuente de Internet

<1%

12

repositorio.upla.edu.pe

Fuente de Internet

<1%

13

alicia.concytec.gob.pe

Fuente de Internet

<1%

Submitted to unasam

14	Trabajo del estudiante	<1 %
15	repositoriotec.tec.ac.cr Fuente de Internet	<1 %
16	repository.unimilitar.edu.co Fuente de Internet	<1 %
17	repositorio.unh.edu.pe Fuente de Internet	<1 %
18	dspace.unitru.edu.pe Fuente de Internet	<1 %
19	Submitted to University of Wales central institutions Trabajo del estudiante	<1 %
20	repositorio.unasam.edu.pe Fuente de Internet	<1 %
21	masterieg.uc.cl Fuente de Internet	<1 %
22	Submitted to Universidad de Málaga - Tii Trabajo del estudiante	<1 %
23	repositorio.upt.edu.pe Fuente de Internet	<1 %
24	Submitted to tec Trabajo del estudiante	<1 %
25	idoc.pub Fuente de Internet	<1 %
26	Submitted to Universidad Alas Peruanas Trabajo del estudiante	<1 %
27	Submitted to Universidad Anahuac México Sur Trabajo del estudiante	<1 %
28	repositorio.esan.edu.pe Fuente de Internet	<1 %
29	cybertesis.uni.edu.pe Fuente de Internet	<1 %
30	repositorio.ulasamericas.edu.pe Fuente de Internet	<1 %

31	Submitted to Universidad Católica de Santa María Trabajo del estudiante	<1 %
32	Submitted to Universidad de Alcalá Trabajo del estudiante	<1 %
33	Submitted to University of Anbar Trabajo del estudiante	<1 %
34	portal.mtc.gob.pe Fuente de Internet	<1 %
35	repositorio.uchile.cl Fuente de Internet	<1 %
36	Submitted to Consorcio CIXUG Trabajo del estudiante	<1 %
37	Submitted to Universitat Politècnica de València Trabajo del estudiante	<1 %
38	uvadoc.uva.es Fuente de Internet	<1 %
39	www.risti.xyz Fuente de Internet	<1 %
40	Submitted to Webster University Trabajo del estudiante	<1 %
41	Ruiz Gallardo, Jose Reyes. "Remote sensing and GIS assistance in post-fire intervention", Proquest, 20111109 Publicación	<1 %

Excluir citas

Activo

Excluir coincidencias < 30 words

Excluir bibliografía

Activo