



UNIVERSIDAD CÉSAR VALLEJO

FACULTAD DE INGENIERÍA Y ARQUITECTURA

ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

Aplicación de Deep Learning para la detección de anomalías en pavimento en una zona del distrito de “Socabaya”, Arequipa 2024.

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:

Ingeniero de Sistemas

AUTORES:

Chino Mestas, Jose Rodolfo (orcid.org/0009-0000-4198-9554)

Inchicsana Huamani, Peter Junior (orcid.org/0000-0002-2796-7655)

ASESOR:

Mg. Barrientos Ynfante, Marco Antonio (orcid.org/0000-0001-9886-7267)

LÍNEA DE INVESTIGACIÓN:

Sistemas de Información y Comunicaciones

LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:

Desarrollo económico, empleo y emprendimiento

LIMA – PERÚ

2024

Dedicatoria

Dedico mi tesis principalmente a Dios, por guiarme por buen camino para culminar esta meta de sacar mi título profesional.

A mis padres, por todo su amor y por motivarme a seguir hacia adelante.

También a mi hermana, por brindarme su apoyo moral en esas noches que tocaba investigar.

Y, finalmente, a los que no creyeron en mí, con su actitud lograron que tomará más impulso.

Dedico esta investigación principalmente a Dios, por guiarme por buen camino para culminar esta meta de sacar mi Título profesional.

A mis padres, por todo su amor y por motivarme a seguir hacia adelante.

También a mi hermana, por brindarme su apoyo moral en esas noches que tocaba investigar.

Y, finalmente, a los que no creyeron en mí, con su actitud lograron que tomará más impulso.

Agradecimiento

Dar Gracias a mis padres, por su amor incondicional y su apoyo moral, incluso en los momentos más difíciles, ha sido el pilar de este logro. También expreso mi gratitud a mi hermana, quienes supieron brindarme su tiempo para escucharme y apoyarme. Sin ustedes, todo esto no habría sido posible. Su amor y sacrificio han sido la luz que guio mi camino a través de este viaje académico.

FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

Declaratoria de Autenticidad del Asesor

Yo, BARRIENTOS YNFANTE MARCO ANTONIO, docente de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA ATE, asesor de Tesis titulada: "Aplicación de Deep Learning para la detección de anomalías en pavimento en una zona del distrito de "Socabaya", Arequipa 2024.", cuyos autores son INCHICSANA HUAMANI PETER JUNIOR, CHINO MESTAS JOSE RODOLFO, constato que la investigación tiene un índice de similitud de 18%, verificable en el reporte de originalidad del programa Turnitin, el cual ha sido realizado sin filtros, ni exclusiones.

He revisado dicho reporte y concluyo que cada una de las coincidencias detectadas no constituyen plagio. A mi leal saber y entender la Tesis cumple con todas las normas para el uso de citas y referencias establecidas por la Universidad César Vallejo.

En tal sentido, asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

LIMA, 30 de Julio del 2024

Apellidos y Nombres del Asesor:	Firma
BARRIENTOS YNFANTE MARCO ANTONIO DNI: 44185249 ORCID: 0000-0001-9886-7267	Firmado electrónicamente por: BARRIENTOS el 30- 07-2024 11:28:53

Código documento Trilce: TRI – 0838737

FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

Declaratoria de Originalidad de los Autores

Nosotros, INCHICSANA HUAMANI PETER JUNIOR, CHINO MESTAS JOSE RODOLFO estudiantes de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA ATE, declaramos bajo juramento que todos los datos e información que acompaña la Tesis titulada: "Aplicación de Deep Learning para la detección de anomalías en pavimento en una zona del distrito de "Socabaya", Arequipa 2024.", es de nuestra autoría, por lo tanto, declaramos que la Tesis:

1. No ha sido plagiada ni total, ni parcialmente.
2. Hemos mencionado todas las fuentes empleadas, identificando correctamente toda cita textual o de paráfrasis proveniente de otras fuentes.
3. No ha sido publicada, ni presentada anteriormente para la obtención de otro grado académico o título profesional.
4. Los datos presentados en los resultados no han sido falseados, ni duplicados, ni copiados.

En tal sentido asumimos la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de la información aportada, por lo cual nos sometemos a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

Nombres y Apellidos	Firma
JOSE RODOLFO CHINO MESTAS DNI: 74999291 ORCID: 0009-0000-4198-9554	Firmado electrónicamente por: JOCHINOME el 30-07-2024 15:36:18
PETER JUNIOR INCHICSANA HUAMANI DNI: 43124211 ORCID: 0000-0002-2796-7655	Firmado electrónicamente por: PEINCHICSANAHU el 30-07-2024 15:31:19

Código documento Trilce: TRI – 0838738

Índice de contenidos

Carátula.....	i
Dedicatoria	ii
Agradecimiento	iii
Declaratoria de Autenticidad del Asesor.....	iv
Declaratoria de Originalidad de los Autores.....	v
Índice de contenidos	vi
Índice de tablas	vii
Índice de figuras.....	viii
Resumen.....	x
Abstract.....	xi
I. INTRODUCCIÓN.....	1
II. MARCO TEÓRICO	4
III. METODOLOGÍA.....	10
3.1. Tipo y diseño de investigación	10
3.2. Variable y operacionalización.....	11
3.3. Población, muestra y muestreo.....	11
3.4. Técnicas e instrumentos de recolección de datos.....	14
3.5. Procedimientos	15
3.6. Metodología de análisis de datos.....	17
3.7. Aspectos éticos	18
IV. RESULTADOS	19
V. DISCUSIÓN.....	31
VI. CONCLUSIONES	32
VII. RECOMENDACIONES.....	34
REFERENCIAS.....	37
ANEXOS	42

Índice de tablas

Tabla 1. Principales Calles de la zona de San Martin de Socabaya	12
Tabla 2: Conjunto de imágenes que representa la dataset.	23
Tabla 3:Análisis de resultado	26
Tabla 4:Histograma de la detección de tipos de clases (grietas y hueco) en 30 imágenes, donde:	26
Tabla 5: Histograma de confianza	27
Tabla 6: Elaboración propia tipo de métricas	27
Tabla 7: Matriz de confusión	85
Tabla 8: Característica Operativa del Recepto (ROC) general de las dimensiones de grietas y huecos	85
Tabla 9: Curva ROC para mediciones de grietas y huecos.....	29
Tabla 10: Precisión de la curva del ROC bajo la sensibilidad o recall.....	86
Tabla 11: Indicador del Accuracy	87
Tabla 12: Registro estadístico de imágenes de pavimentos en el distrito de Socabaya	69
Tabla 13: Ficha de registro de las características de las clases de grietas y huecos	69

Índice de Figuras

Ilustración 1: Inteligencia artificial.....	51
Ilustración 2: Adaptación de las redes neuronales	52
Ilustración 3: Estructura U-net CNN	53
Ilustración 4: RNN Red Neuronal Recurrente.....	54
Ilustración 5: Estructura de red neuronal convolucional multicapas	55
Ilustración 6: Arquitectura de red neuronal convolucional	56
Ilustración 7: Diagrama de flujo de la captura de imagen.....	57
Ilustración 8: Instalación de la arquitectura YOLOv5.....	59
Ilustración 9: Proceso de entrenamiento	60
Ilustración 10: Precisión, recuperación y puntuación mAP (Sun et al., 2021)	61
Ilustración 11: Estadísticas de auditoría y registro de resultados.....	62
Ilustración 12: Dataset_classificacionGH AI informar los resultados obtenidos durante el entrenamiento, podemos comprobar la precisión de la detección de grietas y agujeros clasificados por los indicadores 0 y 1.	63
Ilustración 13:Es el resultado de una red neuronal convolucional utilizada para detectar grietas y agujeros en estructuras de carreteras como asfalto o pavimento de hormigón.	64
Ilustración 14: Ilustración que muestra un cuadro de identificación de grietas y agujeros en un pavimento asfáltico.	65
Ilustración 15: Ilustración que muestra un cuadro de identificación de grietas y agujeros en un pavimento asfáltico.	66
Ilustración 16: Lugar de prueba de estudios de captura de imágenes con el teléfono inteligente	67
Ilustración 17: Captura de imágenes con el teléfono inteligente	68
Ilustración 18: Asignación de nombre a las imágenes capturadas.....	70
Ilustración 19: Diagrama de flujo para el diseño del aplicativo denominado	71
Ilustración 20: Diagrama de clases, representa la visualización de las funciones y clases implementadas en el aplicativo	72
Ilustración 21: Diagrama de paquetes.....	73
Ilustración 22: Arquitectura para el desarrollo del sistema inteligente	74

Ilustración 23: Escritura de código de los módulos denominados login.py, ventana_principal.py	75
Ilustración 24: Escritura de código de los módulos denominados camara.py, Detect.py	76
Ilustración 25: Escritura de código de los módulos denominados analizar_image.py	77
Ilustración 26: Listado de librerías instaladas para el funcionamiento del aplicativo	78
Ilustración 27: Interfaz de validación de usuario.....	79
Ilustración 28: Modulo principal del proyecto.....	80
Ilustración 29: Módulo de cámara fotográfica	81
Ilustración 30: Módulo incorporado con git, para listar, configurar archivos del sistema.	82
Ilustración 31: Módulo de activación IA detectando grieta con una precisión de 0.86.	83
Ilustración 32: Módulo de activación IA detectando hueco con una precisión de 0.56.	84

Resumen

La tesis de investigación desarrolla una aplicación móvil que utiliza algoritmos de aprendizaje profundo para analizar en tiempo real las imágenes y datos, con el objetivo de identificar y evaluar el estado de los pavimentos. Ante ello se presenta el objetivo el cual es identificar la, magnitud de la ejecución de una aplicación utilizando técnicas Deep Learning intervienen en la detección de anomalías en el pavimento las condiciones adversas en carreteras y calles, como grietas y baches, generan riesgos y costos de reparación para las autoridades locales. Además, la inspección tradicional es subjetiva, pero el aprendizaje profundo permite detectar y evaluar anomalías de manera precisa y eficiente a través del análisis automático de imágenes y datos no invasivos. de un de las zonas del distrito de Socabaya de la localidad de Arequipa-Perú. redactan que, la detección precisa de problemas en el pavimento es esencial para la seguridad vial y el mantenimiento de infraestructuras urbanas. aplicar estas técnicas para identificar y describir problemas en el pavimento, con el objetivo de mejorar la planificación y el mantenimiento de las carreteras. sino también la seguridad y eficiencia de las carreteras.

Palabras clave: Aprendizaje profundo, inteligencia artificial, Deep Learning, tecnología, red neuronal.

Abstract

The research thesis develops a mobile application that uses deep learning algorithms to analyze in real time images and data, with the aim of identifying and assessing the condition of pavements. The objective is to identify the magnitude of the execution of an application using Deep Learning techniques involved in the detection of pavement anomalies. Adverse conditions in roads and streets, such as cracks and potholes, generate risks and repair costs for local authorities. In addition, traditional inspection is subjective, but deep learning allows to detect and evaluate anomalies accurately and efficiently through the automatic analysis of images and non-invasive data. of one of the areas of the Socabaya district of Arequipa- Peru. They write that, the accurate detection of pavement problems is essential for road safety and maintenance of urban infrastructure. apply these techniques to identify and describe pavement problems, with the aim of improving the planning and maintenance of roads. but also, the safety and efficiency of roads.

Keywords: deep learning, artificial intelligence, deep learning, technology, neural, network.

I. INTRODUCCIÓN

A nivel mundial, según, Shu et al. (2022) describen que, las condiciones adversas en carreteras y calles, como grietas y baches, generan riesgos y costos de reparación para las autoridades locales.

Por otra parte, Chen et al. (2023) mencionan que, en China el estado deficiente de las carreteras resalta la importancia de una infraestructura vial sólida para la sociedad moderna. La necesidad de soluciones innovadoras y sostenibles es urgente con el crecimiento de las ciudades y el enfoque en la movilidad ya que realiza mediante métodos tradicionales.

En otra línea, Nyirandayisabye et al. (2022) redactan que, la detección precisa de problemas en el pavimento es esencial para la seguridad vial y el mantenimiento de infraestructuras urbanas. Deep Learning, se destaca como una herramienta efectiva en este contexto.

A nivel internacional, para Arellano (2020) argumenta que, en México, los datos del INEGI muestran una situación preocupante en cuanto al estado de las vías de transporte. Un 17.3% de estas vías presenta un deterioro significativo, revelando desafíos persistentes en términos de calidad y mantenimiento de la infraestructura vial. Esto no solo afecta la apariencia, sino también la seguridad y eficiencia de las carreteras, vitales para la conectividad y el comercio. El llamado del INEGI destaca la necesidad de acción por parte de las autoridades y responsables de la infraestructura.

En relación con, La República (2019) menciona que, en Colombia, la situación de las vías terciarias supervisadas por el Departamento Nacional de Planeación es preocupante. Estas rutas, que totalizan 142.284 kilómetros, son vitales para la conectividad y el desarrollo rural. Sin embargo, el 45.4% de estas vías está en mal estado y el 36.1% apenas es aceptable. Aunque un 33.5% muestra una condición satisfactoria, esto plantea dudas sobre la calidad general de la red vial.

En el entorno nacional, para INEI (2022) argumenta que, en el estado de los pavimentos y carreteras en Perú puede variar debido a varios factores, como la falta

de mantenimiento, el clima adverso, el tráfico intenso y la calidad de la construcción inicial. Algunos departamentos muestran un aumento en el mal estado de los pavimentos, como Amazonas (13%) y Ancash (6.2%). En contraste, otros departamentos experimentan mejoras, como Cusco (11.3%), Apurímac (-5.9%), y Arequipa (-4.5%). Varios departamentos enfrentan una disminución significativa en la calidad de los pavimentos, como Huancavelica (-21.7%), Huánuco (-22.3%), Loreto (-19.2%), San Martín (-28.4%), y Ucayali (-24.2%).

Se propone desarrollar una aplicación móvil que utilice algoritmos de aprendizaje profundo para analizar en tiempo real imágenes y datos, con el objetivo de identificar y evaluar el estado de los pavimentos.

Ante ello, se presenta la **problemática general** ¿En qué magnitud la ejecución de una aplicación móvil utilizando técnicas de Deep Learning interviene en la detección de anomalías en pavimento de una zona del distrito de “Socabaya”, 2024?, así mismo se presenta la problema específica como: **I)** ¿En qué magnitud la ejecución de una aplicación móvil utilizando Deep Learning interviene en la medición y detección de grietas en pavimento de una zona del distrito de “Socabaya”, 2024?,**II)** ¿En qué magnitud la ejecución de una aplicación móvil utilizando Deep Learning interviene en la medición y detección de desprendimiento de agregados en pavimento de una zona del distrito de “Socabaya”, 2024?, **III)** ¿En qué magnitud la ejecución de una aplicación móvil utilizando Deep Learning interviene en la medición y detección de piel de cocodrilo en pavimento de una zona del distrito de “Socabaya”, 2024?

Justificación teórica, según Quresshi et al. (2023) argumentan que, el uso de algoritmos de aprendizaje profundo ha demostrado ser eficaz en interpretar datos complejos, como imágenes y patrones, permitiendo una identificación precisa y automatizada del estado del pavimento. Estos algoritmos se basan en modelos matemáticos y redes neuronales que pueden aprender y mejorar con la experiencia, lo que es esencial en el análisis de datos de infraestructura vial.

Justificación operativa, así mismo Quresshi et al. (2023) mencionan que la implementación de una aplicación móvil con algoritmos de aprendizaje profundo para

analizar pavimentos mejora considerablemente la inspección y el mantenimiento de carreteras. Actualmente, evaluar el estado de los pavimentos es costoso y manual, además de llevar mucho tiempo. La propuesta permitirá inspecciones en tiempo real, agilizando la toma de decisiones.

Justificación Tecnológica, para Quresshi et al. (2023) se centra en la capacidad de los algoritmos de aprendizaje profundo para procesar grandes cantidades de datos complejos de manera rápida y precisa. La aplicación móvil propuesta aprovecha esta capacidad y la combina con la capacidad de los dispositivos modernos para capturar datos en tiempo real.

El objetivo general, Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep Learning interviene en la detección de anomalías en pavimento de una zona del distrito de “Socabaya”, 2024, **O.E I)** Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep interviene en la medición y detección de grietas en pavimento de una zona del distrito de Socabaya, 2024, **O.E II)** Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep interviene en la medición y detección de desprendimiento de agregados en pavimento de una zona del distrito de Socabaya, 2024, **O.E III)** Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep interviene en la medición y detección de piel de cocodrilo en pavimento de una zona del distrito de Socabaya, 2024.

La hipótesis general, la ejecución de una aplicación móvil utilizando Deep Learning influye directamente en la detección de anomalías en pavimento de una zona del distrito de “Socabaya”, 2024, **H I)** La ejecución de una aplicación móvil utilizando Deep Learning influye directamente en la medición y detección de grietas en pavimento de una zona del distrito de “Socabaya”, 2024, **H II)** La ejecución de una aplicación móvil utilizando Deep Learning influye directamente en la medición y detección de desprendimiento de agregados en pavimento de una zona del distrito de “Socabaya”, 2024, **H III)** La ejecución de una aplicación móvil utilizando Deep Learning influye directamente en la medición y detección de piel de cocodrilo en pavimento de una zona del distrito de “Socabaya”, 2024.

II. MARCO TEÓRICO

A nivel internacional, según Mayorga [2023](#) (2023) en su estudio se propuso elaborar un sistema implementado un modelo de reconocimiento y clasificación de daños de pavimento para el monitoreo de calidad de las vías. El estudio está orientada al sentido cuantitativa, aplicada y pre experimental, utilizando un total de 513 de imágenes. Los resultados obtenidos para la precisión fueron de 96%, Recall fue de 92%, F1 fue de 93%. Concluyendo, que es de utilidad el sistema para la detección de daños en los pavimentos para el monitoreo de vías, ya que se obtuvieron resultados excelentes en las métricas propuestas.

Por otra parte, Ortega [2021](#) (2021) en este estudio, se desarrolló un sistema automático para detectar y clasificar grietas en pavimentos. El estudio se enfocó en métodos cuantitativos, aplicados y pre experimental, utilizando una población de 165.624 km de carreteras tomando imágenes de grietas longitudinales, transversales y de tipo malla, así como pavimentos sin grietas. Los resultados mostraron altos niveles de precisión y recall para diferentes tipos de grietas, es del 100% de precisión y recall para grietas longitudinales y pavimentos sin grietas es del 100%. Concluyendo, los algoritmos de Deep Learning demostraron ser efectivos en la detección y clasificación de grietas en pavimentos.

En otra línea, Rodríguez [2020](#) (2020) en su estudio se propuso elaborar un sistema automático para la detección y clasificación de grietas en pavimentos. El estudio se enfocó en métodos cuantitativos, aplicados y pre experimental, utilizando una población de 165.624 Km tomando imágenes que incluían grieta longitudinal, transversal, malla, pavimento sin grieta. Los resultados del estudio mostraron la detección y clasificación de grietas 100% de precisión y recall para grietas longitudinales y pavimentos sin grietas, 100% de precisión y 99% de recall para grietas transversales, y 91.6% de precisión y 98% de recall para grietas de tipo malla. Concluyendo, los algoritmos de Deep Learning demostraron una efectividad significativa en la detección y clasificación de grietas.

De otra manera, Tello [2021](#). (2021) en su estudio se propuso elaborar un sistema de detección de grietas en los pavimentos utilizando redes neuronales artificiales. El estudio está orientada al sentido cuantitativa, aplicada y pre experimental, Se adquirieron 300 imágenes clasificadas en diferentes tipos de grietas y se dividieron en entrenamiento (80%) y validación (20%), se aplicarán técnicas como Wavelet Scattering para mejorar la textura y Prewitt para detectar bordes. Los resultados mostraron altos índices de precisión y recall para la detección de diferentes tipos de grietas, con una precisión global del 95,56% y una recall del 94,44%. Concluyendo que se obtuvieron excelentes resultados teniendo una precisión global de 95.56 y recall de 94.44%.

Por último, Lia (2023) (2023) en su estudio se propuso elaborar un sistema de detección de grietas en los pavimentos utilizando redes neuronales artificiales. El estudio está orientada al sentido cuantitativa aplicada y pre experimental, se usó modelos ResNet 34, ResNet 50, VGG 16 y VGG 19, se utilizaron 9017 imágenes con 6 tipos de deterioro y 9620 imágenes. Los resultados destacaron que ResNet 50 tuvo la mayor precisión en la clasificación binaria 96.243% y ResNet 34 mostró la recuperación más sobresaliente 97.824%, ResNet 50 superó 90,257%. Concluyeron que los resultados de los indicadores propuestos obtuvieron resultados sobresalientes.

A nivel nacional, en la línea de investigación sobre la aplicación de Inteligencia Artificial para la detección de fallas, anomalías e imperfecciones en el ámbito de la pavimentación, se realizó una búsqueda exhaustiva de antecedentes. En este proceso, se identificó un único antecedente proveniente de la Universidad César Vallejo (UCV). No obstante, con el fin de enriquecer el análisis y la discusión en comparación con otros estudios, se llevará a cabo una investigación adicional para identificar antecedentes que hayan empleado técnicas de aprendizaje profundo en otras áreas de estudio.

Según, Zúñiga [2022](#) (2022) en su estudio se propuso elaborar un sistema de detección de grietas en los pavimentos utilizando redes neuronales artificiales. El estudio está orientada al sentido cuantitativa, aplicada y pre experimental, utilizando redes neuronales artificiales y la técnica Yolo V5. Se utilizaron 420 imágenes para clasificar

diferentes tipos de grietas y huecos. Los resultados mostraron una precisión del 93% para grietas y 77% para huecos, con sensibilidades de 92% y 91% respectivamente. Concluyendo que los indicadores propuestos obtuvieron resultados sobresalientes para la identificación de grietas y huecos en los pavimentos.

Para, Baca Sihuacollo [2022](#) (2022) en su estudio se propusieron elaborar un sistema inteligente para la detección de uso correcto de mascarillas mediante Deep Learning. El estudio está orientada al sentido cuantitativa, aplicada y preexperimental encaminada a la elaboración de un sistema inteligente, se utilizaron 690 imágenes, se procesaron y extrajeron características para mejorar la calidad de las imágenes, se realizaron pruebas con 60 clientes para evaluar la seguridad, confianza, tiempo de detección, velocidad de reacción y verificación del uso adecuado de las mascarillas. Los resultados, analizados con el software SPSS 25 las medias aumentaron de 11.8% a 15.8% para I1, de 2.32% a 4.27% para I2, de 2.37% a 4.28% para I3 y de 2.32% a 4.27%. Concluyendo que se obtuvieron resultados excelentes en los indicadores presentados.

En otra línea, Huarote Zegarra [2021](#) (2021) en su estudio se propuso determinar la influencia del Deep Learning para mejorar el porcentaje de consultas médicas programadas en las reservas hospitalarias. El estudio está orientada al sentido cuantitativa, aplicada y pre experimental, se utilizaron 70 fichas de reservas y se aplicaron métodos de pre-test y post-test para medir los indicadores como porcentaje de consultas médicas programadas, ocupación de camas en consultas externas y eficiencia en el pedido de recursos hospitalarios. Los resultados para el I1 en el pre-test la media es de 73%, mientras que en el post-test tuvo una media de 95%, para el I2 en el pre-test la media es de 77%, mientras que en el post-test tuvo una media de 89%, para el I3 en el pre-test la media es de 72%, mientras que en el post-test tuvo una media de 94%. Concluyendo que Deep Learning para la gestión de reservas hospitalarias mejoró en el porcentaje de consultas médicas.

Para, Esparza del castillo [2021](#) (2020) en su estudio se propuso desarrollar un sistema inteligente para apoyar el análisis monográfico de la detección rápida de cáncer de mama. El estudio está orientada al sentido cuantitativa, aplicada y pre experimental,

usando CNN y la metodología RUP, además propusieron los indicadores como porcentaje de exactitud, porcentaje de sensibilidad, porcentaje de especificidad, porcentaje de precisión. Los resultados obtenidos de los indicadores en el porcentaje de exactitud se obtuvieron un 80%, porcentaje de sensibilidad se obtuvo un 71.4%, especificidad se obtuvo un porcentaje de 88.5, precisión se obtuvo un 86.2%. Concluyendo que en la ejecución del sistema implementado Deep Learning y aplicando la metodología RUP se obtuvieron resultados excelentes en los indicadores propuestos.

Por último, Hernández [2022](#) (2022) en su estudio se propuso desarrollar un sistema para identificar automáticamente gatos mediante imágenes digitales usando redes neuronales convolucionales. El estudio está orientada al sentido cuantitativa, aplicada y pre experimental, su población está dada por 500 imágenes de entrenamiento 170 para la validación y 165 para el entrenamiento, se hicieron uso de los instrumentos de ficha de observación para medir los siguientes indicadores como exactitud, precisión global, precisión por clase, sensibilidad. Los resultados obtenidos para el I1 son del 98%, I2 es de 97%, I3 94%, I4, 97%. Concluyendo que al evaluar el rendimiento del algoritmo se tuvieron resultados excelentes en los indicadores propuestos.

A continuación, se expondrán las bases teóricas que fundamentan el estudio para las variables.

Las estructuras viales, según Yao Hui (2023) (2023) mencionan que representan una columna vertebral vital en el entramado urbano y rural de nuestras ciudades y pueblos. Sin embargo, Wang Huaping (2023) (2023) redactan que el desgaste y las fallas en los pavimentos son inevitables a lo largo del tiempo debido a la exposición constante a cargas vehiculares, condiciones climáticas cambiantes y otros factores externos. Glinicki Michal ([2022](#)) (2022) argumentan que el desgaste y las fallas en los pavimentos son más que simples imperfecciones en la superficie; pueden representar peligros potenciales para la seguridad vial. Grietas, baches y deformaciones pueden crear condiciones peligrosas para conductores y peatones, aumentando el riesgo de accidentes.

Mantenimiento de pavimento, Jiang Qi ([2023](#)) (2023) mencionan que el diagnóstico de pavimento es una herramienta esencial para guiar las estrategias de mantenimiento y tomar decisiones informadas. Mediante técnicas de evaluación como la inspección visual, el análisis de muestras de pavimento y pruebas de laboratorio, es posible identificar patrones de desgaste y problemas subyacentes permite priorizar las áreas que requieren intervención inmediata y planificar el mantenimiento de manera eficiente. Por otra parte, Murrugarra y Ruiz ([2021](#)) (2021) comentan que el mantenimiento son acciones planificadas y ejecutadas para preservar, reparar y prolongar la vida útil de las superficies de carreteras, con el fin de garantizar la seguridad y comodidad de los usuarios, así como reducir los costos a largo plazo asociados con daños y desgaste.

Deep Learning, según Shadmani Alireza ([2023](#)) (2023) manifiestan que Deep Learning, inspirado en el cerebro humano, se presenta como una faceta influyente en el mundo de la inteligencia artificial y el procesamiento de datos. Esta técnica utiliza redes neuronales artificiales con múltiples capas para abordar problemas complejos, revelando patrones y representaciones de datos previamente inaccesibles. Por otro lado, Ganaie M.A ([2022](#)) (2022) redactan que, Deep Learning demuestra su capacidad para aprender automáticamente características y patrones relevantes de los datos ha revolucionado campos como la visión por computadora, el procesamiento de lenguaje natural y la robótica la detección de objetos en imágenes, la traducción automática o el diagnóstico médico alcanzando niveles de precisión que desafían las expectativas.

Redes neuronales, Basogain Xabier ([2023](#)) (2023) menciona que el primer modelo de red neuronal, fue propuesto por McCulloch y Pitts en 1943, estableciendo las bases conceptuales para las redes neuronales modernas. Aunque inicialmente tenía limitaciones, en la década de 1950, Rosenblatt mejoró el perceptrón introduciendo ponderaciones ajustables y un algoritmo de aprendizaje que permitía reconocer patrones específicos y ajustar automáticamente las ponderaciones en función de los resultados esperados. Peng Yujia ([2023](#)) (2023) indican que las redes neuronales son sistemas computacionales inspirados en el funcionamiento del cerebro humano, diseñados para procesar información y aprender patrones complejos a través de capas

interconectadas de nodos, imitando así la estructura y el funcionamiento de las neuronas. Se utilizan en inteligencia artificial para tareas como reconocimiento de patrones, procesamiento de lenguaje natural y toma de decisiones.

La estructura de las redes neuronales, Para Landauer Max [\(2023\)](#) (2023) contextualizan que la arquitectura de las redes neuronales en inteligencia artificial tiene similitudes con las redes neuronales biológicas. En ambas, la información fluye desde las entradas que se conectan al núcleo para el procesamiento, y luego se emite como salida a través del axón. Esta interconexión y almacenamiento de información son cruciales para el aprendizaje en sistemas biológicos. Sierra y Santos [\(2021\)](#) (2021) mencionan que, cada conexión entre nodos tiene un peso que ajusta la importancia de la señal transmitida. Durante el entrenamiento, los pesos se ajustan para que la red aprenda patrones y realice tareas específicas, como reconocimiento de imágenes o procesamiento de texto.

Para, SHAHA Aarushi (2023) (2023) definen que CNN utiliza capas de convolución para detectar patrones visuales en datos de entrada, lo que la hace especialmente efectiva en tareas de reconocimiento de imágenes y clasificación visual. Han revolucionado campos como procesamiento de imágenes, permitiendo aplicar en reconocimiento facial y la conducción autónoma. Para, Apicella Andrea [\(2023\)](#) (2023) mencionan que, (CNN) son una arquitectura innovadora en el aprendizaje automático constan de múltiples capas, incluyendo que detecta características como bordes y texturas, después sigue una capa de activación para modelar relaciones no lineales, y luego una capa de pooling para reducir la dimensionalidad del mapa de características, conservando lo esencial. Estas capas se repiten para aprender representaciones complejas.

Redes neuronales recurrentes, según Cao Xinwei [\(2023\)](#) (2023) redactan que las (RNN) marcan un hito en el aprendizaje automático al capturar estructuras secuenciales en datos como texto y audio. Sherstinsky Alex (2020) (2020) menciona que, a diferencia de las redes tradicionales, las RNN modelan relaciones temporales y dependencias en secuencias utilizando conexiones retroalimentadas, manteniendo la "memoria" de información pasada.

III. METODOLOGÍA

3.1. Tipo y diseño de investigación

Tipo de investigación

Para, Castañeda María ([2022](#)) (2022) menciona que la metodología aplicada y el enfoque cuantitativo son dos elementos fundamentales en la investigación científica, haciendo referencia al conjunto de pasos, técnicas y herramientas utilizadas para llevar a cabo un estudio o investigación con el propósito de obtener resultados y conclusiones válidas y confiables.

El estudio estará dado por carácter aplicada, ya que estará enfocado al desarrollo de un sistema inteligente utilizando Deep Learning para la detección y diagnóstico de anomalías del pavimento.

Diseño de investigación

Así mismo, Castañeda ([2022](#)) (2022) manifiesta que el diseño de investigación pre experimental es un enfoque básico en la investigación científica que implica la manipulación de una variable independiente para observar su efecto en una variable dependiente, sin la inclusión de un grupo de control. Es decir, no se establece una comparación directa entre grupos, lo que limita la capacidad de establecer relaciones causales sólidas.

En el estudio estará dada por el diseño pre experimental para aplicar el método de la preprueba y posprueba para verificar el comportamiento de un antes y después de los indicadores.

$$GE \ O_1 \ X \ O_2$$

Fuente. Hernández et al. (2014).

Donde:

GE: Grupo experimental dentro de este campo se realizará la recolección de información para su análisis.

O_1 : Pretest, resultados obtenidos antes del análisis

X: Deep Learning, evaluación de variable dependiente

O_2 : Posttest, resultados obtenidos después de utilizar el Deep Learning.

3.2. Variable y operacionalización

Variable independiente: Aplicación móvil utilizando técnicas de Deep Learning

De otra manera, Huang Chenxi [\(2023\)](#) (2023) describen que el aprendizaje profundo (Deep Learning) es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones. Estas redes imitan el funcionamiento del cerebro humano al procesar información en capas sucesivas, extrayendo características complejas a medida que avanzan.

Variable dependiente: Anomalías en pavimento

Por otra parte, Martínez Erick [\(2023\)](#) (2023) Las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro. Estas condiciones anómalas pueden ser causadas por factores como el tráfico vehicular intenso, cambios climáticos, falta de mantenimiento adecuado o problemas de diseño. Detectar y reparar estas anomalías es crucial para mantener la seguridad vial y la durabilidad de las infraestructuras pavimentadas.

3.3. Población, muestra y muestreo

Población

En otra línea, Mucha Luis [\(2021\)](#) (2021) comentan que la población se refiere al conjunto completo de elementos o datos que comparten una característica común y son objeto de estudio en una investigación.

Por lo tanto, la población del estudio consta de 250 fotografías tomadas en las principales calles pavimentadas de San Martín de Socabaya, ubicado en el Distrito de

Socabaya. Estas imágenes fueron capturadas en cinco calles específicas que están pavimentadas con asfalto en la mencionada zona.

Tabla 1.

Principales Calles de la zona de San Martin de Socabaya

Distrito	Zona	Tipo	Nombre	Distancia en kilómetros	Cantidad imágenes
Socabaya	San Martin de Socabaya	Av.	San Martin	1.27	72
		Calle	Oroya	0.74	54
		Av.	Unión	0.72	38
		Calle	Caraveli	0.84	50
		Calle	Huancayo	0.66	36

Nota. Elaboración propia.

Muestra

De la misma manera, Mucha [\(2021\)](#) (2021) mencionan que es una muestra es un subconjunto de la población total, se elige para representar las características de la población de manera que los resultados obtenidos a partir de la muestra puedan generalizarse o inferirse sobre la población completa.

La muestra en la presente investigación se aplicará 250 fotografías que se obtendrán desde un teléfono inteligente, para ello es importante mencionar la ubicación geográfica ubicado en el distrito de Socabaya siendo el punto focalizado San Martin de Socabaya donde se obtuvo los datos para la siguiente investigación.

En el cual se aplicó la siguiente formula.

$$n = \frac{z^2 * N * P * Q}{(N - 1) * E^2 + z^2 * p * q}$$

Siendo las siguientes características:

n = muestra

Z = nivel de confianza al 95% (1.96)

N = población de la zona de estudio

p = Posibilidad de éxito en 0.5

q = Posibilidad del fracaso en 0.5

E = Rango de error al 5%

Usando la formula con los valores obtenidos.

$$n = \frac{1.96^2 * 250 * 0.5 * 0.5}{(250 - 1) * 0.05^2 + 1.96^2 * 0.5 * 0.5} = 151.68 = 152$$

Por lo tanto, con base en los resultados, se identificó y asignó la muestra del universo utilizado en este estudio a través de un total de 152 fotografías tomadas con teléfonos inteligentes del área de estudio.

Con respecto al muestreo en el estudio, esto se hará por conveniencia porque las áreas enumeradas en la Tabla 2 contienen la clasificación de las discontinuidades necesarias para fines de la investigación mediante el análisis de imágenes, que se capturarán divididas en píxeles. Las principales calles adoquinadas del distrito de Socabaya. Por otro lado, cabe recordar que para ello se utilizarán modelos y arquitecturas divididas en varios módulos jerárquicos para el correcto análisis de las imágenes grabadas con teléfonos inteligentes y se cargarán para utilizar correctamente las reglas de validación. En consecuencia, también se realizarán registros de las principales características y dimensiones.

por ejemplo, escriba el tipo de algoritmo de entrenamiento para medir la latencia de ejecución de la prueba y otras características consideradas en el proceso.

Muestreo

Por lo tanto, Mucha [\(2021\)](#) (2021) describe que el muestreo implica una serie de pasos para seleccionar una muestra representativa de la población, utilizando métodos como el muestreo aleatorio.

Por ende, el muestreo probabilístico del estudio debido a que calculo la muestra para las zonas pavimentadas que presenta anomalías de tipo de grietas, huecos y piel de cocodrilo que se requiere para el estudio a través de las fotografías segmentadas las cuales serán capturadas de las principales calles pavimentadas de la zona de San Martín de Socabaya del distrito de Socabaya.

Para ello se desarrolló un conjunto de fotografías, en particular de grietas y agujeros aparecidos en la superficie de la carretera del objeto de investigación, de las que se obtuvieron 250 fotografías.

3.4. Técnicas e instrumentos de recolección de datos

Técnicas

Según, Sánchez Diana [\(2022\)](#) (2022) argumenta que las técnicas de recolección de datos son utilizadas para recopilar información importante que incluyen encuestas estructuradas, entrevistas en profundidad, observaciones directas y análisis de contenido, permitiendo obtener datos de manera sistemática y orientada a los objetivos de la investigación, facilitando el análisis y la obtención de información para respaldar conclusiones y hallazgos.

Instrumentos

Así mismo, Sánchez [\(2022\)](#) (2022) describe que los instrumentos de recolección de datos son herramientas empleadas para recopilar información, usando cuestionarios, guías de entrevistas, escalas de medición diseñados para obtener datos específicos y relevantes para el estudio. Además, describe, la técnica de observación consiste en la recolección sistemática y directa de información mediante la visualización y registro de eventos, comportamientos o situaciones en su entorno natural. Se emplean herramientas como la atención detallada, la toma de notas y, en algunos casos,

dispositivos de registro. Así mismo describe, que el instrumento de guía de observación es una herramienta estructurada que facilita y dirige el proceso de observación al enfocar la atención del observador en aspectos específicos de interés. Este instrumento consiste en una lista detallada de categorías, comportamientos o elementos relevantes que se espera observar.

El estudio se utilizará la técnica de observación e instrumento guía de observación para tomar nota de los resultados de los indicadores como como la precisión, recall, f1.

3.5. Procedimientos

Obj1. Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep interviene en la medición y detección de grietas en pavimento de una zona del distrito de “Socabaya”, 2024

- Llevar a cabo la selección de estudio para determinar la población para toma de datos mediante imágenes para la construcción de la data set.
- Se procedería a etiquetar los datos, identificando áreas con anomalías y problemas en el pavimento.
- Procesamiento / segmentación de imágenes
- Se utilizará el aprendizaje profundo para desarrollar un modelo de detección de anomalías. Esto implicaría la creación y entrenamiento de una red neuronal convolucional (CNN) que pueda analizar las imágenes y resaltar las áreas de interés. Durante el proceso de entrenamiento, el modelo aprenderá a identificar patrones asociados con diferentes tipos de anomalías en el pavimento.
- Posteriormente, se realizaría una fase de validación y ajuste fino del modelo utilizando datos adicionales. Una vez que el modelo alcance un nivel adecuado de precisión y confiabilidad, se integraría en una aplicación o plataforma que permita a los administradores de infraestructuras y autoridades locales supervisar el estado del pavimento y tomar medidas preventivas de mantenimiento.
- Desarrollo de la aplicación móvil

Obj2. Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep interviene en la medición y detección de desprendimiento de agregados en pavimento de una zona del distrito de “Socabaya”, 2024

- Llevar a cabo la selección de estudio para determinar la población para la toma de datos mediante imágenes para la construcción de la data set.
- Se procedería a etiquetar los datos, identificando áreas con anomalías y problemas en el pavimento.
- Procesamiento / segmentación de imágenes
- Se utilizará el aprendizaje profundo para desarrollar un modelo de detección de anomalías. Esto implicaría la creación y entrenamiento de una red neuronal convolucional (CNN) que pueda analizar las imágenes y resaltar las áreas de interés. Durante el proceso de entrenamiento, el modelo aprenderá a identificar patrones asociados con diferentes tipos de anomalías en el pavimento.
- Posteriormente, se realizaría una fase de validación y ajuste fino del modelo utilizando datos adicionales. Una vez que el modelo alcance un nivel adecuado de precisión y confiabilidad, se integraría en una aplicación o plataforma que permita a los administradores de infraestructuras y autoridades locales supervisar el estado del pavimento y tomar medidas preventivas de mantenimiento.
- Desarrollo de la aplicación móvil

Obj3. Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep interviene en la medición y detección de piel de cocodrilo en pavimento de una zona del distrito de “Socabaya”, 2024

- Llevar a cabo la selección de estudio para determinar la población para la toma de datos mediante imágenes para la construcción de la data set.
- Se procedería a etiquetar los datos, identificando áreas con anomalías y problemas en el pavimento.
- Procesamiento / segmentación de imágenes
- Se utilizará el aprendizaje profundo para desarrollar un modelo de detección de anomalías. Esto implicaría la creación y entrenamiento de una red neuronal

convolucional (CNN) que pueda analizar las imágenes y resaltar las áreas de interés. Durante el proceso de entrenamiento, el modelo aprenderá a identificar patrones asociados con diferentes tipos de anomalías en el pavimento.

- Posteriormente, se realizaría una fase de validación y ajuste fino del modelo utilizando datos adicionales. Una vez que el modelo alcance un nivel adecuado de precisión y confiabilidad, se integraría en una aplicación o plataforma que permita a los administradores de infraestructuras y autoridades locales supervisar el estado del pavimento y tomar medidas preventivas de mantenimiento.
- Desarrollo de la aplicación móvil

3.6. Metodología de análisis de datos

Según, Castañeda ([2022](#)) (2022) se argumenta que la metodología de análisis de datos constituye un enfoque sistemático y estructurado para examinar y comprender la información recolectada durante una investigación. Esta metodología guía el proceso de interpretación de los datos, la identificación de patrones, la detección de relaciones y la obtención de conclusiones sustanciales.

La prueba de normalidad constituye un método estadístico que se emplea con el propósito de discernir si un conjunto de datos se adhiere a una distribución normal, en la cual los valores se dispersan simétricamente alrededor de la media. Su utilidad radica en la evaluación de la conformidad de los datos a un modelo normal, lo cual es esencial para la aplicación de determinados enfoques estadísticos.

En el contexto del análisis cuantitativo de datos, se adopta un enfoque específico según los objetivos planteados.

a) En el Análisis de Datos Descriptivos, se realizan cálculos estadísticos descriptivos como promedios, medianas y desviaciones estándar antes y después de la implementación de Business Intelligence para cada uno de los objetivos particulares.

b) En el apartado de Pruebas Estadísticas, se recurre a pruebas estadísticas apropiadas para contrastar las diferencias pre y post implementación. Por ejemplo, en situaciones donde los datos no obedecen a una distribución normal, se pueden utilizar pruebas t de Student o pruebas de Wilcoxon para muestras relacionadas.

3.7. Aspectos éticos

La realización de la investigación se desarrolló en pleno acatamiento de los derechos de propiedad intelectual de los autores involucrados. En esta dimensión, se atendieron rigurosamente las fuentes de referencia y las citas bibliográficas en estricta consonancia con las directrices establecidas en la norma ISO 690-2. Adicionalmente, se siguieron de manera escrupulosa las orientaciones que rige el reglamento de la Universidad César Vallejo, en lo que concierne a la formulación de investigaciones.

De igual manera, se concedió primordial importancia a la salvaguardia de la confidencialidad y la fiabilidad de los datos suministrados por los empleados. Este aspecto se fundamentó en el respaldo otorgado por el permiso expreso de la empresa, específicamente emitido para esta pesquisa. Adicionalmente, se tomaron precauciones especiales para asegurar que el nivel de semejanza se mantenga considerablemente por debajo del umbral permitido por la Universidad César Vallejo, conforme a las directrices establecidas por Turnitin.

IV. RESULTADOS

Esta parte del capítulo de Resultados presenta la información obtenida durante el proceso de aprendizaje profundo, mostrando la caracterización y validación de los conceptos.

4.1. Análisis descriptivo

4.1.1. Recopilar datos del entorno de aprendizaje.

En el análisis descriptivo es importante mencionar dónde se ubica el campo de estudio. recolectaron imágenes a través de teléfonos móviles, ya que es similar al presente estudio y fue elegida para ayudar a identificar grietas y agujeros. En carreteras de hormigón y concreto. (tabla 12)

4.1.2. Etiquetado de imagen

Además, una vez completada la selección, se utiliza el método de diseño para cambiar el tamaño de la imagen a 1920x1080 píxeles a través de las herramientas de Adobe Cloud para seleccionar herramientas técnicas que puedan escribir y convertir en las fotos. Presentar documentos compatibles con YOLO, ya que cada formulario contiene información sobre la matriz requerida para realizar estos estudios a través de la Colaboración de Google y el trabajo estructurado de YOLO, las herramientas seleccionadas para esta ubicación se pueden encontrar en el Anexo 16, donde Estructura. Como se muestra en la imagen, es de fácil uso debido a su diseño y fácil etiquetado, permitiendo registrar la planta.

La transformación de los datos se puede encontrar y llenar en un formato Zip que representa los datos del grupo que será entrenado, validado y probado para obtener las mediciones presentadas en este estudio para la identificación de grietas y corrosión. Sobre pavimento, apto para todo tipo de grava u hormigón.

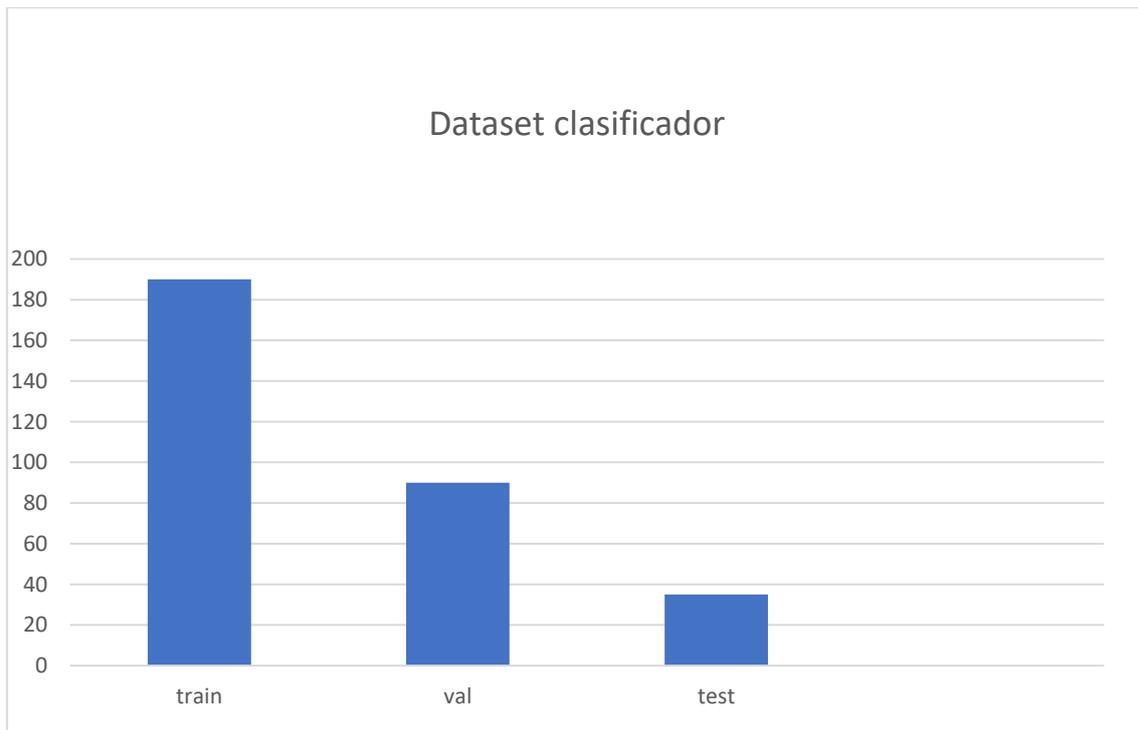


Figura 2: Dataset del conjunto de imágenes

Nota. Elaboración propia

La parte "Train" contiene 200 fotografías durante el entrenamiento, 100 fotografías en la parte "Val" como datos para confirmar sus secretos y tratar de hacerlo más fácil, y 30 fotografías tomadas como indicación del fracaso de la prueba. Intentaremos analizar los resultados de la muestra de entrenamiento, lo que revelará la medición de la variable dependiente y nos permitirá obtener nueva información.

4.1.3. Presentamos la arquitectura YOLOv5 y el formato Google Colab

Además, al construir YOLOv5, se requiere más configuración, incluidos archivos yaml, incluido 201 100 30 0 50 100 150 200 250 entrenamiento para probar muchos componentes e insertar la imagen Dataset_classifier5GH como imagen 5: de componentes de clase e insertar la imagen Dataset_classifier5GH como imagen 5: de clase Componentes e insertar imagen Imagen lmas 5: Clase de componentes, número, clase, válvula y método de carpeta de prueba. Esto permite la conexión

entre el indicador YOLO y "dataset_classifierGH".

4.1.4. Desarrollo del entrenamiento de las redes neuronales

Una vez que se completa la configuración, el conjunto de datos se crea en formato .ZIP, se abre la carpeta lista para leer, se codifican argumentos como el tamaño de la imagen, el número de lote y se muestra el conjunto de datos de una vez en el lenguaje de programación Python. Cuanto mayor sea el tamaño del lote, más rápido será el proceso de entrenamiento de salida de la red neuronal, donde se seleccionan 16 lotes y 150 épocas, la ruta al archivo yaml configurado define los pesos para transformar el archivo. Como se puede ver en la imagen adjunta, los datos de entrada se empaquetan en la capa oculta de una red neuronal convolucional, que es una versión YOLOv5 de la clase de tipo yolov5x que sirve eficazmente al proceso de entrenamiento de la red neuronal.

4.1.1. Análisis de las métricas del entrenamiento.

Se obtuvieron las métricas del resultado del desarrollo de entrenamiento de las redes neuronales donde se aprecia a detalle todos los indicadores como la precisión, recall o sensibilidad, arrojando los equivalentes de puntuación.

Con conocimientos de las métricas donde se visualiza la gráfica de las mAP el cual representa la medición del efecto en los enfoques que están etiquetadas en pixeles ejecutados en el rendimiento. Está es una de las formas de segmentación semántica es el método más común para obtener la precisión media de la media representada por las iniciales (mAP). En la primera grafica de la selección de métricas, encontramos el margen de la media al 0.5 mientras que en la segunda grafica se puede ver la gráfica estadística del margen del 0.5 al 0.95, así como la precisión y el recuento responsables de la recuperación de información. Además, las gráficas de la perdida ocurrida durante el proceso de optimización se pude visualizar en la segunda fila.

Las imágenes agrupadas en la fila de validación (val) muestran los resultados obtenidos durante el entrenamiento y la fila de la variable "x", que

representa el sesgo y el peso proporcionado por la red neuronal dentro de los límites de las épocas indicadas. hasta 150.

La matriz que se muestra en la figura anterior representa el conjunto de datos como porcentaje de respuesta correctas, teniendo en cuenta ciertas características y criterios de elegibilidad, dividido por el corte que permitió respuestas a las preguntas formuladas. En una hipótesis que planteo las siguientes preguntas: ¿Deep Learning permitirá detectar defectos en el pavimento en la zona el distrito de Socabaya en el 2024? Y permite resultados positivos para la detección de grietas y agujeros de alta precisión utilizando técnicas de aprendizaje profundo en una arquitectura neuronal convolucional.

En este sentido, la función de la matriz de confusión jugo un papel importante en el desarrollo de esta investigación, debido a los argumentos denominados negativos y positivos que conducen a la unión de operaciones lógicas son valores parametrizados en valores de 0 y 1 que serán usados por los log-loss o pérdida logarítmica. indicando el valor de las etiquetas es 0 representa a la confianza obstante si es valor de 1 con aproximación del 0.51 de probabilidad, sin embargo, el margen de error se encuentra en el punto de corte del 0.5.

Se visualiza el registró de los gráficos estadísticos del entrenamiento (box_loss, obj_loss, cls_loss) así como la métrica de precisión y recall donde:

- Box_loss: representa la pérdida de regresión el error cuadrático medio.
- Obj_loss: representa la confianza del objeto.
- Cls_loss: pérdida de clasificación.
- Precisión: mide la precisión de las predicciones de box es decir $VP/VP+FP$.
- Recall: mide si el valor de box_loss es verdadero, incluyendo conjeturas. Tiene razonen decir $VP/VP+FN$, que significa $mAP_{0.5}$. 0.5 es la precisión media(mAP) en el límite. En 0.95 es el promedio de varios umbrales existentes.

La pila o la matriz de imágenes de arriba muestra 60 fotogramas. Los valores 0 y 1, conde el 36.67% identifica los huecos y el 63.33% identifico grietas, en pavimentos de asfalto y hormigón.

Además, las lecturas registradas muestran puntos entre 0.3 y 0.9 una puntuación mayor a 0.5 donde indica una margen de error del 50 %.

4.2. Análisis inferencia

4.2.1 Análisis del resultado de validación de imágenes.

Con este fin, realizamos experimentos en un subconjunto de 30 imágenes de dataset_clasificacionGH para evaluar el rendimiento de confianza y analizar las mediciones obtenidas.

deteccion de clases						
	valido		perdidos		total	
	N	porcentaje	N	porcentaje	N	porcentaje
clases	726	100.00%	0	0.00%	726	100.00%

Tabla 3: Análisis de resultado *Nota*. Elaboración propia

Dónde:

N = representa el número total de iteraciones de imágenes a probar y validar y las categorías que se perderán en el proceso. Clase = representa el número de clases (grietas y huecos) encontradas en N secciones.

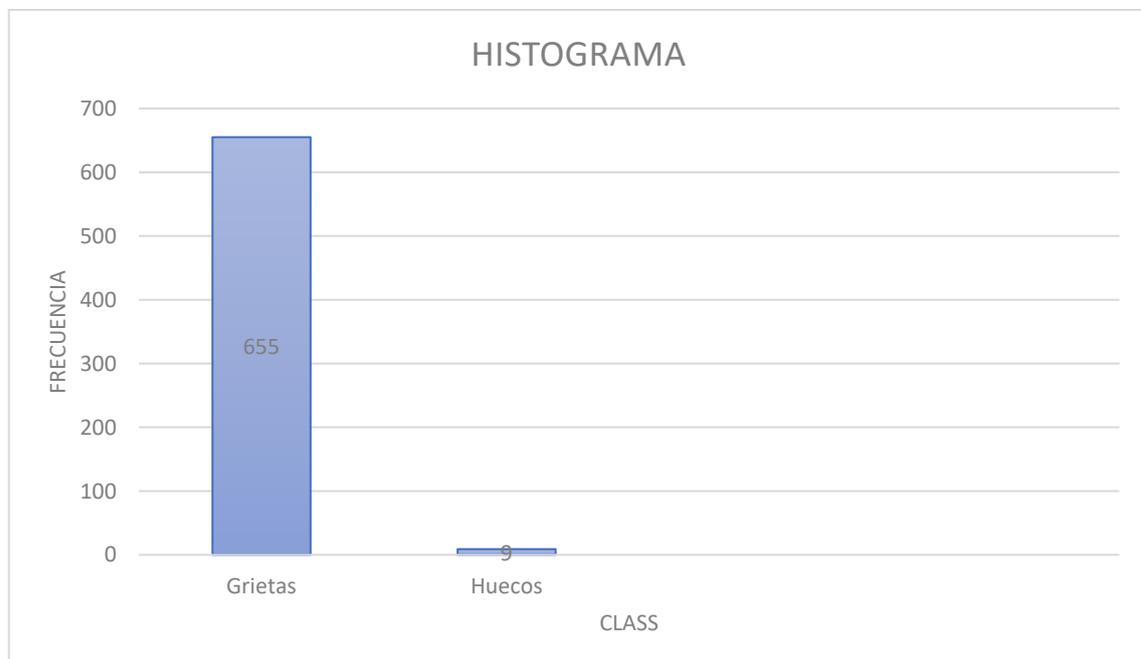


Figura 4: Histograma de la detección de tipos de clases (grietas y hueco) en 30 imágenes, donde:

Nota. Elaboración propia

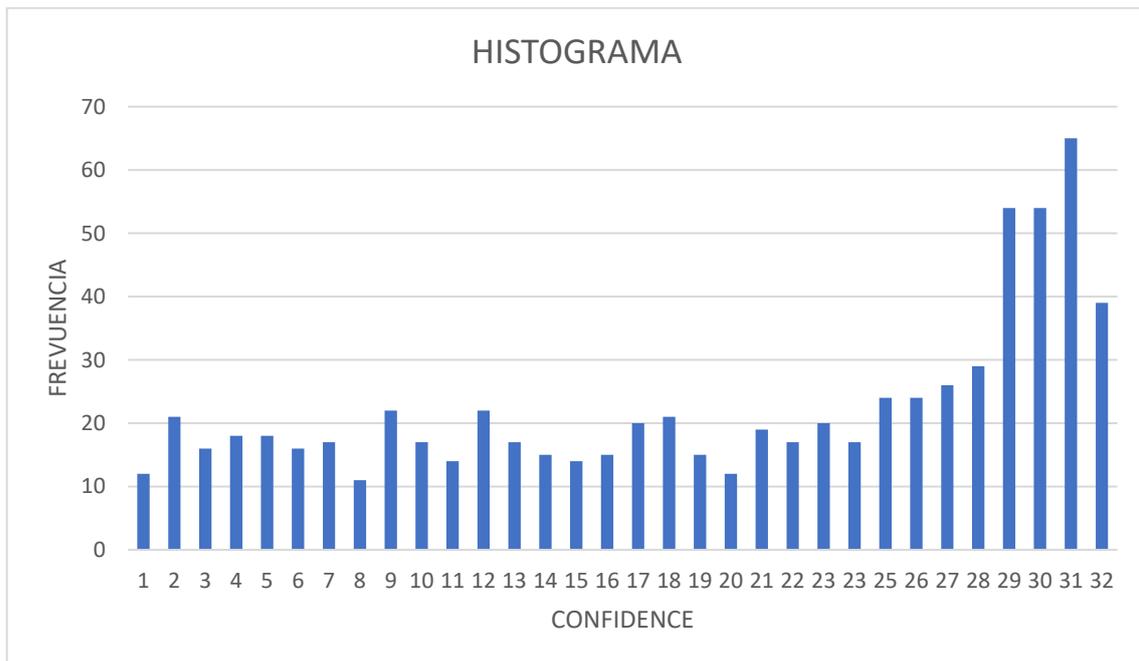


Figura 5: Histograma de confianza

Nota. Elaboración propia

obtenido de 30 verificaciones de imágenes tiene un valor promedio superior al 50%, un índice de 0,62 y la diferencia llega a 0,19 cuando se repite 724 veces.

Tipo de Metrica	resultado
Accuracy	0.867
ROC AUC Macro Unidad	0.943
ROC AUC Micro Unidad	0.946
F1 - Score Macro Unidad	0.881
F1 - Score Micro Unidad	0.867
ROC AUC GRIETA	0.92
ROC AUC HUECO	0.91
Unidad de precision Grieta	0.933
Unidad de precision Hueco	0.775
F1 - score Grieta	0.867
F1 - Score Hueco	0.778

Tabla 6: Elaboración propia tipo de métricas

Nota. Elaboración propia

Del análisis de los resultados de las pruebas realizadas se obtuvieron resultados de medición similares, como que la precisión promedio del área fue de 0,93% y 0,77%, mientras que la transparencia de las grietas alcanzó 0,92% y 0,91% en algunos lugares, y finalmente, algunas encontramos grietas llega al 0,86%, y en algunos lugares llegan al 0,77%.

4.2.2. Matriz de confusión del test.

La Matriz utilizada en los métodos de aprendizaje profundo nos permite ver mejor el rendimiento del algoritmo YOLOv5, el cual está dividido en filas y columnas, donde cada parte de la matriz muestra el número de predicciones para cada categoría y la fila correspondiente, lo que significa que no se permiten eventos de cada categoría del tipo de éxito creado durante el modelo de expresión.

Según esta teoría, el número de muestras utilizadas en el experimento fue de 30 imágenes, que se crearon de la siguiente manera.

- VP (verdadero positivo), El modelo dejó un signo (+) en el trayecto de la grieta intersticial.
- VN (verdadero negativo), no hay espacio para caminar porque el modelo lo clasifica como que no envía una señal (-).
- FN (falso negativo), En la pista, los lugares donde las ubicaciones de los modelos muestran grietas y fallas en los asientos están marcados (-), posiblemente debido a errores en los cálculos.
- FP (falso positivo), En un camino sin fisuras, en este caso el modelo lo clasifica como falla y le da un signo (+), lo que puede ser un error en el cálculo.

4.2.3. cuadro de ROC por una marca y el total

En este principio, la señal sensible se refleja en la información de la curva ROC y también se encuentra la integral de precisión, la cual es necesaria para mostrar si existen fallas como agujeros o grietas en la estructura de la carretera, a continuación. Ese concepto. Esta figura muestra el método para

juzgar y evaluar los resultados, y ambos muestran el efecto y la autenticidad del eje "Y", por ejemplo:

$$Precision = \frac{VP}{VP + FN}$$

Dónde:

- a). La curva ROC que representa la predicción del lado de la grieta (TPR) consta de hechos verdaderos: el último pico en 70 puntos alcanza 0,8 y el verdadero (FPR) en el eje "X" representa falsas alarmas que alcanzan 0,7.
- b). Este gráfico muestra los resultados de predicción (TPR) marcados hasta 0,7 y hasta 0 en el eje 'X'.
- c). Se muestra la ROC común entre las dos mediciones, con una puntuación máxima de 1, lo que confirma la precisión de los resultados de la prueba.

4.2.4 indicador de precisión

Con la Prueba en un solo punto y analice grietas y huecos en la curva ROC.

Como se describe en la Sección 4.2.3, los puntos que alcancen una precisión superior al 50 % se incluirán en el nivel de confianza, con un nivel máximo de 0,95.

4.2.5. indicador recall

En la medición del recuerdo, nos referimos a la cantidad de veces que el evaluador pudo distinguir entre ejemplos positivos y negativos, denominada tasa de verdaderos positivos, de la siguiente manera:

$$Recall = \frac{VN}{VN + FP}$$

Los objetos expuestos se muestran conectados bajo el número 1, que muestra el grado correcto de influencia.

4.2.6. Indicador: F1

$$F1 \text{ value} = \frac{2Recall * Precision}{Recall + Precision}$$

El registro realiza un análisis jerárquico automático de la calidad de la puntuación obtenida, lo cual se puede observar en la figura, cuando la puntuación llega a la mitad del intervalo $[0,8 \geq 1]$, se puede ver una línea azul para la búsqueda. Respecto al tamaño de grietas y huecos al probar fotografías tomadas con un teléfono inteligente.

4.3 Desarrollo del Aplicativo

Después de encontrar nuevos conjuntos de datos que podrían implementarse en sistemas inteligentes, continuamos diseñando y desarrollando programas en el lenguaje de programación Python, utilizando algunas de las bibliotecas descritas. Utilice los métodos y procedimientos de este artículo para preparar el sistema para su uso con los indicadores y funciones, para obtener información sobre las imágenes que se muestran en las secciones del diagrama de flujo. Por lo tanto, a través de los parámetros establecidos en la demostración, se obtuvieron mediciones utilizando los ajustes en la matriz, dando como resultado la identificación de grietas y huecos en caminos estructurales como concreto y grava en el área de estudio.

V. DISCUSIÓN

Los resultados obtenidos fueron óptimos para la detección de grietas y huecos en estructuras viales como asfalto y concreto en el área de estudio, principalmente en las zonas dañadas. Para ello se han implementado varios procesos utilizando métodos de aprendizaje profundo y herramientas tecnológicas. Por ejemplo, se puede observar que algunos métodos tienden a capturar imágenes estáticas para estudiar la detección de grietas (Fan et al. (2020)). 0,19 y 0,92, y la recuperación osciló entre 0,67 y 0,93 en F1 y 0,28 y 0,92 en F1 para imágenes con resoluciones de 768x512, 991x462 y 311x462 píxeles. Los indicadores obtenidos de las obras alcanzan los indicadores entre 0.32 como parte de la confiabilidad.

1920x1080 Píxeles Resolución 0.85.

Las tareas bañadas se basan en rutas que se pueden usar en estructuras de carreteras, incluidas las transacciones de píxeles de las estructuras de carreteras, incluidas las transacciones de píxeles de píxeles. Identificar la brecha, método utilizado para desarrollar este artículo.

La detección de grietas y huecos se determinó mediante aprendizaje profundo utilizando un método de recopilación de datos de una aplicación de fotografías para teléfonos inteligentes implementado por Maeda et al. (2018), que arrojó resultados positivos en la detección de grietas y huecos en esta dirección del tráfico. Se lograron los objetivos utilizados en este estudio.

VI. CONCLUSIONES

El objetivo de este estudio se logró mediante un método de investigación profundo para identificar grietas y baches en caminos de cemento o asfalto en las vías principales del sector de las calles principales del distrito de Socabaya. Los errores que ocurren en la construcción de carreteras se identifican a través de un sistema desarrollado bajo una arquitectura de red neuronal, que analiza la ubicación de grietas y huecos de manera estable a través de imágenes recopiladas con teléfonos móviles.

Asimismo, el cálculo de los efectos y la determinación de las diferencias entre ellos se determina mediante métodos de aprendizaje profundo basados en modelos e implementados en un sistema inteligente que se puede ver directamente mediante una cámara. Además, para el segundo indicador de precisión de grieta, incluida la sensibilidad y los gráficos, determinado por las herramientas utilizadas en el estudio, se mostrarán los mismos indicadores en el próximo capítulo.

Además, este estudio utilizó el algoritmo YOLOv5, que es uno de los sistemas más optimizados para detectar grietas y agujeros en asientos, además, también utilizó este modelo para entrenar una red neuronal y tuvo muchos resultados. En concreto, se podrían utilizar capacidades futuras para evaluar diferentes tipos de grietas que aparecen al tomar fotografías o mirar videos.

El objetivo de este estudio se logró mediante un método de investigación profundo para identificar grietas y baches en caminos de cemento o asfalto en las vías principales del sector de las calles principales del distrito de Socabaya. Los errores que ocurren en la construcción de carreteras se identifican a través de un sistema desarrollado bajo una arquitectura de red neuronal, que analiza la ubicación de grietas y huecos de manera estable a través de imágenes recopiladas con teléfonos móviles.

Asimismo, el cálculo de los efectos y la determinación de las diferencias entre ellos se determina mediante métodos de aprendizaje profundo basados en modelos e implementados en un sistema inteligente que se puede ver directamente mediante una cámara. Además, para el segundo indicador de precisión de grieta, incluida la

sensibilidad y los gráficos, determinado por las herramientas utilizadas en el estudio, se mostrarán los mismos indicadores en el próximo capítulo.

Además, este estudio utilizó el algoritmo YOLOv5, que es uno de los sistemas más optimizados para detectar grietas y agujeros en asientos, además, también utilizó este modelo para entrenar una red neuronal y tuvo muchos resultados. En concreto, se podrían utilizar capacidades futuras para evaluar diferentes tipos de grietas que aparecen al tomar fotografías o mirar vídeos.

VII. RECOMENDACIONES

La aplicación de Deep Learning para la detección de anomalías en pavimento es una tarea avanzada y útil para el mantenimiento de infraestructuras viales. A continuación, te proporciono algunas recomendaciones para llevar a cabo este tipo de proyecto:

1. Recopilación de Datos

- **Imágenes y Videos:** Recopila una gran cantidad de imágenes y videos del pavimento desde diferentes ángulos y condiciones. Puedes utilizar drones o vehículos equipados con cámaras.
- **Anotación:** Anota las imágenes para identificar y clasificar las anomalías como grietas, baches, fisuras, etc. Herramientas como LabelImg o VGG Image Annotator pueden ser útiles.

2. Preprocesamiento de Datos

- **Aumento de Datos (Data Augmentation):** Para mejorar la generalización del modelo, aplica técnicas de aumento de datos como rotación, recorte, cambio de brillo y contraste.
- **Normalización:** Normaliza las imágenes para que los valores de los píxeles estén en un rango específico, como $[0, 1]$ o $[-1, 1]$.

3. Selección del Modelo

- **Modelos Convolucionales (CNN):** Redes neuronales convolucionales como ResNet, VGG, y MobileNet son adecuadas para la detección de objetos en imágenes.
- **Transfer Learning:** Utiliza modelos preentrenados y realiza un ajuste fino (fine-tuning) para tu conjunto de datos específico. Esto puede reducir significativamente el tiempo de entrenamiento y mejorar la precisión.

4. Entrenamiento del Modelo

- **División de Datos:** Divide tu conjunto de datos en conjuntos de entrenamiento, validación y prueba.

- Hiperparámetros: Ajusta los hiperparámetros del modelo como la tasa de aprendizaje, el tamaño del lote (batch size) y el número de épocas.
- Métricas: Utiliza métricas como precisión, recall y F1-score para evaluar el rendimiento del modelo.

5. Implementación y Evaluación

- Evaluación en Tiempo Real: Implementa el modelo en una plataforma que pueda procesar imágenes en tiempo real, como TensorFlow Serving o una aplicación móvil.
- Monitoreo: Desarrolla un sistema de monitoreo para evaluar continuamente el rendimiento del modelo y actualizarlo según sea necesario.

6. Mejora Continua

- Retraining: Continúa recolectando datos y retrainando el modelo para adaptarse a nuevas condiciones y tipos de anomalías.
- Feedback: Utiliza feedback de los usuarios y de las inspecciones manuales para mejorar la precisión del sistema.

7. Recursos y Herramientas

- Frameworks: TensorFlow, Keras, PyTorch son opciones populares para construir y entrenar modelos de Deep Learning.
- Plataformas de Computación: Utiliza GPUs y TPUs en plataformas como Google Colab, AWS, o Azure para acelerar el entrenamiento.
- Ejemplo de Implementación
- Dataset: Utiliza un dataset como el Pavement Distress Image Dataset para empezar.
- Modelo Preentrenado: Comienza con un modelo preentrenado como ResNet50 y realiza fine-tuning con tu dataset anotado.
- Implementar estas recomendaciones puede ayudarte a desarrollar una aplicación robusta y eficiente para la detección de anomalías en pavimento mediante Deep Learning.

REFERENCIAS

- APICELLA, Andrea [et al.]. (2023). Adaptive filters in Graph Convolutional Neural Networks. Obtenido de <https://doi.org/10.1016/j.patcog.2023.109867>
- ARRELLANO, Saúl. (2020). *Estas son las entidades con peores calles y avenidas*. Obtenido de MexicoSocial : <https://www.mexicosocial.org/las-entidades-con-peores-calles-y-avenidas/>
- BACA, María; SIHUACOLLO, Julio. (2022). *sistema inteligente basado en deep learning para mejorar el correcto uso personal de mascarillas en el supercado wong*. Universidad César Vallejo, 1-81. Obtenido de https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/88857/Baca_GMR-Sihuacollo_LJA-SD.pdf?sequence=1&isAllowed=y
- BASOQAIN, Xabier. (2023). Redes neuronales artificiales u sus aplicaciones. Obtenido de https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf
- CAO, Xinwei [et al.]. (2023). A novel recurrent neural network based online portfolio analysis for high frequency trading. Obtenido de <https://doi.org/10.1016/j.eswa.2023.120934>
- CASTAÑEDA, María. (2022). *The scientificity of quantitative, qualitative and emerging methodologies*. Revista Digital de Investigación en Docencia Universitaria, 16, 1-12. Obtenido de <http://orcid.org/0000-0002-4847-4382>
- CHEN, L. [. (2023). A systematic review of steel bridge deck pavement in China. Obtenido de <https://doi.org/10.1016/j.jreng.2023.01.003>
- ESPARZA, J. (2020). *Rede neuronales convolucionales en la detección de efeccciones respiratorias de los sistemas locales de salud: Un resvisión sistemática entre los años 2010 y 2020*. Universidad Privada del Norte, 1-34. Obtenido de https://repositorio.upn.edu.pe/bitstream/handle/11537/25838/JOSE_ESPAR

ZA_REVISI%c3%93N-

SISTEM%c3%81TICA%20Total.pdf?sequence=1&isAllowed=y

Ganaie, M.A [et al.]. (2022). Ensemble deep learning: A review. Obtenido de <https://doi.org/10.1016/j.engappai.2022.105151>

GLINICKI, M. (2022). *Diagnosis of ASR damage in highway pavement after 15 years of service in wet-freeze climate region*. *Case Studies in Construction Materials*, 17, 1-15. Obtenido de <https://doi.org/10.1016/j.cscm.2022.e01226>

HERNANDEZ, A. (2022). *Identificación automática de gatos mediante reconocimiento de imágenes usando redes neuronales convolucionales*. Universidad Señor de Sipán, 1-83. Obtenido de <https://repositorio.uss.edu.pe/bitstream/handle/20.500.12802/10219/Hernandez%20Neria%20Marco%20Antonio%20Rosas.pdf?sequence=1&isAllowed=y>

HUANG, Chenxi [et al.]. (2023). A review of deep learning in dentistry. Obtenido de <https://doi.org/10.1016/j.neucom.2023.126629>

HUAROTE, Raul. (2021). *Deep learning para la mejora en la gestión de reservas hospitalarias en el Hospital Mariano Molina Scippa de Comas, Li,a-2020*. Universidad César Vallejo, 1-70. Obtenido de https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/106124/Huarte_ZRE-SD.pdf?sequence=1&isAllowed=y

INSTITUTO NACIONAL DE ESTADÍSTICA E INFORMÁTICA. (2022). *Indicador de la Actividad Productiva Departamental - Cuarto Trimestre 2021*. Obtenido de *Indicador de la Actividad Productiva Departamental - Cuarto Trimestre 2021*: <https://m.inei.gob.pe/biblioteca-virtual/boletines/produccion-nacional-departamenal-9836/2022/1/#lista>

Jiang, Qi [et al.]. (2023). Comprehensive assessment of the durability deterioration of asphalt pavement in salt environment: A literature review. *Case Studies in Construction Materials*, 17, 1-22. Obtenido de <https://doi.org/10.1016/j.cscm.2022.e01706>

- LA REPUBLICA. (2019). *Del total de la red vial terciaria con la que cuenta Colombia, 96% está en mal estado*. Obtenido de Del total de la red vial terciaria con la que cuenta Colombia, 96% está en mal estado: <https://www.larepublica.co/infraestructura/del-total-de-la-red-vial-terciaria-con-la-que-cuenta-colombia-96-esta-en-mal-estado-2828335>
- LANDAUER, Max [et al.]. (2023). Deep learning for anomaly detection in log data: A survey. Obtenido de <https://doi.org/10.1016/j.mlwa.2023.100470>
- LIA, Deru [et al.]. (2023). Clasificación y detección automatizadas de múltiples imágenes de deterioro del pavimento basadas en aprendizaje profundo. Obtenido de <https://doi.org/10.1016/j.jtte.2021.04.008>
- MARTINEZ, Erick [et al.]. (2023). Generalized Morse Wavelets parameter selection and transfer learning for pavement transverse cracking detection. Obtenido de <https://doi.org/10.1016/j.engappai.2023.106355>
- MAYORGA, Diego. (2023). *Diseño de un modelo de aprendizaje de máquina para reconocimiento y clasificación de daños en pavimento para vías de Sogamoso*. Universidad Nacional de Colombia, 1-31. Obtenido de <https://repositorio.unal.edu.co/handle/unal/84420>
- MUCHA, Luis [et al.]. (2021). Evaluación de procedimientos empleados para determinar la población y muestra en trabajos de investigación de posgrado. Obtenido de <https://doi.org/10.37711/desafios.2021.12.1.253>
- MURRAGARRA, Ana; Ruiz, Jenny. (2021). *Gestión de mantenimiento de pavimento de carreteras en base al modelo HDM-4 en diferentes países. una revisión sistemática*. Universidad priva del norte, 1-51. Obtenido de <https://repositorio.upn.edu.pe/bitstream/handle/11537/27190/Murrugarra%20Sanchez%2c%20Ana%20Liliana%20-%20Ruiz%20Olortegui%2c%20Jenny%20Yadira.pdf?sequence=1&isAllowed=y>
- NYIRANDAYISABYE, Ritha [et al.]. (2022). Predicciones automáticas de daños en el pavimento utilizando varios algoritmos de aprendizaje automático:

- evaluación y comparación. Obtenido de <https://doi.org/10.1016/j.rineng.2022.100657>
- ORTEGA, Julian. (2021). *Aprendizaje profundo para la detección automática de fisuras de hormigón usando redes neuronales convolucionales*. Universidad Politecnica de Valencia, 1-115. Obtenido de <https://riunet.upv.es/handle/10251/174954>
- PENG, Yujia [et al.]. (2023). The Tong Test: Evaluating Artificial General Intelligence Through Dynamic Embodied Physical and Social Interactions. Obtenido de <https://doi.org/10.1016/j.eng.2023.07.006>
- QURESHI, Waqar [et al.]. (2023). Deep learning framework for intelligent pavement condition rating: A direct classification approach for regional and local roads. Obtenido de <https://doi.org/10.1016/j.autcon.2023.104945>
- RODRÍGUEZ, Francisco. (2020). *Sistema automático para la detección y clasificación de grietas en pavimentos*. Universidad de Cordoba, 1-183. Obtenido de <https://helvia.uco.es/handle/10396/20499>
- SÁNCHEZ, Diana. (2022). *Técnicas e instrumentos de recolección de datos en investigación*. TEPEXI Boletín Científico de la Escuela Superior Tepeji del Río, 9, 38-39. Obtenido de <https://doi.org/10.29057/estr.v9i17.7928>
- SHADMANI, Alireza [et al.]. (2023). A review of machine learning and deep learning applications in wave energy forecasting and WEC optimization. Obtenido de <https://doi.org/10.1016/j.esr.2023.101180>
- SHAHA, Aarushi [et al.]. (2023). Un estudio integral sobre la detección del cáncer de piel mediante redes neuronales artificiales (ANN) y redes neuronales convolucionales (CNN). Obtenido de <https://doi.org/10.1016/j.ceh.2023.08.002>
- SHERSTINSKY, Alex. (2020). *ndamentos de la red neuronal recurrente (RNN) y la red de memoria a corto plazo (LSTM)*. Physica D: Fenómenos no lineales, 404, 1-12. Obtenido de <https://doi.org/10.1016/j.physd.2019.132306>

- SHU, Xiang [et al.]. (2022). Large-scale evaluation of pavement performance models utilizing automated pavement condition survey data. Obtenido de <https://doi.org/10.1016/j.ijtst.2021.09.003>
- SIERRA, J., & SANTOS, M. (2021). *Redes neuronales y aprendizaje por refuerzo en el control de turbinas eólicas*. Revista Iberoamericana de Automática e Informática industrial, 18(4), pp. 327–335. Obtenido de <https://doi.org/10.4995/riai.2021.16111>
- TELLO, Lizette [et al.]. (2021). *Detección de grietas en el pavimento usando técnicas de procesamiento de imágenes y redes neuronales artificiales*. Universidad del Valle, 1-9. Obtenido de <https://doi.org/10.26507/ponencia.1565>
- WANG, Huaping [et al.]. (2023). Monitoreo de la salud in situ de pavimentos de cemento y concreto basado en tecnología de detección de fibra óptica. Obtenido de <https://doi.org/10.1016/j.jreng.2022.09.003>
- YAO, Hui [et al.]. (2023). Informática industrial avanzada hacia carreteras inteligentes, seguras y sostenibles: un estado del arte. Obtenido de <https://doi.org/10.1016/j.jtte.2023.02.001>
- ZÚÑIGA, Yenmy. (2022). *Deep Learning Para la Detección de Fallas en Pavimentos de una Deep Learning Para la Detección de Fallas en Pavimentos de una*. Universidad César Vallejo, 1-126. Obtenido de <https://repositorio.ucv.edu.pe/handle/20.500.12692/93124>

ANEXOS

Anexo A.

Matriz de consistencia

Título: Aplicación de Técnicas de Deep Learning para la Detección de Anomalías en Pavimento de una zona del Distrito de “Socabaya”, 2024.						
Problema General	Objetivo General	Hipótesis General	Variables	Dimensión	Indicador	Metodología
¿En qué magnitud la ejecución de una aplicación móvil utilizando técnicas de Deep Learning en la detección de anomalías en pavimento de una zona del distrito de “Socabaya”, 2024?	Determinar en qué magnitud la ejecución de una aplicación móvil utilizando técnicas de Deep Learning en la detección de anomalías en pavimento de una zona del distrito de “Socabaya”, 2024	La ejecución de una aplicación móvil utilizando técnicas de Deep Learning influye directamente en la detección de anomalías en pavimento de una zona del distrito de “Socabaya”, 2024	Aplicación móvil utilizando técnicas de Deep Learning			Tipo de investigación: Aplicada Nivel de la investigación: Explicativa Diseño de la investigación: 1-pre-Experimental
Específicos: ¿En qué magnitud la ejecución de una aplicación móvil utilizando técnicas de Deep Learning interviene en la medición de las grietas y huecos en pavimento de una zona del distrito de “Socabaya”, 2024?	Específicos: Determinar en qué magnitud la ejecución de una aplicación móvil utilizando técnicas de Deep Learning interviene en la medición de las grietas y huecos en pavimento de una zona del distrito de “Socabaya”, 2024	Específicos: La ejecución de una aplicación móvil utilizando técnicas de Deep Learning influye directamente en la medición de las grietas y huecos en pavimento de una zona del distrito de “Socabaya”, 2024	Anomalías en Pavimento	Medición de las grietas y huecos en pavimento	Precisión Recall F1	
¿En qué magnitud la ejecución de una aplicación móvil utilizando técnicas de Deep Learning interviene en la detección de grietas y huecos en pavimento de una zona del distrito de “Socabaya”, 2024?	Determinar en qué magnitud la ejecución de una aplicación móvil utilizando técnicas de Deep Learning en la detección de grietas y huecos en pavimento de una zona del distrito de “Socabaya”, 2024	La ejecución de una aplicación móvil utilizando técnicas de Deep Learning influye directamente en la detección de grietas y huecos en pavimento de una zona del distrito de “Socabaya”, 2024		detección de grietas y huecos en pavimento		

Anexo B.

Operacionalización de variables

Variables de estudio	Definición conceptual	Definición operacional	Dimensión	Indicadores	Escala de medición
Independiente: Aplicación móvil utilizando técnicas de Deep Learning	Huang et al. (2023) describen que Deep Learning es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones.	La detección y gestión de estas anomalías es de vital importancia para garantizar la seguridad vial y prolongar la vida útil de las infraestructuras pavimentadas. En este sentido, la aplicación móvil desarrollada con técnicas de Deep Learning se convierte en una herramienta esencial.			
Dependiente: Anomalías en Pavimento	Por otra parte, Martínez et al. (2023) las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro.	En términos concretos, se trata de daños, irregularidades o situaciones inusuales que pueden afectar a carreteras, calles u otras áreas pavimentadas. Esta categoría abarca una variedad de condiciones anómalas, como grietas, baches, hundimientos, fisuras y desgaste excesivo, entre otros.	Medición y detección de grietas en pavimento	Precisión Recall F1	Razón
			Medición y detección de desprendimiento de agregados en pavimento		
			Medición y detección de piel de cocodrilo en pavimento		Razón

Anexo C.

Instrumento para el indicador Precisión

Investigador		Tipo de prueba	Pre-Test	Fórmula
Empresa Investigada				$P = TP / (TP + FP)$ P= Precisión TP= Tasa de Positivo FP= Falso Positivo
Indicador	Precisión			
ítem	Fecha	TP	CTIP	Precisión
1				
2				
3				
4				
5				
6				
7				
8				
9				
10				
11				
12				
13				
14				
15				

Anexo D.

Instrumento para el indicador recall

Investigador		Tipo de prueba	Pre-Test	Fórmula
Empresa Investigada				Recall= TP/TP+FP R= Recall TP= Tasa de Positivo FP= Falso Positivo
Indicador	Recall			
ítem	Fecha	TP	CTIP	Precisión
1				
2				
3				
4				
5				
6				
7				
8				
9				
10				
11				
12				
13				
14				
15				

Anexo E.

Instrumento para el indicador F1

Investigador		Tipo de prueba	Pre-Test	Fórmula
Empresa Investigada				F1= 2Recall+precision/ recall+ Precision
Indicador	F1			
ítem	Fecha	TP	CTIP	Precisión
1				
2				
3				
4				
5				
6				
7				
8				
9				
10				
11				
12				
13				
14				
15				

Anexo 6.

Tipos de aprendizaje de IA

Tipo de Aprendizaje	Descripción	Ejemplos de aplicaciones	ventajas	Desventajas
Aprendizaje Supervisado	Utiliza datos etiquetados con ejemplos de entrada y salida. El modelo se entrena para predecir salidas a partir de nuevas entradas.	Clasificación, Regresión	Alta precisión en predicciones, estructura clara del problema.	Dependencia de etiquetas, dificultad para obtener datos de etiquetas en algunos casos.
Aprendizaje No Supervisado	Utiliza datos sin etiquetar para descubrir patrones y estructuras intrínsecas en los datos.	Agrupamiento, Reducción de dimensionalidad	Descubrimiento de patrones ocultos, aplicable a datos no etiquetados.	Interpretación subjetiva de resultados, desafío para evaluar el rendimiento.
Aprendizaje por Refuerzo	El modelo interactúa con un entorno y aprende a tomar acciones para maximizar las recompensas a lo largo del tiempo.	Juegos, Robótica	Capacidad de aprendizaje autónomo, aplicable en entornos dinámicos.	Entrenamiento complejo, sensibilidad a la definición de recompensas.
Aprendizaje Profundo	Utiliza redes neuronales profundas para aprender características y patrones de los datos en capas sucesivas.	Reconocimiento de Imágenes, Procesamiento de Lenguaje Natural	Representaciones jerárquicas de datos, alta capacidad para abordar problemas complejos.	Requiere grandes conjuntos de datos, entrenamiento intensivo y ajuste de hiperparámetros.

Anexo 7.

Tipos de redes neuronales

Tipo de Red Neuronal	Descripción	Aplicaciones	Características Clave
perceptrón simple	Red de una sola capa de entrada y salida.	Clasificación lineal	Uso de ponderaciones y activación.
Redes Neuronales Multicapa	Capas de entrada, ocultas y salida.	Problemas complejos	Capacidad para aprender abstracciones.
Redes Neuronales Convolucionales (CNN)	Capas convolucionales y de pooling.	visión por computadora	Identificación de patrones en imágenes
Redes Neuronales Recurrentes (RNN)	Retroalimentación de salidas anteriores.	Procesamiento de lenguaje natural	Captura de relaciones temporales
Redes Neuronales LSTM	Variantes de RNN con puertas de memoria.	secuencias largas	Manejo de dependencias a largo plazo
Redes Neuronales Generativas Adversarias (GAN)	Generador y discriminador compiten.	Generación de contenido realista	Creación de contenido original
transformadores	Atención y procesamiento paralelo.	Procesamiento de lenguaje natural	Relaciones entre palabras en oraciones
Redes Neuronales Siamesas	Dos ramas idénticas para comparación de similitud.	Verificación de similitud	Aprendizaje de comparación

Anexo 8.

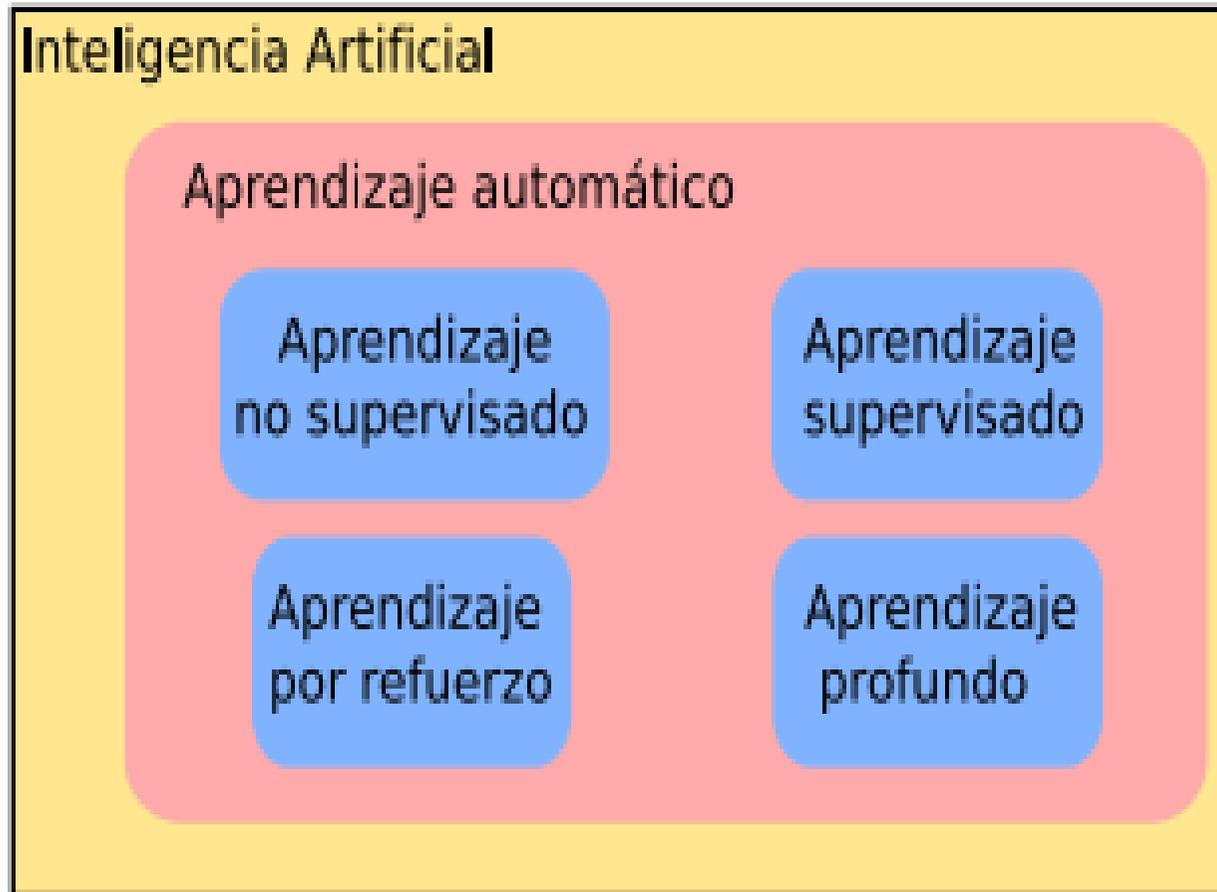
Tipos de Fallas en pavimento

Tipo de grieta	Descripción	Causas Comunes	Impacto
Grieta Transversal	Grietas perpendiculares al eje de la carretera.	Cambios de temperatura, cargas vehiculares.	Entrada de agua, agrandamiento de grietas, riesgo de baches y desprendimiento de material.
	Pueden ser continuas o espaciadas.	Efecto del envejecimiento.	
Grieta Longitudinal	Grietas paralelas al eje de la carretera.	Efecto del envejecimiento, cargas vehiculares.	Aumento del riesgo de deslizamiento y acumulación de agua.
	Pueden ser continuas o espaciadas.	Pobre drenaje.	
Piel de Cocodrilo	Patrón en forma de retícula similar a la piel de cocodrilo.	Acumulación de tensiones por cargas repetitivas.	Riesgo de desprendimiento de material, inseguridad vial por superficie resbaladiza.
	Indica daño profundo en capas del pavimento.	Fatiga del pavimento.	
Cuévano (Bache)	Depresión localizada en la superficie del pavimento.	Efecto del envejecimiento, cargas vehiculares.	Riesgo de daño a vehículos, peligro para conductores y peatones, deterioro rápido de la zona afectada.
	puede variar en tamaño.	Infiltración de agua, erosión.	

ANEXO 9: Cuadro comparativo con la metodología de desarrollo

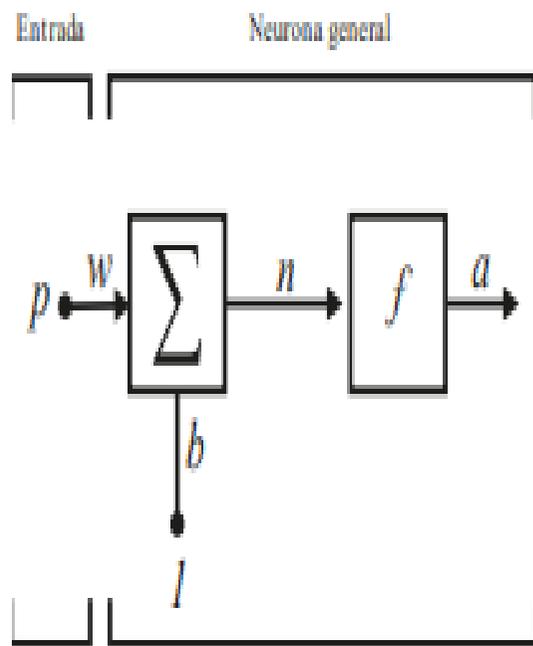
METODOLOGÍA		
XP	SCRUM	CommonKADS
Un conjunto de prácticas y reglas utilizadas en el desarrollo de software.	Un conjunto de mejores prácticas para trabajar en equipo y aprovechar al máximo sus proyectos. es un ciclo completo.	Un conjunto de mejores prácticas para trabajar a través de capas y modelos contextuales, conceptuales y de diseño.
<ul style="list-style-type: none"> - Comunicación. - opinión - Tiempo mínimo de alta calidad. - Reducir el seguimiento de errores - Coraje (satisfacción del programador) 	<ul style="list-style-type: none"> - Conocimientos necesarios para alcanzar los objetivos. - Involúcrate desde el principio y da un papel a cada uno. - Entregado a tiempo. 	<ul style="list-style-type: none"> - Conocimientos necesarios para alcanzar los objetivos. - Nos interesan las interrelaciones entre todos los procesos desde el principio. El artefacto final consta de una serie sistemática de actividades que permiten el correcto desarrollo del organismo. proyecto.
<ul style="list-style-type: none"> - Dificultades para determinar los costos del proyecto. - Utilizado principalmente para proyectos pequeños. 	<ul style="list-style-type: none"> - Los miembros del equipo se saltan pasos importantes en el camino hacia el sprint final. - Con demasiada frecuencia los avances son escasos. 	<ul style="list-style-type: none"> - Los miembros del proyecto están en contacto permanente a diferentes niveles.
<ul style="list-style-type: none"> - programador - Gerente de pruebas - Responsable de seguimiento - consultor 	<ul style="list-style-type: none"> - Los miembros del equipo se saltan pasos importantes en la ruta del sprint final. - Los avances suelen ser limitados. 	<ul style="list-style-type: none"> - Los proyectos pueden ser creados por un equipo de expertos con conocimientos de diseño, creación de prototipos y desarrollo de documentación adicional.
<ul style="list-style-type: none"> - La prueba intestinal. Se basa en evidencia de posibles errores. - Metodología basada en prueba y error. - Basado en valores y prácticas 	<ul style="list-style-type: none"> - Se basa en principios. - Reducir el costo de cambiar en cada paso. - Equipo muy capacitado. 	<ul style="list-style-type: none"> - Se basa en principios. - Reducir las transiciones de cambio en todas las etapas. - Equipo muy capacitado.

Ilustración 1: Inteligencia artificial



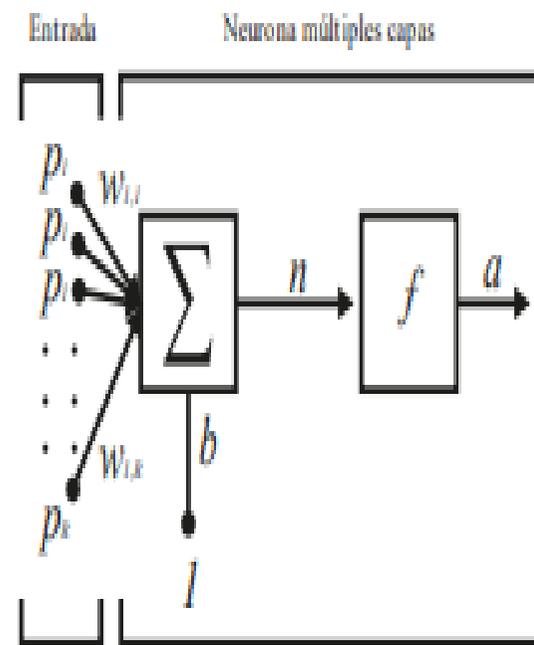
Fuente. Tomado de Peng et al. (2023).

Ilustración 2: Adaptación de las redes neuronales



$$a = f(wp + b)$$

a)

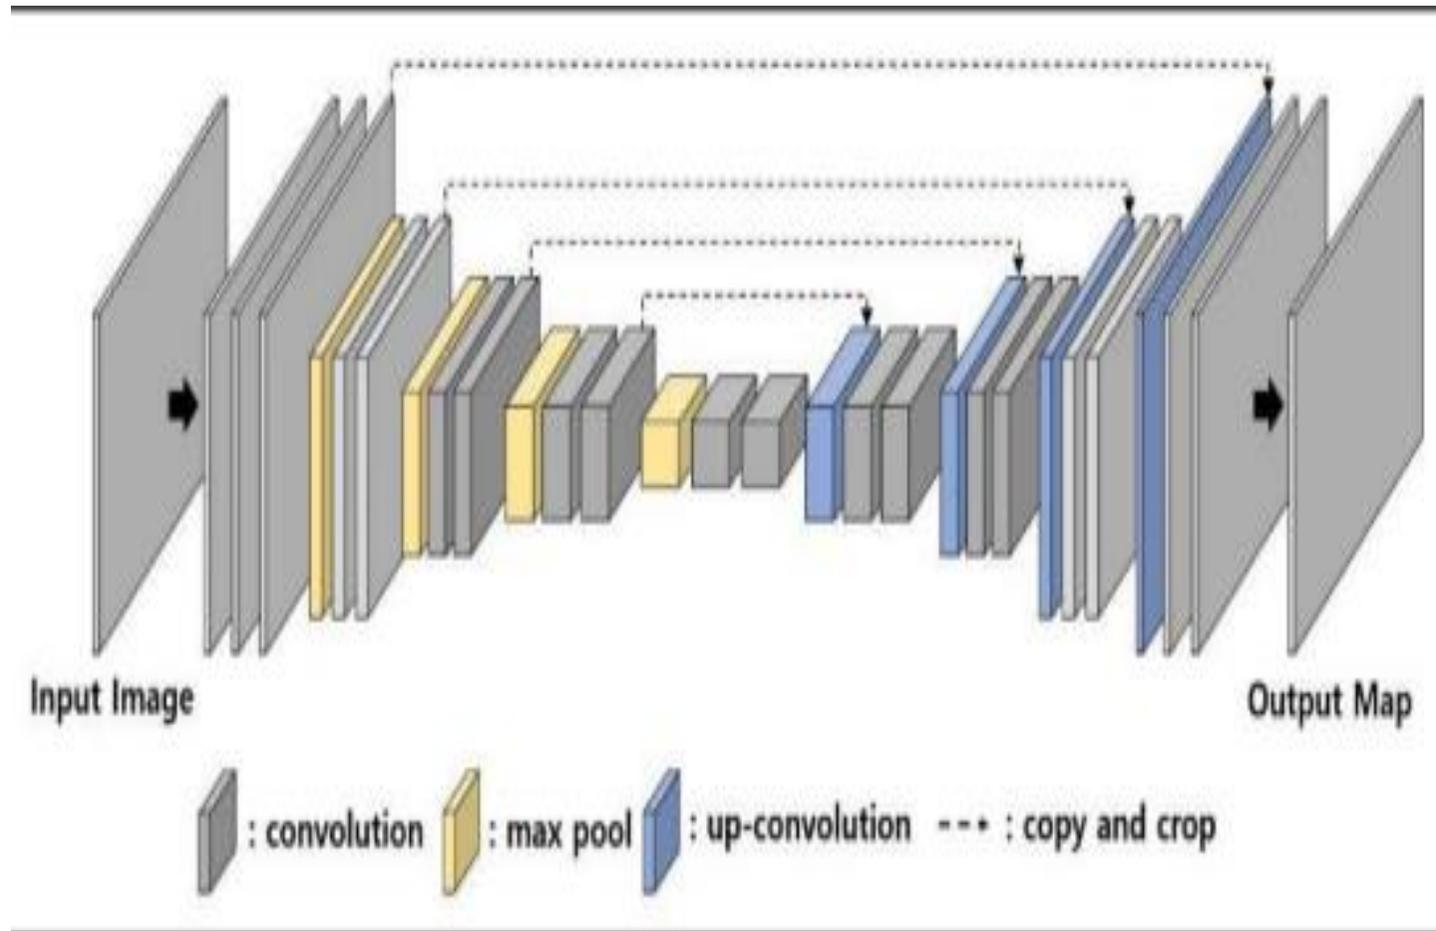


$$a = f(wp + b)$$

b)

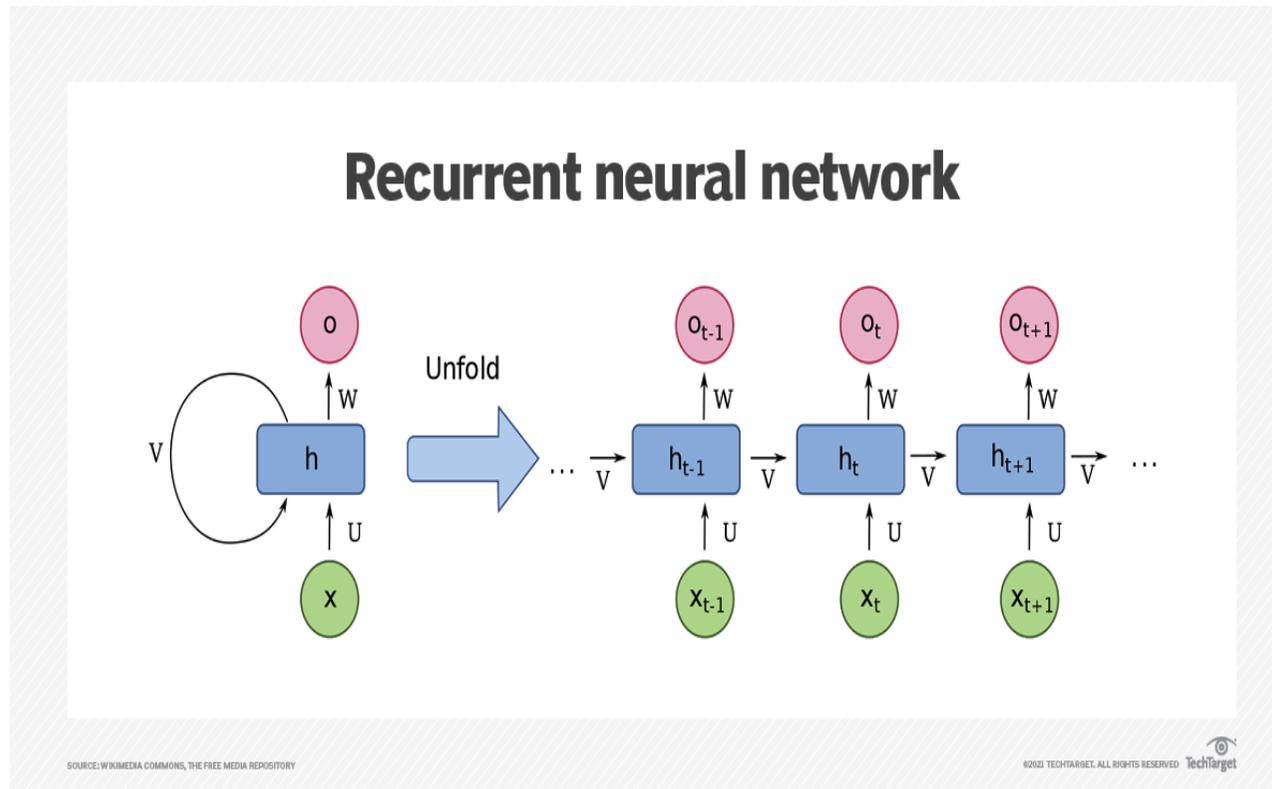
Fuente. Tomado de Landauer et al. (2023).

Ilustración 3: Estructura U-net CNN



Fuente. Tomado de Apicella et al. (2023).

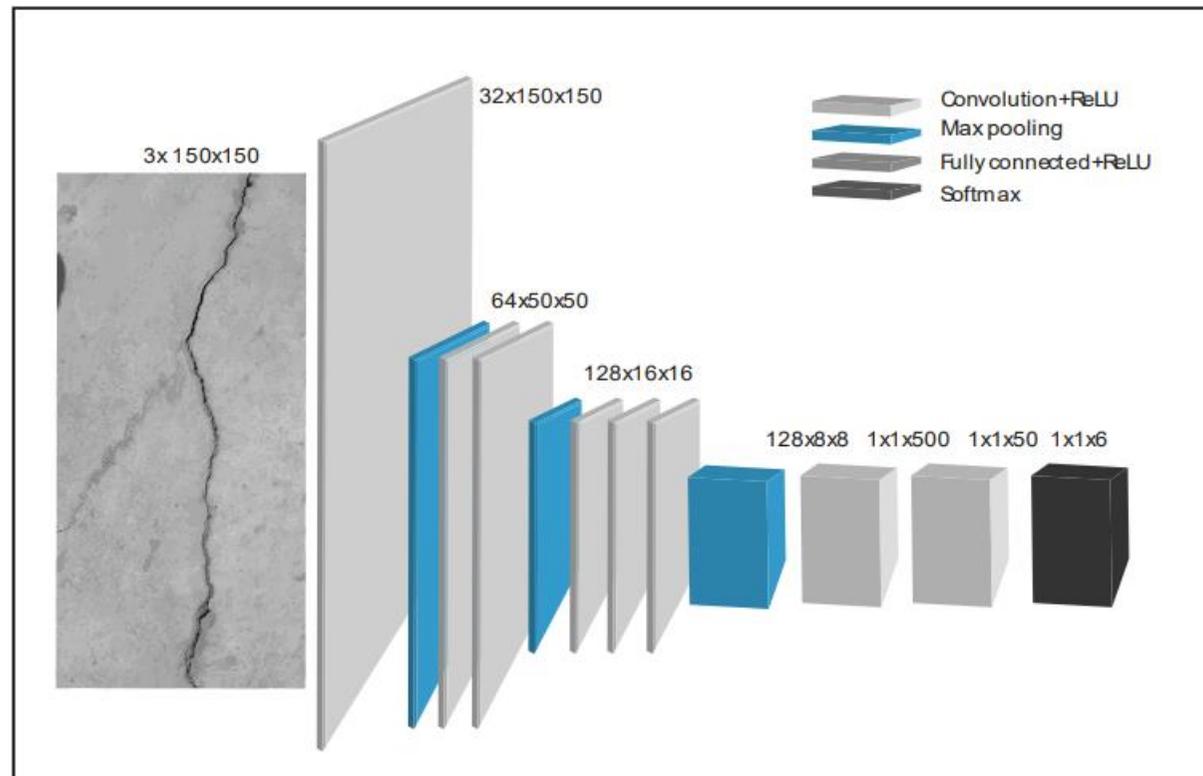
Ilustración 4: RNN Red Neuronal Recurrente



Fuente. Tomado de Cao et al. (2023)

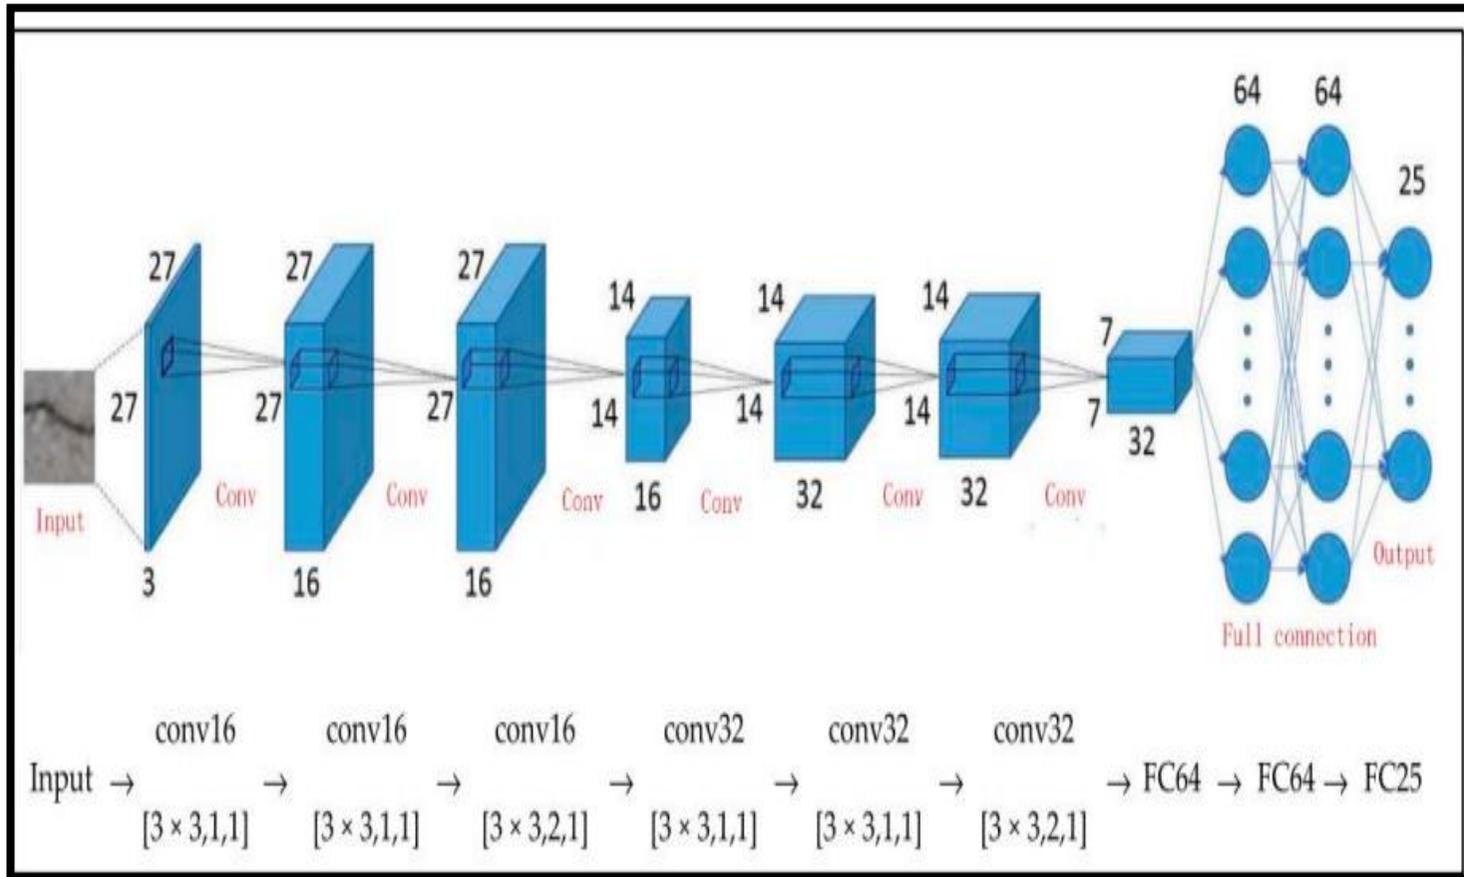
Anexo 13.

Ilustración 5: Estructura de red neuronal convolucional multicapas



Fuente: Tomado de Apicella et al. (2023).

Ilustración 6: Arquitectura de red neuronal convolucional



Fuente. Tomado de Apicella et al. (2023)

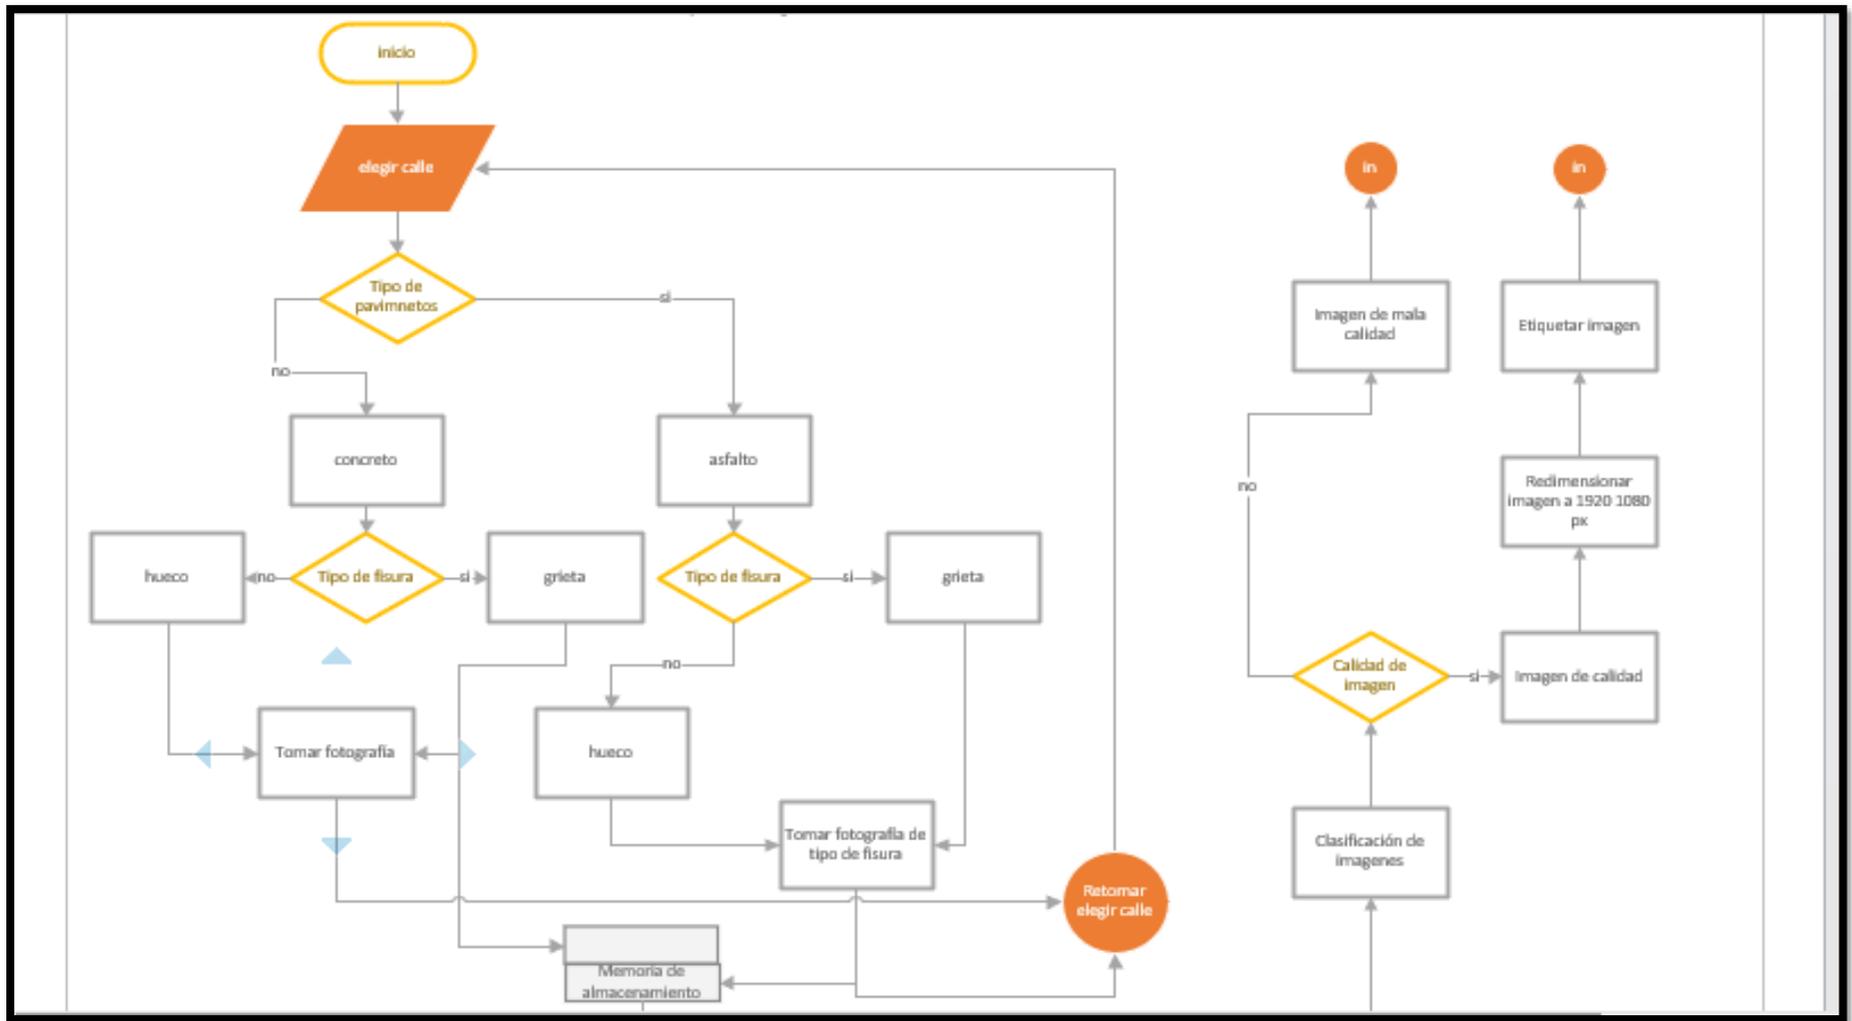


Ilustración 7: Diagrama de flujo de la captura de imagen

IdentificadorGHv1.ipynb ☆

Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardó por última vez: 16:00

+ Código + Texto

```

1 #instalar YOLOv5
2 !git clone https://github.com/ultralytics/yolov5 # repositorio YOLOv5
3 %cd yolov5
4 %pip install -qr requirements.txt # instalar las dependencias
5 %pip install -q roboflow
6
7 import torch
8 import os
9 from IPython.display import Image, clear_output # mostrara las imagenes
10
11 print(f"Setup complete. Using torch {torch.__version__} ({torch.cuda.get_device_properties(0).name if torch.cuda.is_available() else 'CPU'})")

```

Cloning into 'yolov5'...

```

remote: Enumerating objects: 12396, done.
remote: Counting objects: 100% (16/16), done.
remote: Compressing objects: 100% (14/14), done.
remote: Total 12396 (delta 4), reused 13 (delta 2), pack-reused 12380
Receiving objects: 100% (12396/12396), 12.18 MiB | 16.79 MiB/s, done.
Resolving deltas: 100% (8547/8547), done.
/content/yolov5

```

	596 kB	31.8 MB/s
	145 kB	53.9 MB/s
	178 kB	61.8 MB/s
	3.1 MB	6.0 MB/s
	1.1 MB	59.1 MB/s
	21.8 MB	1.2 MB/s
	67 kB	4.2 MB/s
	54 kB	2.9 MB/s
	138 kB	74.7 MB/s
	62 kB	1.5 MB/s

```

Building wheel for roboflow (setup.py) ... done
Building wheel for wget (setup.py) ... done
ERROR: pip's dependency resolver does not currently take into account all the packages that are installed. This behaviour is the source of the following errors.
google-colab 1.0.0 requires requests~=2.23.0, but you have requests 2.28.1 which is incompatible.
datascience 0.10.6 requires folium==0.2.1, but you have folium 0.8.3 which is incompatible.
albumations 0.1.12 requires imgaug<0.2.7,>=0.2.5, but you have imgaug 0.2.9 which is incompatible.
roboflow 0.2.7 requires Pillow==8.4.0, but you have pillow 7.1.2 which is incompatible.
Setup complete. Using torch 1.11.0+cu113 (Tesla T4)

```

```
[ ] 1 from google.colab import files
    2 uploaded = files.upload()

Elegir archivos Sin archivos seleccionados Upload widget is only available when the cell has been executed in the current browser session. Please rerun this cell to enable.
Saving dataset_clasificadorGH.zip to dataset_clasificadorGH.zip

[ ] 1 !pwd

/content/yolov5

[ ] 1 import zipfile
    2 import io
    3 data = zipfile.ZipFile(io.BytesIO(uploaded['dataset_clasificadorGH.zip']), 'r')
    4 data.extractall()
```

Ilustración 8: Instalación de la arquitectura YOLOv5

```

1 #Pasaremos algunos argumentos para el entrenamiento
2 |python train.py --img 640 --batch 16 --epochs 150 --data /content/yolov5/data/custom.yaml --weights yolov5x.pt --cache
{x}
train: weights=yolov5x.pt, cfg=, data=/content/yolov5/data/custom.yaml, hyp=data/hyps/hyp.scratch-low.yaml, epochs=150, batch_size=16, imgsz=640, rect=False, r
github: ⚠ YOLOv5 is out of date by 1 commit. Use `git pull` or `git clone https://github.com/ultralytics/yolov5` to update.
YOLOv5 🚀 v6.1-277-gfdc9d91 Python-3.7.13 torch-1.11.0+cu113 CUDA:0 (Tesla T4, 15110MiB)

hyperparameters: lr0=0.01, lr1=0.01, momentum=0.937, weight_decay=0.0005, warmup_epochs=3.0, warmup_momentum=0.8, warmup_bias_lr=0.1, box=0.05, cls=0.5, cls_pw
Weights & Biases: run 'pip install wandb' to automatically track and visualize YOLOv5 🚀 runs (RECOMMENDED)
TensorBoard: Start with 'tensorboard --logdir runs/train', view at http://localhost:6006/
Downloading https://ultralytics.com/assets/Arial.ttf to /root/.config/ultralytics/Arial.ttf...
100% 755k/755k [00:00<00:00, 120MB/s]
Downloading https://github.com/ultralytics/yolov5/releases/download/v6.1/yolov5x.pt to yolov5x.pt...
100% 166M/166M [00:26<00:00, 6.64MB/s]

Overriding model.yaml nc=80 with nc=2

      from  n  params module  arguments
0         -1  1     8800  models.common.Conv  [3, 80, 6, 2, 2]
1         -1  1    115520  models.common.Conv  [80, 160, 3, 2]
2         -1  4    309120  models.common.C3    [160, 160, 4]
3         -1  1    461440  models.common.Conv  [160, 320, 3, 2]
4         -1  8    2259200  models.common.C3    [320, 320, 8]
5         -1  1   1844480  models.common.Conv  [320, 640, 3, 2]
6         -1 12   13125120  models.common.C3    [640, 640, 12]
7         -1  1   7375360  models.common.Conv  [640, 1280, 3, 2]
8         -1  4   19676160  models.common.C3    [1280, 1280, 4]
9         -1  1   4099840  models.common.SPPF  [1280, 1280, 5]
10        -1  1    820480  models.common.Conv  [1280, 640, 1, 1]
11        -1  1         0  torch.nn.modules.upsampling.Upsample  [None, 2, 'nearest']
12       [-1, 6]  1         0  models.common.Concat  [1]
13        -1  4   5332480  models.common.C3    [1280, 640, 4, False]
14        -1  1    205440  models.common.Conv  [640, 320, 1, 1]
15        -1  1         0  torch.nn.modules.upsampling.Upsample  [None, 2, 'nearest']
16       [-1, 4]  1         0  models.common.Concat  [1]
17        -1  4   1335040  models.common.C3    [640, 320, 4, False]
18        -1  1    922240  models.common.Conv  [320, 320, 3, 2]
19       [-1, 14]  1         0  models.common.Concat  [1]
20        -1  4   4922880  models.common.C3    [640, 640, 4, False]
21        -1  1   3687680  models.common.Conv  [640, 640, 3, 2]
22       [-1, 10]  1         0  models.common.Concat  [1]
23        -1  4   19676160  models.common.C3    [1280, 1280, 4, False]
24       [17, 20, 23]  1    47103  models.yolo.Detect  [2, [[10, 13, 16, 30, 33, 23], [30, 61, 62, 45, 59, 119], [116, 90, 156, 198, 373, 1

Model summary: 567 layers, 86224543 parameters, 86224543 gradients, 204.6 GFLOPs

```

Ilustración 9: Proceso de entrenamiento

```

1 #Pasaremos algunos argumentos para el entrenamiento
2 !python train.py --img 640 --batch 16 --epochs 150 --data /content/yolov5/data/custom.yaml --weights yolov5x.pt --cache

```

albumentations: version 1.0.3 required by YOLOv5, but version 0.1.12 is currently installed
train: Scanning '/content/dataset_clasificadorGH/labels/train' images and labels...201 found, 0 missing, 0 empty, 0 corrupt: 100% 201/201 [00:00<00:00, 2260.06i
train: New cache created: /content/dataset_clasificadorGH/labels/train.cache
train: Caching images (0.1GB ram): 100% 201/201 [00:10<00:00, 19.40it/s]
val: Scanning '/content/dataset_clasificadorGH/labels/val' images and labels...100 found, 0 missing, 0 empty, 0 corrupt: 100% 100/100 [00:00<00:00, 1204.78it/s]
val: New cache created: /content/dataset_clasificadorGH/labels/val.cache
val: Caching images (0.1GB ram): 100% 100/100 [00:05<00:00, 17.15it/s]
Plotting labels to runs/train/exp/labels.jpg...

AutoAnchor: 3.83 anchors/target, 1.000 Best Possible Recall (BPR). Current anchors are a good fit to dataset ✔
Image sizes 640 train, 640 val
Using 2 dataloader workers
Logging results to runs/train/exp
Starting training for 150 epochs...

Epoch	gpu_mem	box	obj	cls	labels	img_size
0/149	13.3G	0.1082	0.03327	0.02923	44	640: 100% 13/13 [00:17<00:00, 1.37s/it]
	Class	Images	Labels	P	R	mAP@.5 mAP@.5:.95: 100% 4/4 [00:02<00:00, 1.09it/s]
	all	100	139	0.00247	0.503	0.00322 0.000714
Epoch	gpu_mem	box	obj	cls	labels	img_size
1/149	14.1G	0.09123	0.03256	0.02767	25	640: 100% 13/13 [00:14<00:00, 1.10s/it]
	Class	Images	Labels	P	R	mAP@.5 mAP@.5:.95: 100% 4/4 [00:01<00:00, 2.18it/s]
	all	100	139	0.00299	0.616	0.0209 0.00437
Epoch	gpu_mem	box	obj	cls	labels	img_size
2/149	14.1G	0.08269	0.03544	0.02517	22	640: 100% 13/13 [00:14<00:00, 1.11s/it]
	Class	Images	Labels	P	R	mAP@.5 mAP@.5:.95: 100% 4/4 [00:01<00:00, 2.32it/s]
	all	100	139	0.00368	0.784	0.0415 0.00959
Epoch	gpu_mem	box	obj	cls	labels	img_size
3/149	14.1G	0.07557	0.03165	0.02209	33	640: 100% 13/13 [00:14<00:00, 1.12s/it]

Ilustración 10: Precisión, recuperación y puntuación mAP (Sun et al., 2021)

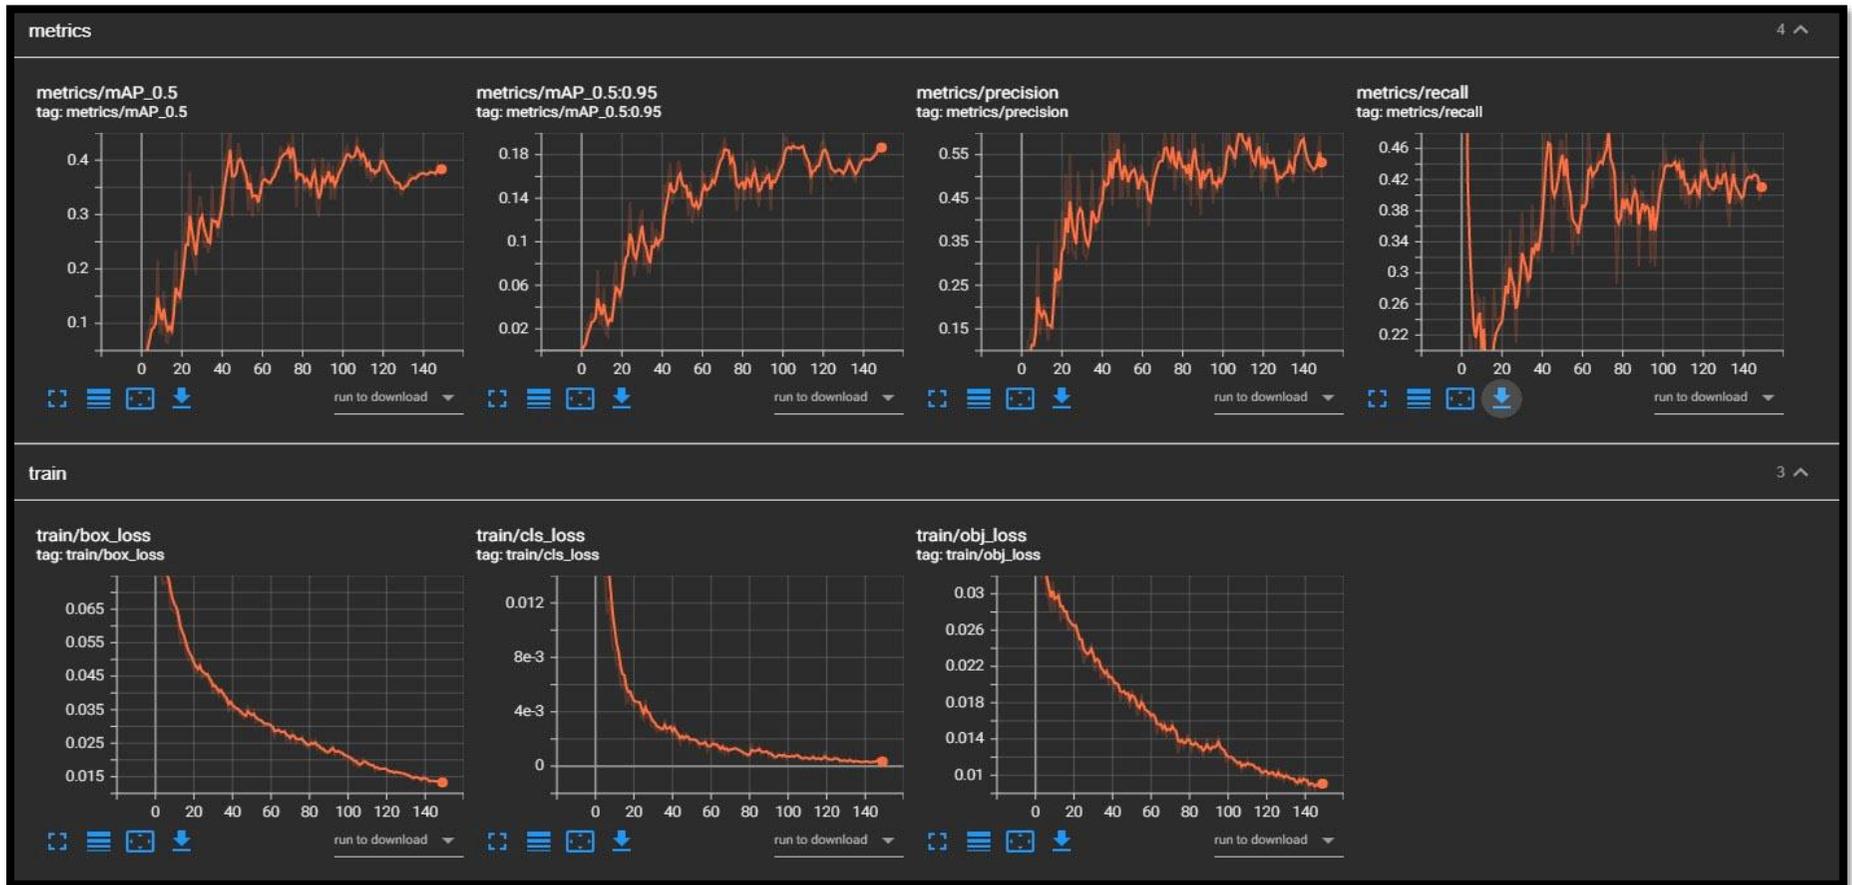


Ilustración 11: Estadísticas de auditoría y registro de resultados.

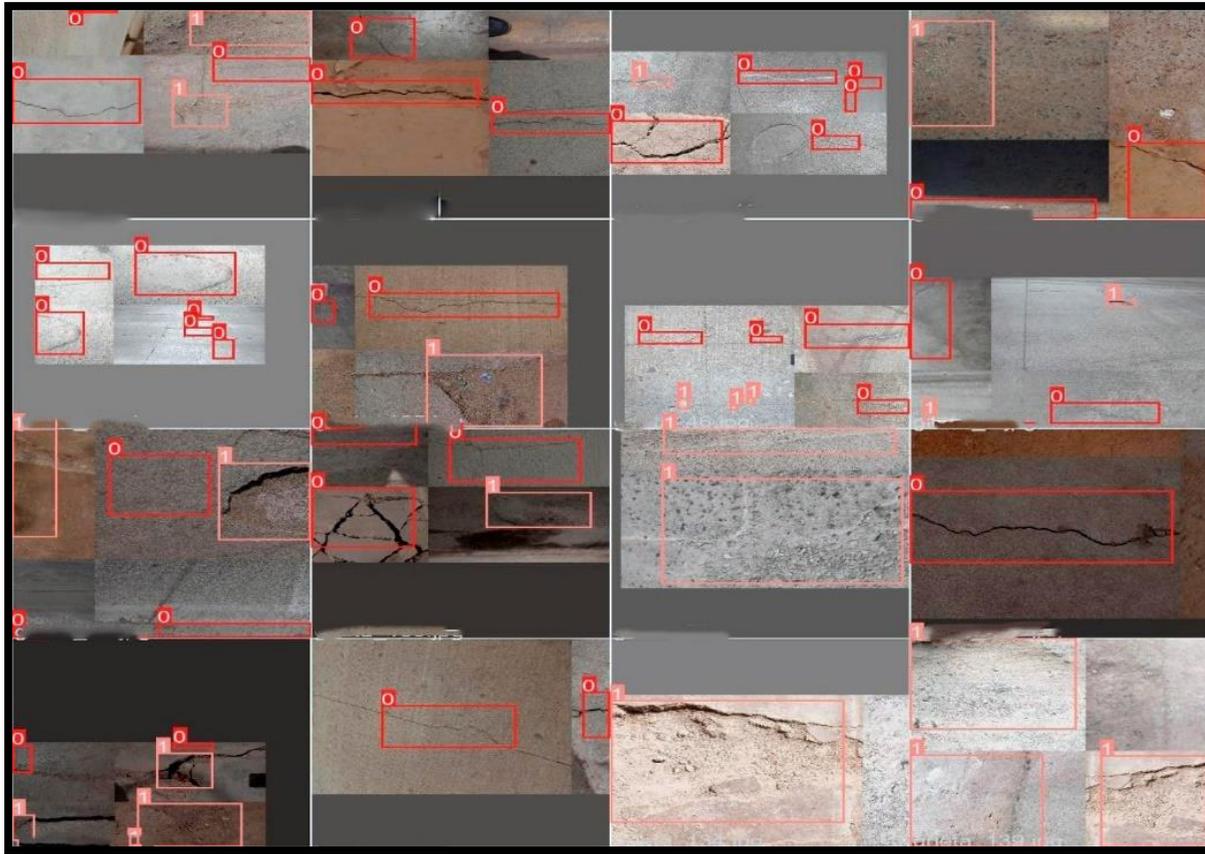


Ilustración 12: Dataset_classificacionGH Al informar los resultados obtenidos durante el entrenamiento, podemos comprobar la precisión de la detección de grietas y agujeros clasificados por los indicadores 0 y 1.



Ilustración 13: Es el resultado de una red neuronal convolucional utilizada para detectar grietas y agujeros en estructuras de carreteras como asfalto o pavimento de hormigón.

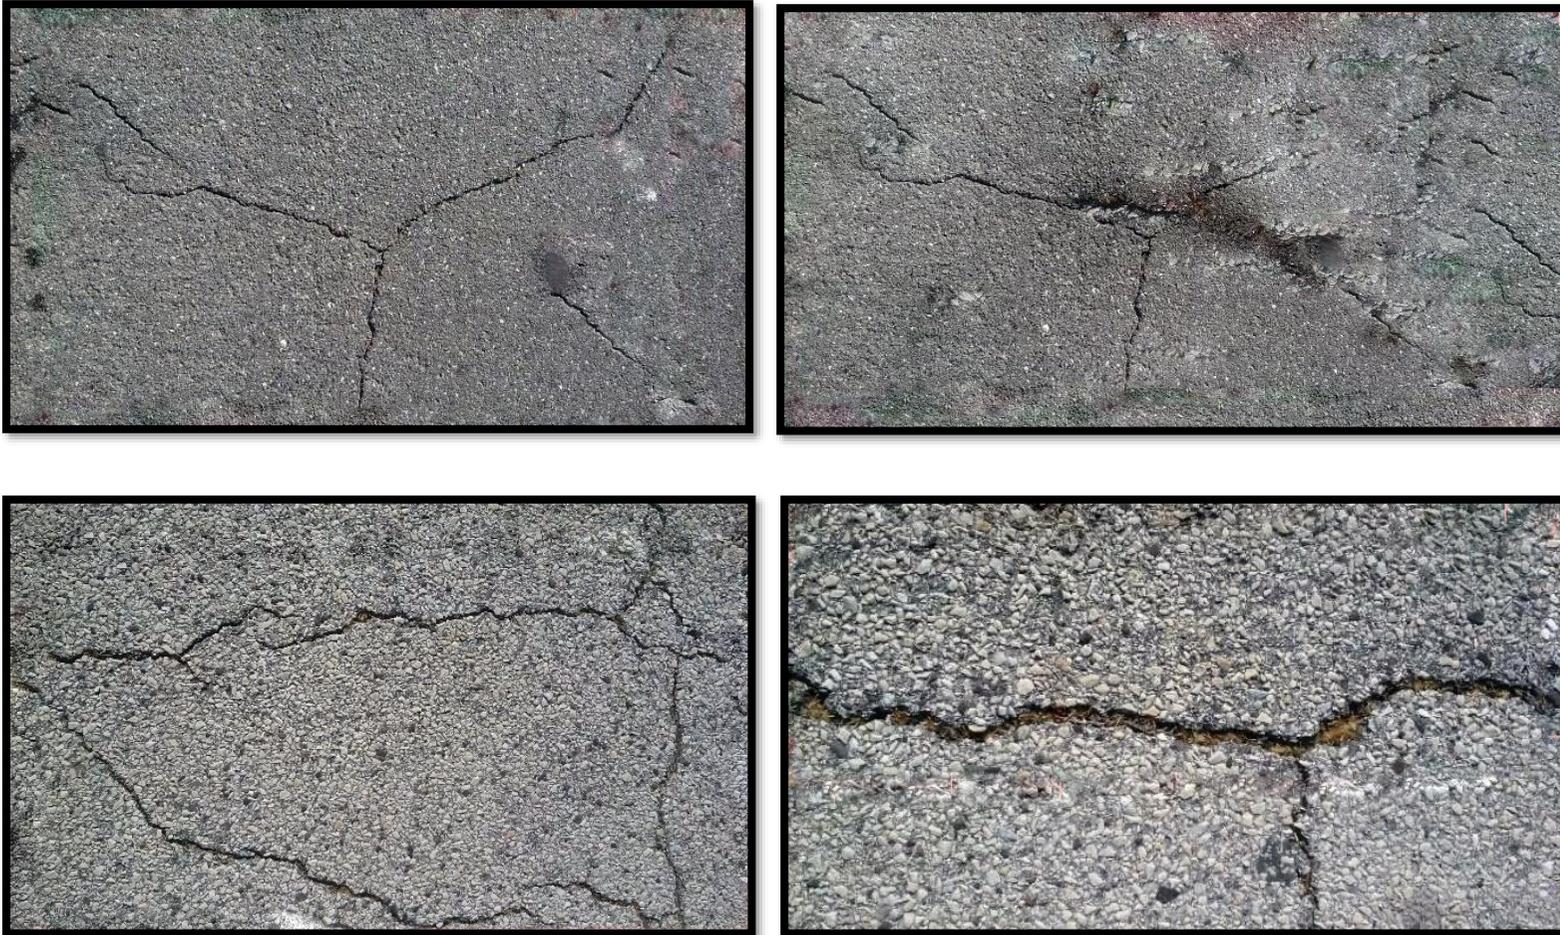


Ilustración 14: Ilustración que muestra un cuadro de identificación de grietas y agujeros en un pavimento asfáltico.

```
[ ] 1 !python detect.py --weights runs/train/exp/weights/best.pt --img 512 --conf 0.1 --source /content/dataset_clasificadorGH/

detect: weights=['runs/train/exp/weights/best.pt'], source=/content/dataset_clasificadorGH/test/images, data=data/coco128.ya
YOLOv5 v6.1-277-gfdc9d91 Python-3.7.13 torch-1.11.0+cu113 CUDA:0 (Tesla T4, 15110MiB)

Fusing layers...
Model summary: 444 layers, 86180143 parameters, 0 gradients, 203.8 GFLOPs
image 1/30 /content/dataset_clasificadorGH/test/images/test_1.jpg: 512x288 2 grietas, 1 hueco, Done. (0.046s)
image 2/30 /content/dataset_clasificadorGH/test/images/test_10.jpg: 512x288 1 hueco, Done. (0.046s)
image 3/30 /content/dataset_clasificadorGH/test/images/test_11.jpg: 288x512 1 hueco, Done. (0.050s)
image 4/30 /content/dataset_clasificadorGH/test/images/test_12.jpg: 288x512 1 hueco, Done. (0.049s)
image 5/30 /content/dataset_clasificadorGH/test/images/test_13.jpg: 512x288 1 hueco, Done. (0.046s)
image 6/30 /content/dataset_clasificadorGH/test/images/test_14.jpg: 512x288 1 hueco, Done. (0.046s)
image 7/30 /content/dataset_clasificadorGH/test/images/test_15.jpg: 512x288 1 hueco, Done. (0.046s)
image 8/30 /content/dataset_clasificadorGH/test/images/test_16.jpg: 512x288 1 hueco, Done. (0.046s)
image 9/30 /content/dataset_clasificadorGH/test/images/test_17.jpg: 512x288 1 hueco, Done. (0.046s)
image 10/30 /content/dataset_clasificadorGH/test/images/test_18.jpg: 512x288 1 hueco, Done. (0.046s)
image 11/30 /content/dataset_clasificadorGH/test/images/test_19.jpg: 512x288 1 hueco, Done. (0.046s)
image 12/30 /content/dataset_clasificadorGH/test/images/test_2.jpg: 512x288 1 grieta, 1 hueco, Done. (0.046s)
image 13/30 /content/dataset_clasificadorGH/test/images/test_20.jpg: 512x288 1 hueco, Done. (0.046s)
image 14/30 /content/dataset_clasificadorGH/test/images/test_21.jpg: 288x512 Done. (0.049s)
image 15/30 /content/dataset_clasificadorGH/test/images/test_22.jpg: 352x512 Done. (0.047s)
image 16/30 /content/dataset_clasificadorGH/test/images/test_23.jpg: 288x512 Done. (0.044s)
image 17/30 /content/dataset_clasificadorGH/test/images/test_24.jpg: 320x512 1 hueco, Done. (0.044s)
image 18/30 /content/dataset_clasificadorGH/test/images/test_25.jpg: 352x512 Done. (0.036s)
image 19/30 /content/dataset_clasificadorGH/test/images/test_26.jpg: 320x512 1 hueco, Done. (0.029s)
image 20/30 /content/dataset_clasificadorGH/test/images/test_27.jpg: 288x512 Done. (0.029s)
image 21/30 /content/dataset_clasificadorGH/test/images/test_28.jpg: 384x512 Done. (0.029s)
image 22/30 /content/dataset_clasificadorGH/test/images/test_29.jpg: 512x512 1 hueco, Done. (0.028s)
image 23/30 /content/dataset_clasificadorGH/test/images/test_3.jpg: 288x512 1 hueco, Done. (0.024s)
image 24/30 /content/dataset_clasificadorGH/test/images/test_30.jpg: 384x512 Done. (0.024s)
image 25/30 /content/dataset_clasificadorGH/test/images/test_4.jpg: 288x512 1 hueco, Done. (0.024s)
image 26/30 /content/dataset_clasificadorGH/test/images/test_5.jpg: 512x288 1 hueco, Done. (0.023s)
image 27/30 /content/dataset_clasificadorGH/test/images/test_6.jpg: 288x512 1 grieta, Done. (0.028s)
image 28/30 /content/dataset_clasificadorGH/test/images/test_7.jpg: 288x512 1 grieta, 1 hueco, Done. (0.024s)
image 29/30 /content/dataset_clasificadorGH/test/images/test_8.jpg: 288x512 1 hueco, Done. (0.024s)
image 30/30 /content/dataset_clasificadorGH/test/images/test_9.jpg: 512x288 1 hueco, Done. (0.023s)
Speed: 0.4ms pre-process, 37.7ms inference, 0.8ms NMS per image at shape (1, 3, 512, 512)
Results saved to runs/detect/exp2
```

Ilustración 15: Ilustración que muestra un cuadro de identificación de grietas y agujeros en un pavimento asfáltico.

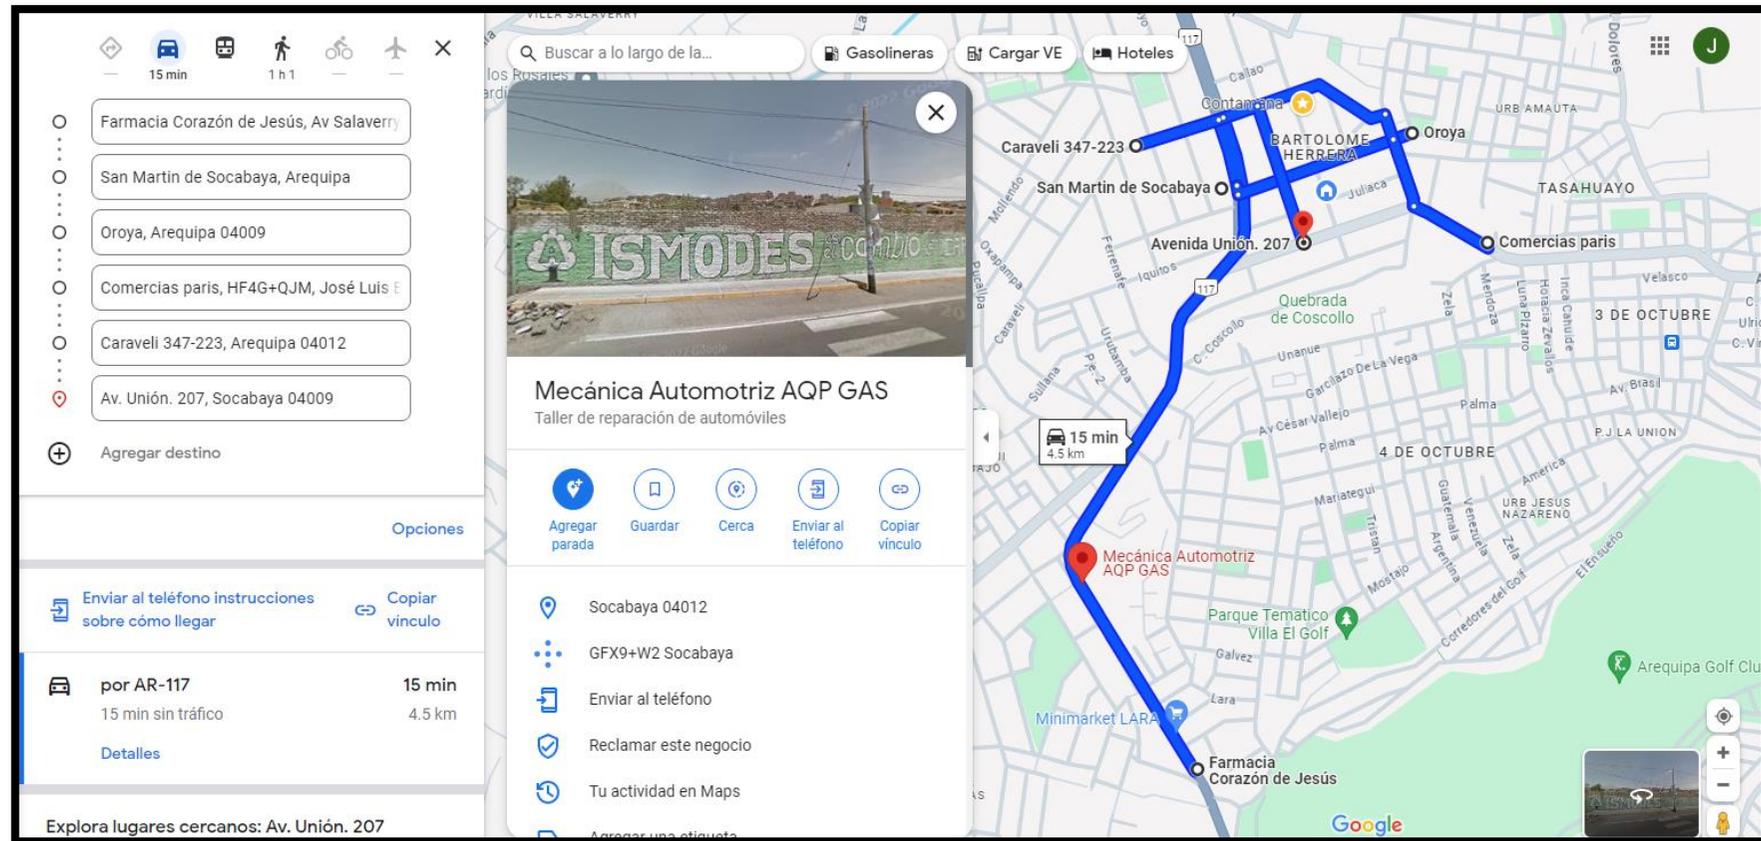
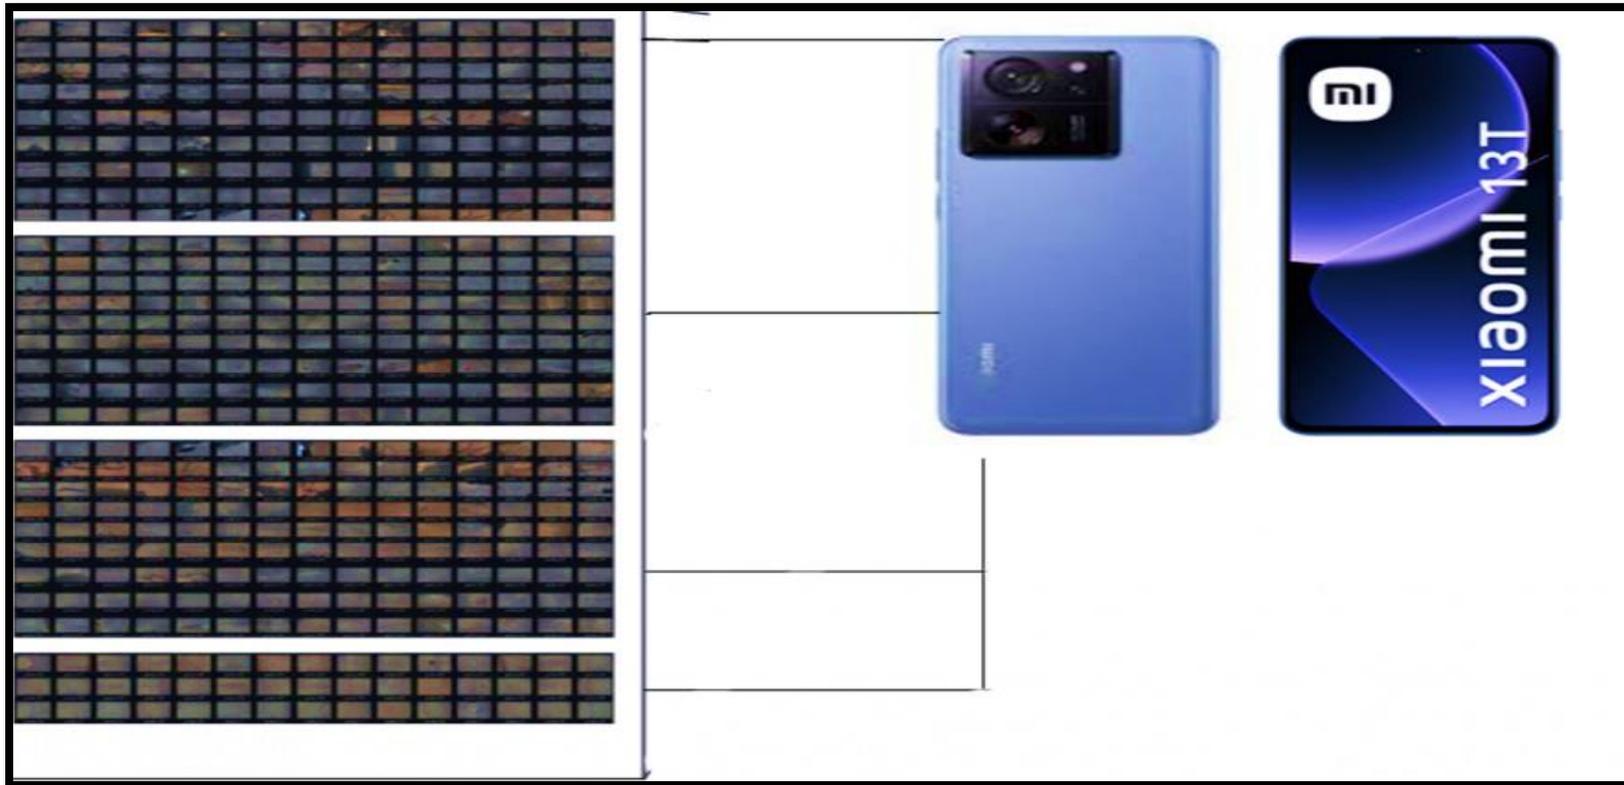


Ilustración 16: Lugar de prueba de estudios de captura de imágenes con el teléfono inteligente

Fuente: Elaboración propia



- **Procesador:** MediaTek Helio G99 Ultra
- **Cámara frontal:** 16 MP
- **Almacenamiento:** 256 GB
- **Memoria RAM:** 8 GB
- **Batería y carga:** De larga duración 5000 mAh | Carga Turbo de 67W | Carga de 0 a 50% en 15 min. Aprox.
- **Sensores:** Sensor lateral de huellas dactilares y desbloqueo facial por IA
- **Resistencia al agua y salpicaduras:** IP54

Ilustración 17: Captura de imágenes con el teléfono inteligente



Tabla 7: Registro estadístico de imágenes de pavimentos en el distrito de Socabaya

Tabla 8: Ficha de registro de las características de las clases de grietas y huecos

Clase	Defecto	Tipo de pavimento	Tipo de inspección	Formato	Tamaño real		Redimensión		Número de imágenes	Total por clase
					Anchura	Altura	Anchura	Altura		
Grieta	Grieta transversal	Cemento	Teléfono xiaomi	jpg	4160	3120	1920	1080	52	150
		Asfaltado	Teléfono xiaomi	jpg	4160	3120	1920	1080	12	
	Grieta longitudinal	Cemento	Teléfono xiaomi	jpg	4160	3120	1920	1080	34	
		Asfaltado	Teléfono xiaomi	jpg	4160	3120	1920	1080	8	
	Grieta de cocodrilo	Cemento	Teléfono xiaomi	jpg	4160	3120	1920	1080	20	
		Asfaltado	Teléfono xiaomi	jpg	4160	3120	1920	1080	24	
Hueco	Cubierta de pozo	Cemento	Teléfono xiaomi	jpg	4160	3120	1920	1080	43	100
		Asfaltado	Teléfono xiaomi	jpg	4160	3120	1920	1080	57	

Fuente. Elaboración propia

grieta_1	grieta_44	grieta_87	grieta_130	grieta_173	grieta_216	grieta_259	grieta_302	grieta_345	grieta_388
grieta_2	grieta_45	grieta_88	grieta_131	grieta_174	grieta_217	grieta_260	grieta_303	grieta_346	grieta_389
grieta_3	grieta_46	grieta_89	grieta_132	grieta_175	grieta_218	grieta_261	grieta_304	grieta_347	grieta_390
grieta_4	grieta_47	grieta_90	grieta_133	grieta_176	grieta_219	grieta_262	grieta_305	grieta_348	grieta_391
grieta_5	grieta_48	grieta_91	grieta_134	grieta_177	grieta_220	grieta_263	grieta_306	grieta_349	grieta_392
grieta_6	grieta_49	grieta_92	grieta_135	grieta_178	grieta_221	grieta_264	grieta_307	grieta_350	grieta_393
grieta_7	grieta_50	grieta_93	grieta_136	grieta_179	grieta_222	grieta_265	grieta_308	grieta_351	grieta_394
grieta_8	grieta_51	grieta_94	grieta_137	grieta_180	grieta_223	grieta_266	grieta_309	grieta_352	grieta_395
grieta_9	grieta_52	grieta_95	grieta_138	grieta_181	grieta_224	grieta_267	grieta_310	grieta_353	grieta_396
grieta_10	grieta_53	grieta_96	grieta_139	grieta_182	grieta_225	grieta_268	grieta_311	grieta_354	grieta_397
grieta_11	grieta_54	grieta_97	grieta_140	grieta_183	grieta_226	grieta_269	grieta_312	grieta_355	grieta_398
grieta_12	grieta_55	grieta_98	grieta_141	grieta_184	grieta_227	grieta_270	grieta_313	grieta_356	grieta_399
grieta_13	grieta_56	grieta_99	grieta_142	grieta_185	grieta_228	grieta_271	grieta_314	grieta_357	grieta_400
grieta_14	grieta_57	grieta_100	grieta_143	grieta_186	grieta_229	grieta_272	grieta_315	grieta_358	grieta_401
grieta_15	grieta_58	grieta_101	grieta_144	grieta_187	grieta_230	grieta_273	grieta_316	grieta_359	grieta_402
grieta_16	grieta_59	grieta_102	grieta_145	grieta_188	grieta_231	grieta_274	grieta_317	grieta_360	grieta_403
grieta_17	grieta_60	grieta_103	grieta_146	grieta_189	grieta_232	grieta_275	grieta_318	grieta_361	grieta_404
grieta_18	grieta_61	grieta_104	grieta_147	grieta_190	grieta_233	grieta_276	grieta_319	grieta_362	grieta_405
grieta_19	grieta_62	grieta_105	grieta_148	grieta_191	grieta_234	grieta_277	grieta_320	grieta_363	grieta_406
grieta_20	grieta_63	grieta_106	grieta_149	grieta_192	grieta_235	grieta_278	grieta_321	grieta_364	grieta_407
grieta_21	grieta_64	grieta_107	grieta_150	grieta_193	grieta_236	grieta_279	grieta_322	grieta_365	grieta_408
grieta_22	grieta_65	grieta_108	grieta_151	grieta_194	grieta_237	grieta_280	grieta_323	grieta_366	grieta_409
grieta_23	grieta_66	grieta_109	grieta_152	grieta_195	grieta_238	grieta_281	grieta_324	grieta_367	grieta_410
grieta_24	grieta_67	grieta_110	grieta_153	grieta_196	grieta_239	grieta_282	grieta_325	grieta_368	grieta_411
grieta_25	grieta_68	grieta_111	grieta_154	grieta_197	grieta_240	grieta_283	grieta_326	grieta_369	grieta_412
grieta_26	grieta_69	grieta_112	grieta_155	grieta_198	grieta_241	grieta_284	grieta_327	grieta_370	grieta_413
grieta_27	grieta_70	grieta_113	grieta_156	grieta_199	grieta_242	grieta_285	grieta_328	grieta_371	grieta_414
grieta_28	grieta_71	grieta_114	grieta_157	grieta_200	grieta_243	grieta_286	grieta_329	grieta_372	grieta_415
grieta_29	grieta_72	grieta_115	grieta_158	grieta_201	grieta_244	grieta_287	grieta_330	grieta_373	grieta_416
grieta_30	grieta_73	grieta_116	grieta_159	grieta_202	grieta_245	grieta_288	grieta_331	grieta_374	grieta_417
grieta_31	grieta_74	grieta_117	grieta_160	grieta_203	grieta_246	grieta_289	grieta_332	grieta_375	grieta_418
grieta_32	grieta_75	grieta_118	grieta_161	grieta_204	grieta_247	grieta_290	grieta_333	grieta_376	grieta_419
grieta_33	grieta_76	grieta_119	grieta_162	grieta_205	grieta_248	grieta_291	grieta_334	grieta_377	grieta_420
grieta_34	grieta_77	grieta_120	grieta_163	grieta_206	grieta_249	grieta_292	grieta_335	grieta_378	
grieta_35	grieta_78	grieta_121	grieta_164	grieta_207	grieta_250	grieta_293	grieta_336	grieta_379	
grieta_36	grieta_79	grieta_122	grieta_165	grieta_208	grieta_251	grieta_294	grieta_337	grieta_380	
grieta_37	grieta_80	grieta_123	grieta_166	grieta_209	grieta_252	grieta_295	grieta_338	grieta_381	
grieta_38	grieta_81	grieta_124	grieta_167	grieta_210	grieta_253	grieta_296	grieta_339	grieta_382	
grieta_39	grieta_82	grieta_125	grieta_168	grieta_211	grieta_254	grieta_297	grieta_340	grieta_383	
grieta_40	grieta_83	grieta_126	grieta_169	grieta_212	grieta_255	grieta_298	grieta_341	grieta_384	
grieta_41	grieta_84	grieta_127	grieta_170	grieta_213	grieta_256	grieta_299	grieta_342	grieta_385	
grieta_42	grieta_85	grieta_128	grieta_171	grieta_214	grieta_257	grieta_300	grieta_343	grieta_386	
grieta_43	grieta_86	grieta_129	grieta_172	grieta_215	grieta_258	grieta_301	grieta_344	grieta_387	

Ilustración 18: Asignación de nombre a las imágenes capturadas

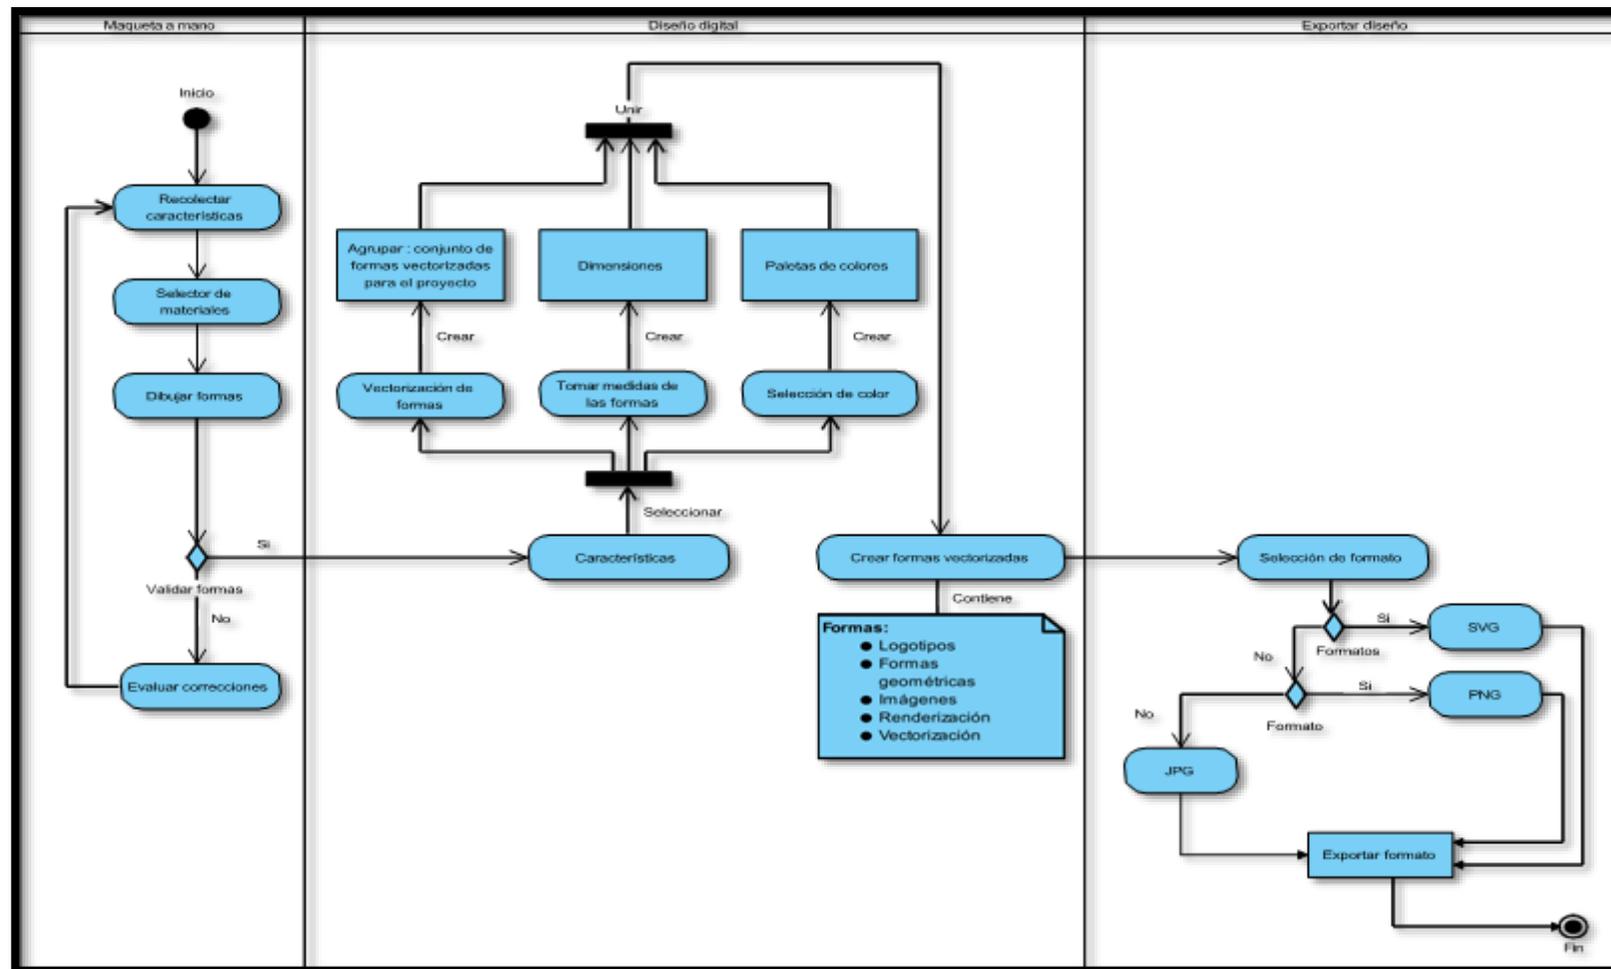


Ilustración 19: Diagrama de flujo para el diseño del aplicativo denominado

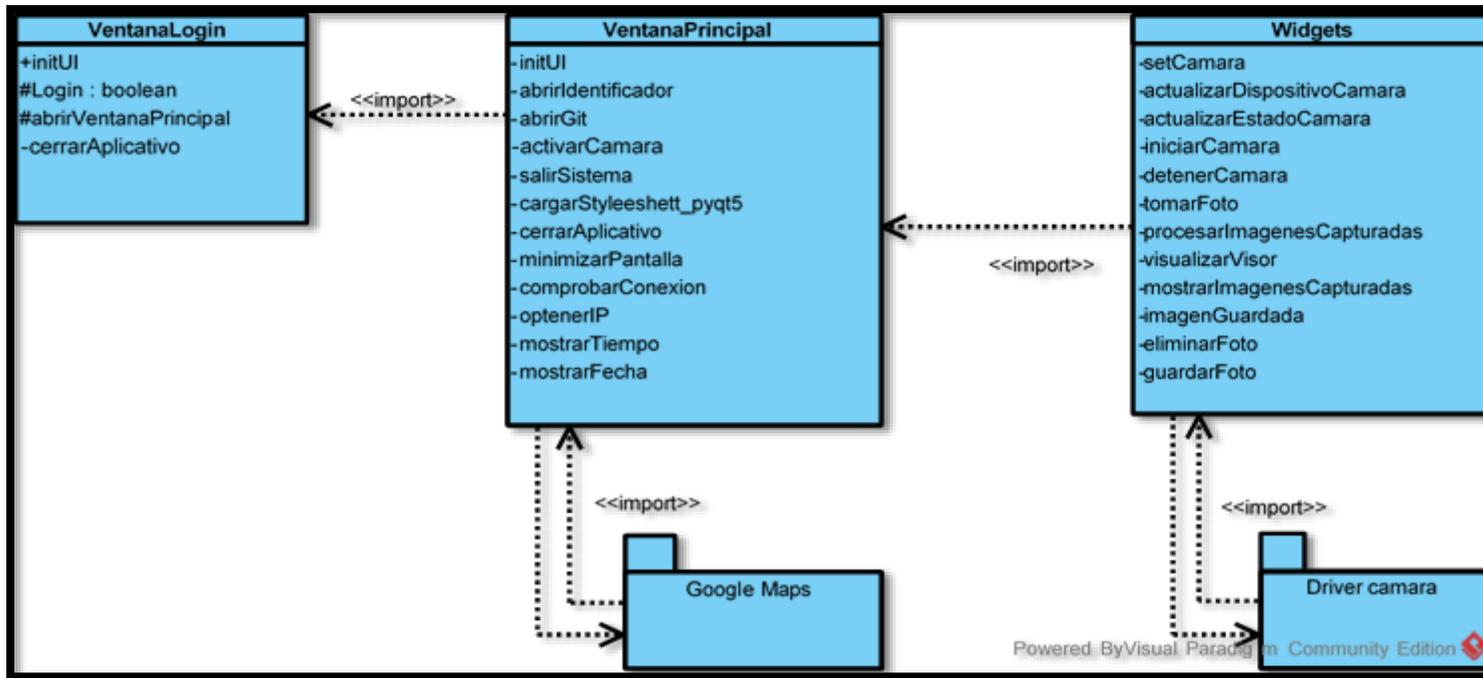


Ilustración 20: Diagrama de clases, representa la visualización de las funciones y clases implementadas en el aplicativo

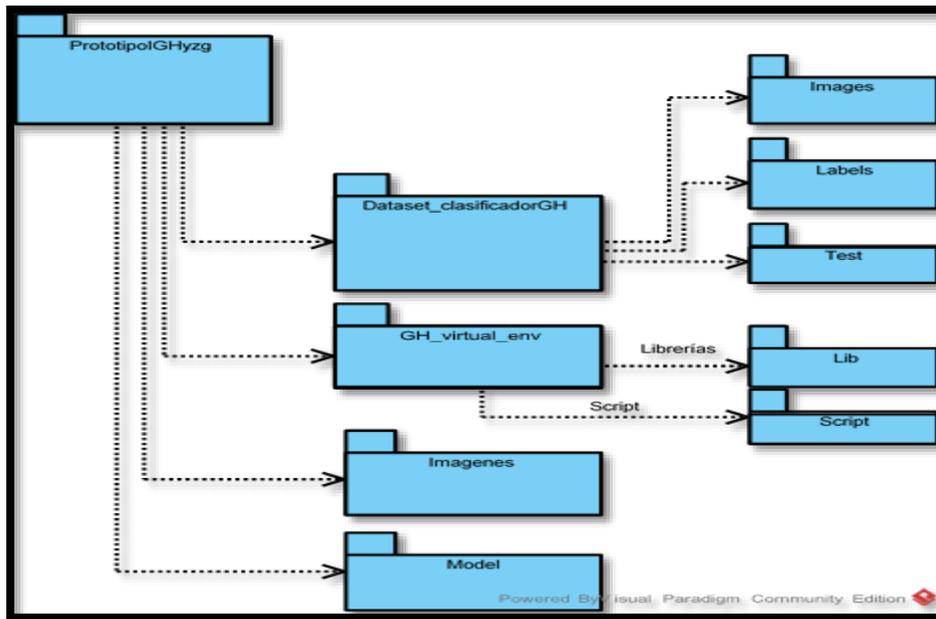


Ilustración 21: Diagrama de paquetes

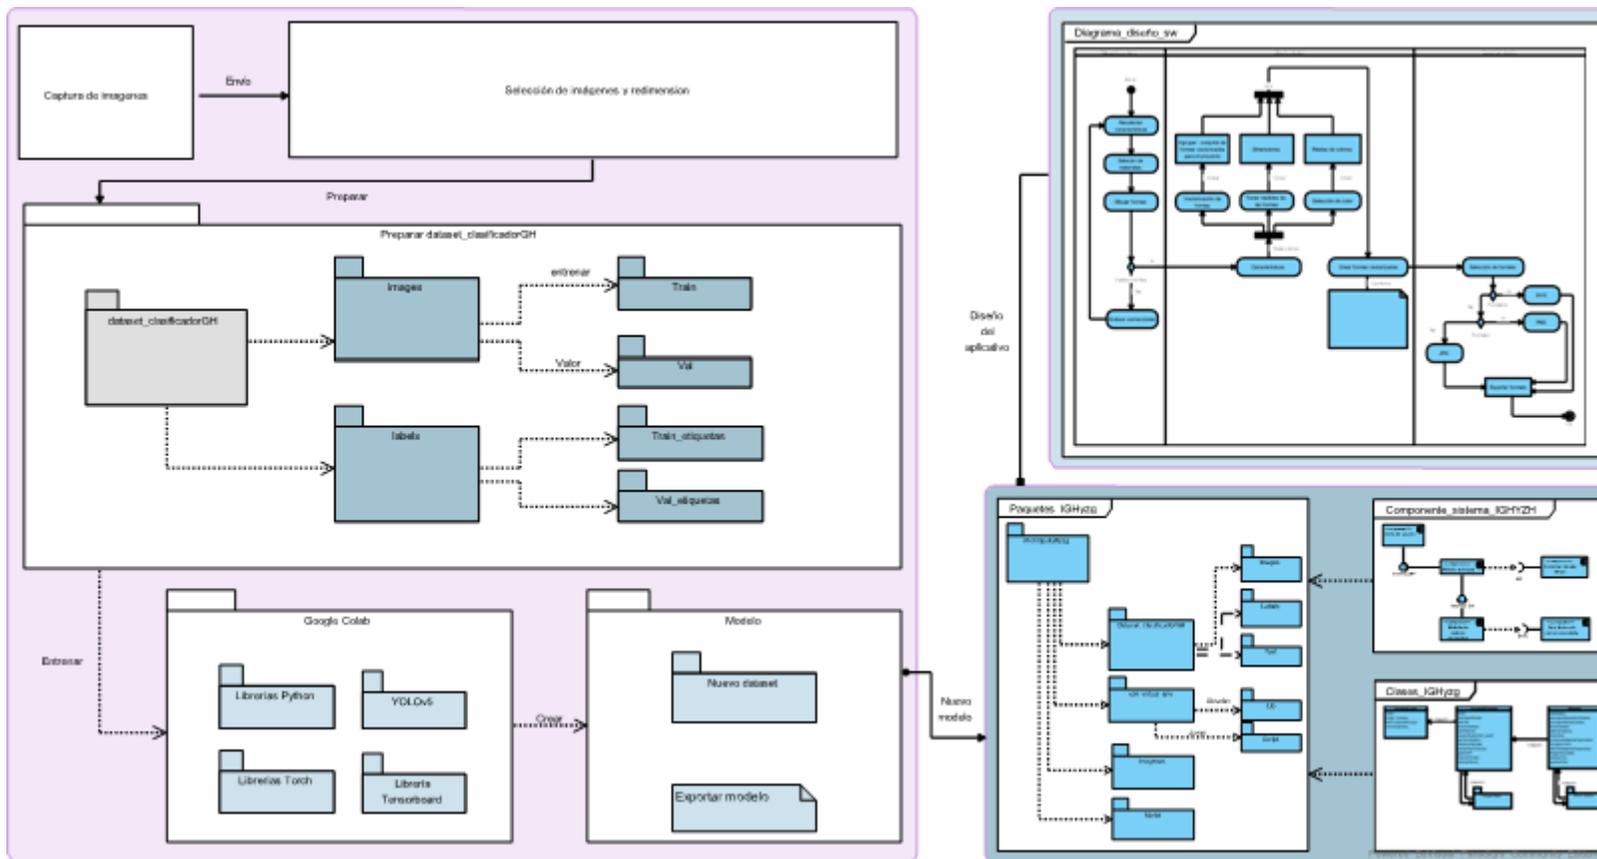


Ilustración 22: Arquitectura para el desarrollo del sistema inteligente

```

    IGHYZG_login.py
    usuario = self.lineEditUsuario.text()
    contraseña = self.lineEditContraseña.text()

    print("Usuario:", usuario)
    print("Contraseña:", contraseña)

    try:
        with open('data.json') as file:
            data = json.load(file)
            for usuarioData in data['usuarios']:
                validarUsu = usuarioData['nombre']
                if usuario == validarUsu:
                    msg.information(self, "Correcto", "Usuario autenticado", QMessageBox.Ok)
                    print("bienvenido")
                    self.abrirVentanaPrincipal()
                    break
                else:
                    msg.warning(self, "Error", "Usuario incorrecto", QMessageBox.Ok)
                    break
    except:
        print("sin respuesta")

    self.lineEditUsuario.clear()
    self.lineEditContraseña.clear()

    def abrirVentanaPrincipal(self):
        self.Principal_win = ventanaPrincipal(self)
        self.Principal_win.show()
        self.destroy()

    def cerrarAplicativo(self):
        ventanaLogin

    IGHYZG_ventana_principal.py
    import sys
    from PyQt5.QtGui import QIcon, QPalette, QColor, QLinearGradient, QPixmap, QFont
    from PyQt5.QtCore import Qt, QSize, QTimer, QTime
    from PyQt5 import QtCore
    from PyQt5.QtCore import QUrl
    from PyQt5.QtWebEngineWidgets import QWebEngineView
    from PyQt5.QtWidgets import (QApplication, QMainWindow, QDialog, QLineEdit, QPushButton, QLabel,
        QWidget, QDesktopWidget, QFrame, QMenu, QMessageBox)
    from ctypes import windll, byref
    from datetime import datetime
    from ctypes.wintypes import DWORD
    import socket
    import os

    from IGHYZG_camara import tomarFoto
    from Detect import iniciarVideo
    from IGHYZG_analizar_image import iniciarVentanaImagen

    def cargar_stylesheet(self):
        archivo = QtCore.QFile('UI_Estilos_yzuguui.qss')

        try:
            if not archivo.exists():
                print("No existe el archivo")
            else:
                archivo.open(QtCore.QFile.ReadOnly | QtCore.QFile.Text)
                ts = QtCore.QTextStream(archivo)
                estilos = ts.readAll()
                return estilos
        except:
            print("No se pudo cargar los iconos")

    ventanaPrincipal initUI()
  
```

Ilustración 23: Escritura de código de los módulos denominados login.py, ventana_principal.py

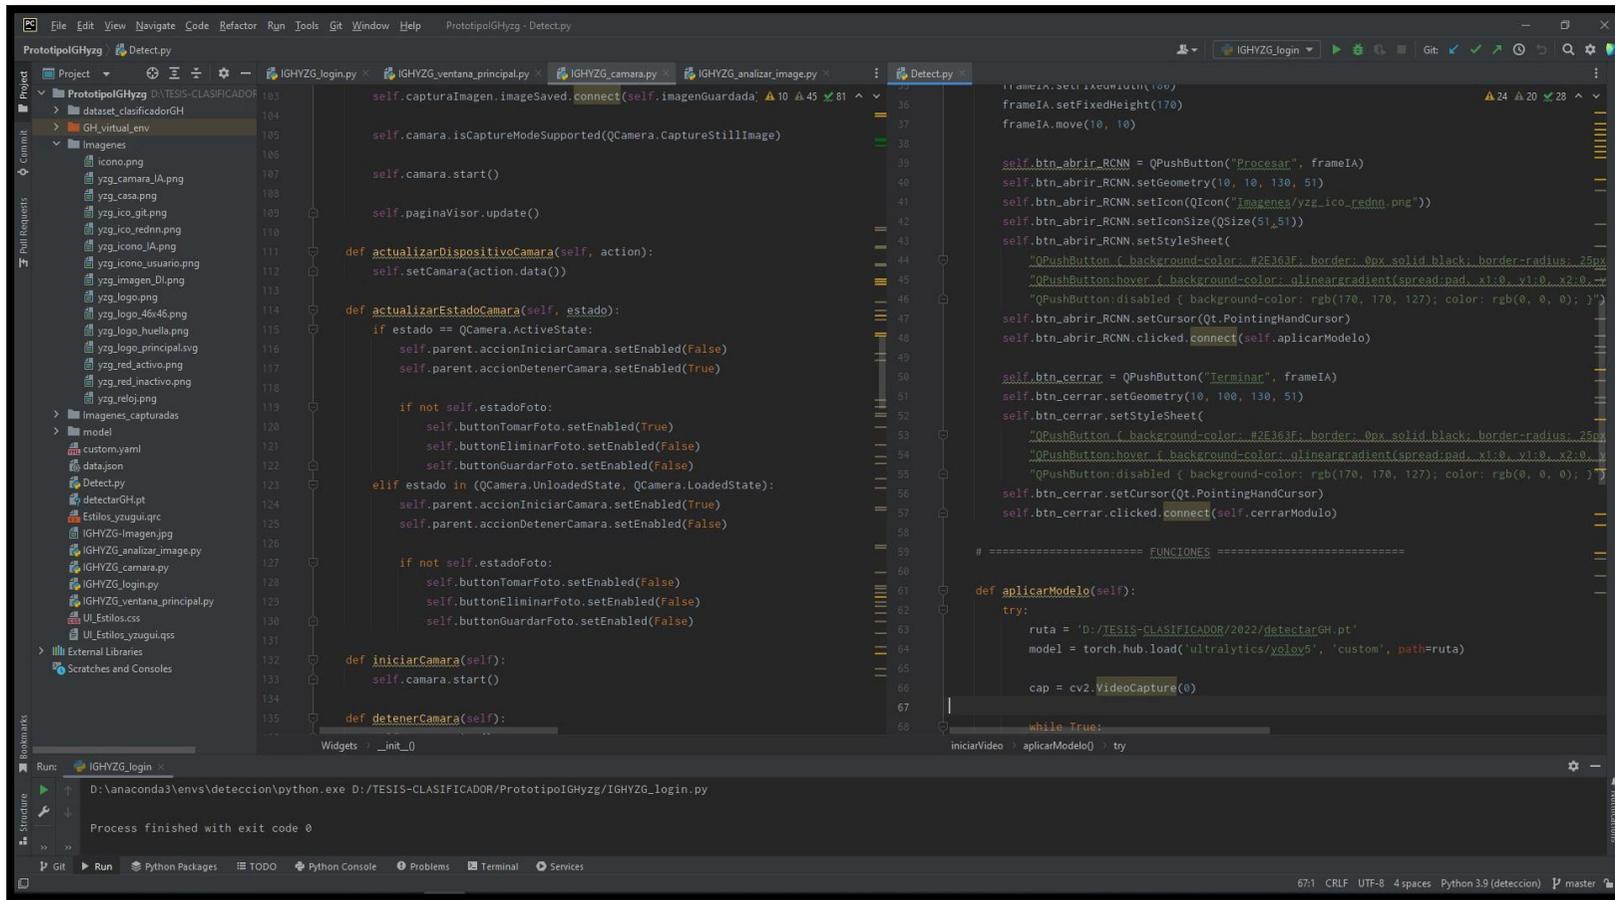


Ilustración 24: Escritura de código de los módulos denominados camara.py, Detect.py

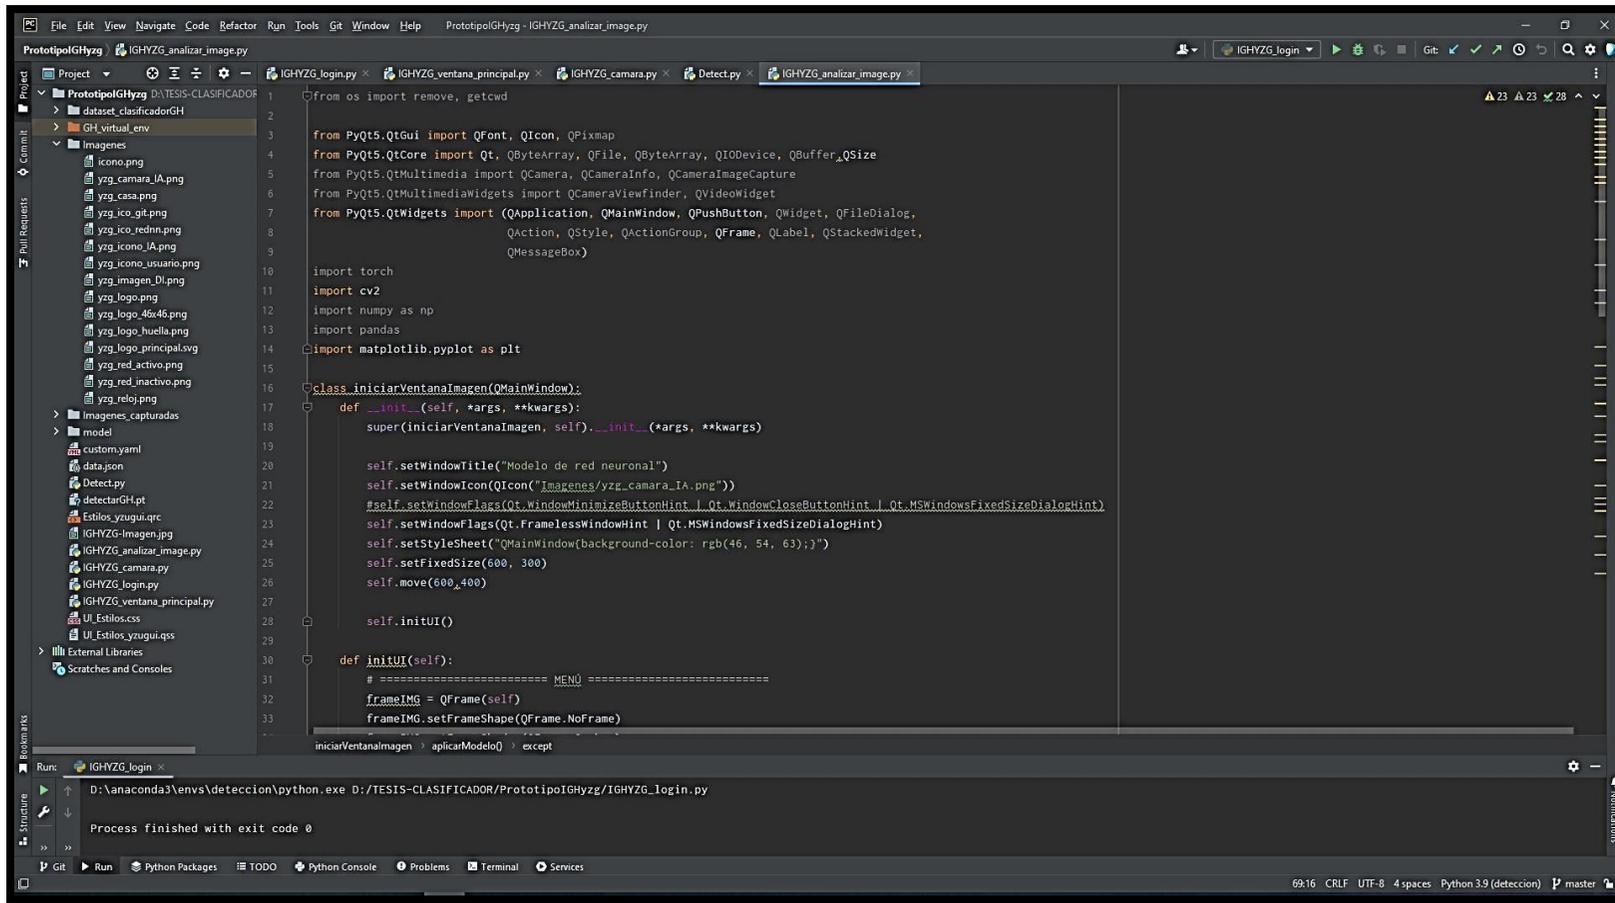


Ilustración 25: Escritura de código de los módulos denominados analizar_image.py

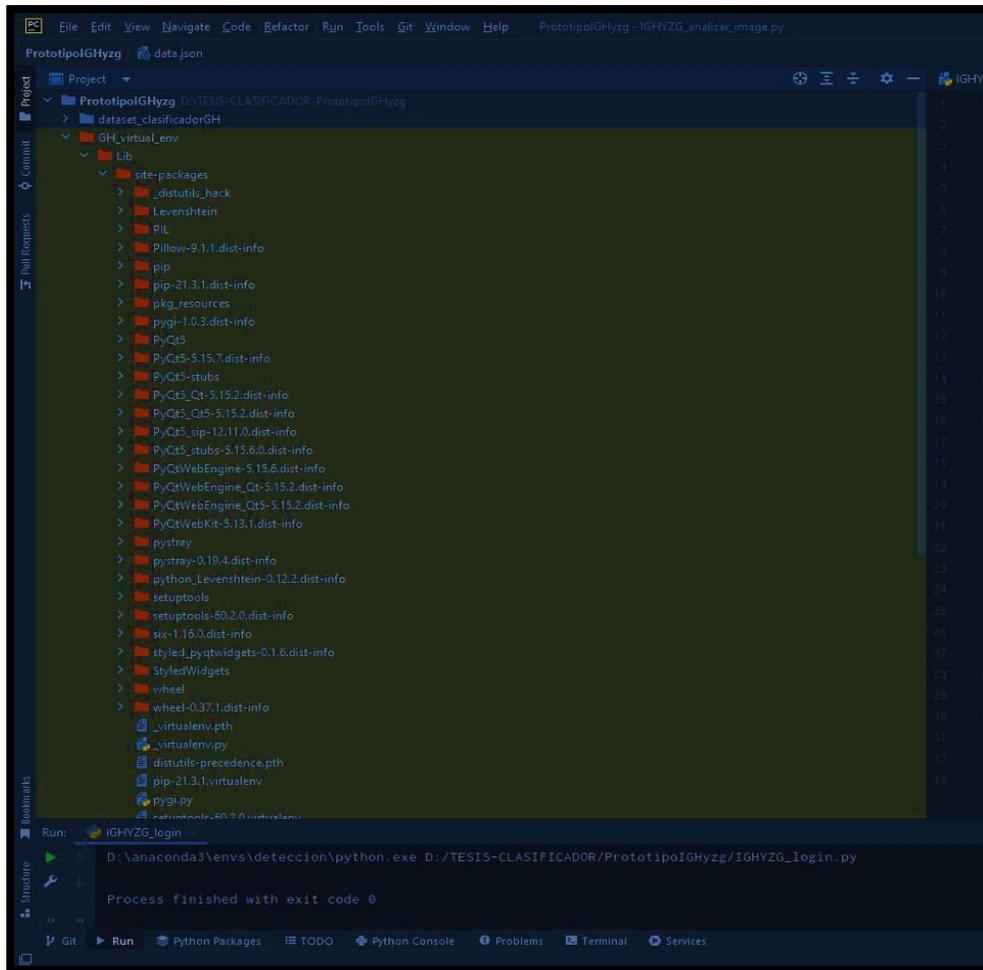


Ilustración 26: Listado de librerías instaladas para el funcionamiento del aplicativo

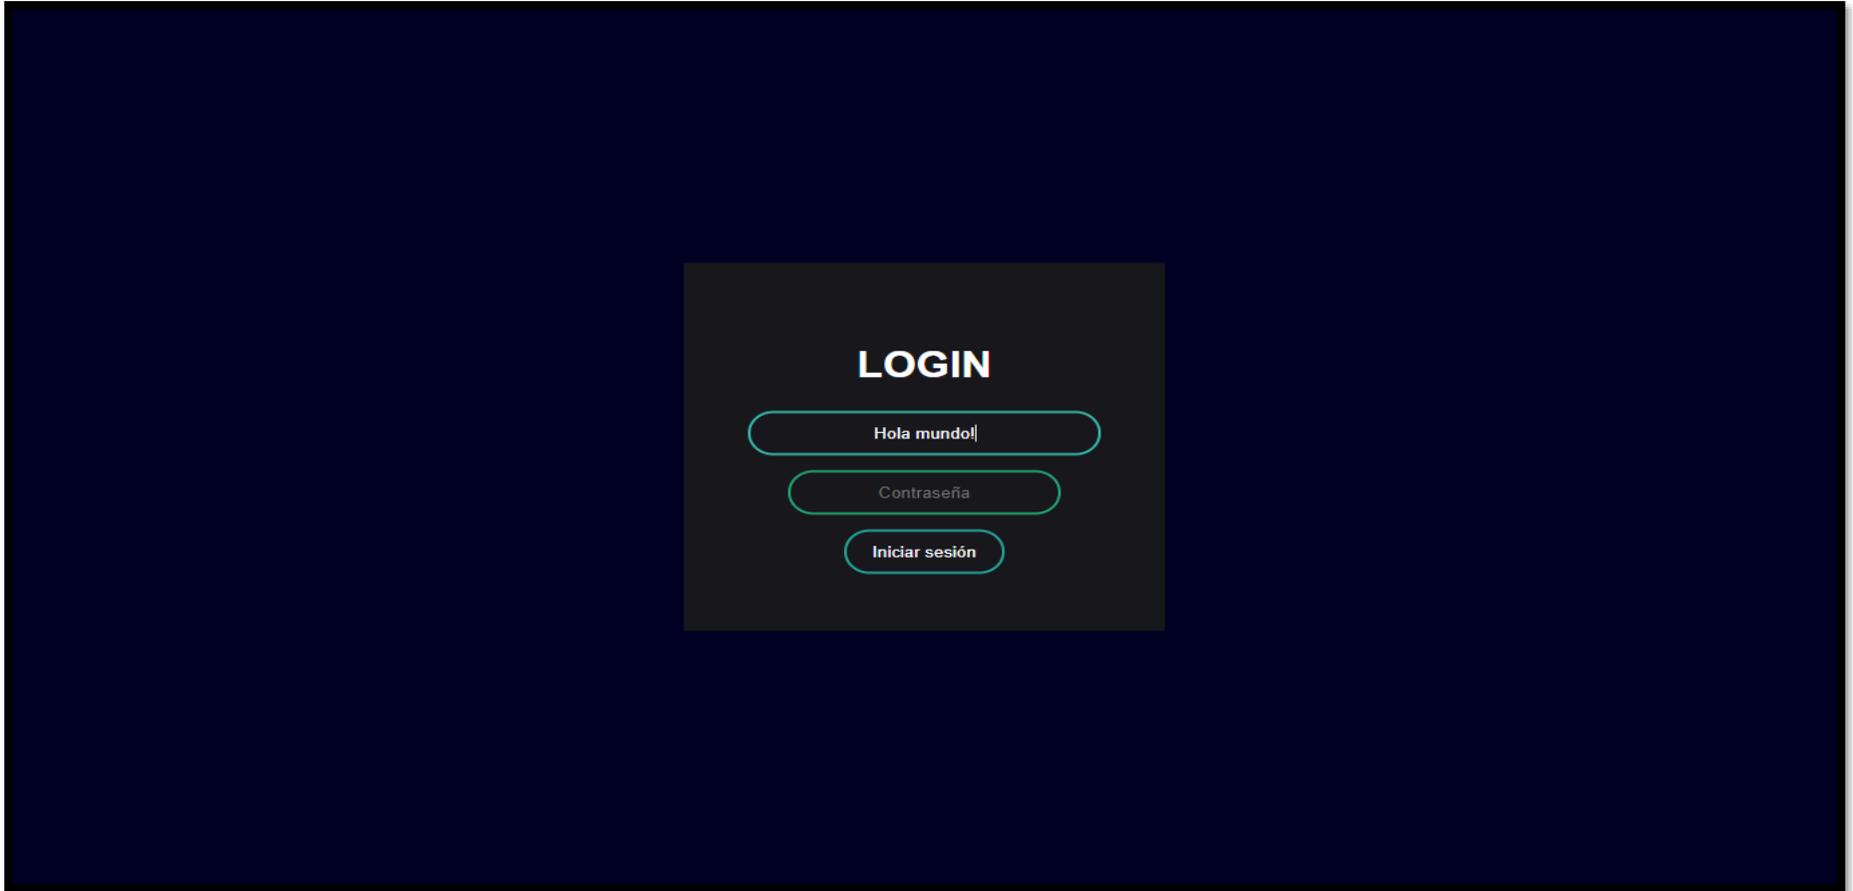


Ilustración 27: Interfaz de validación de usuario

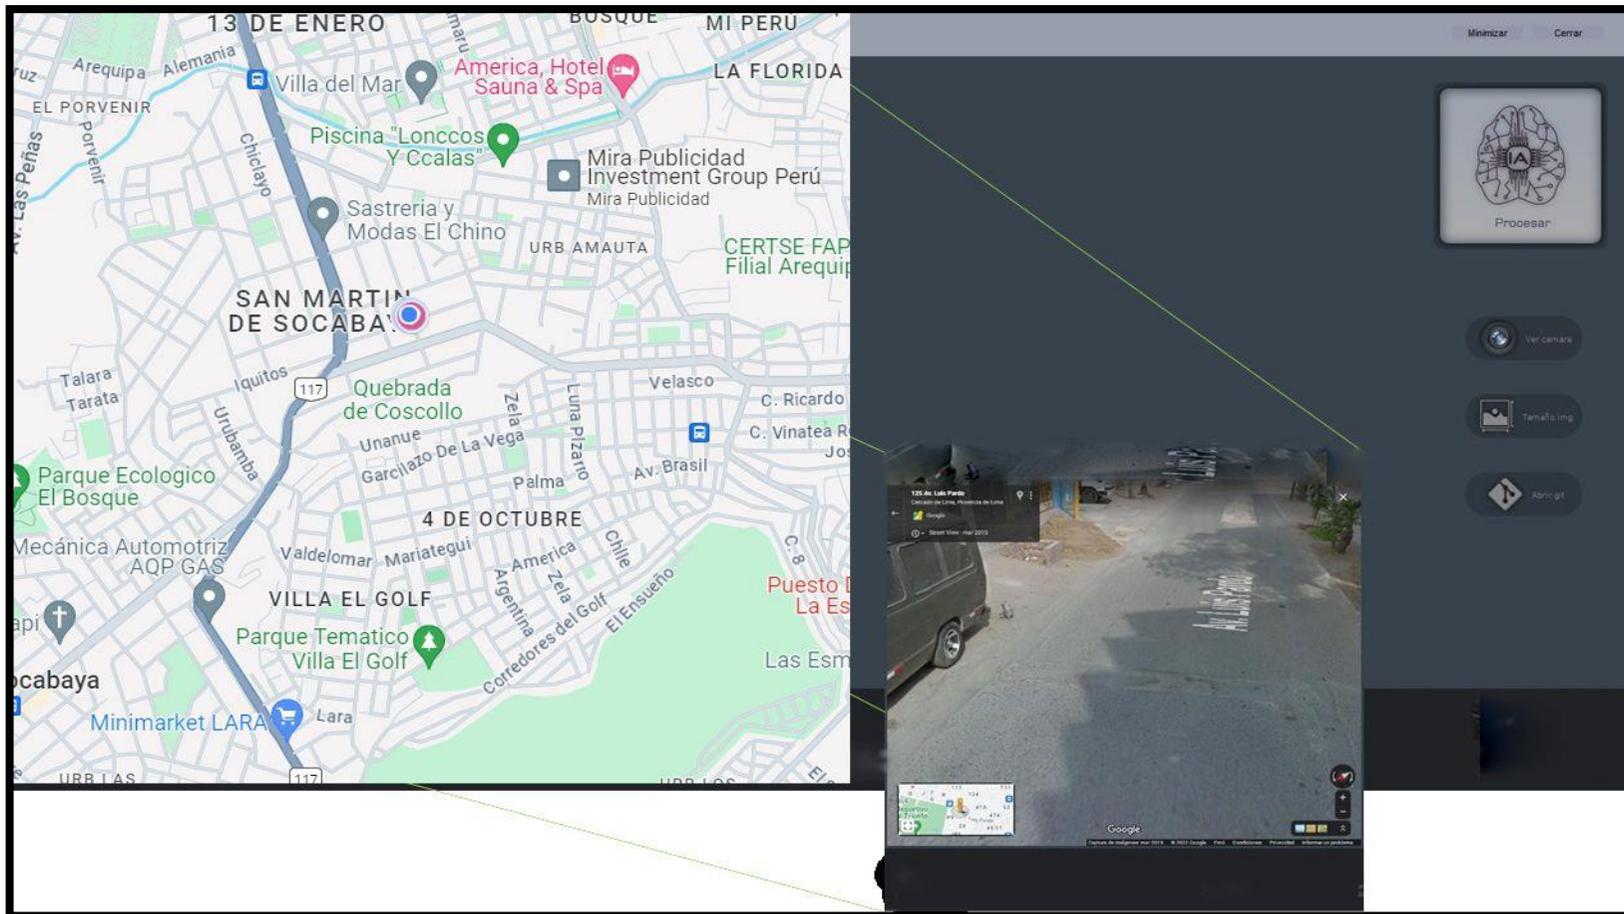


Ilustración 28: Modulo principal del proyecto

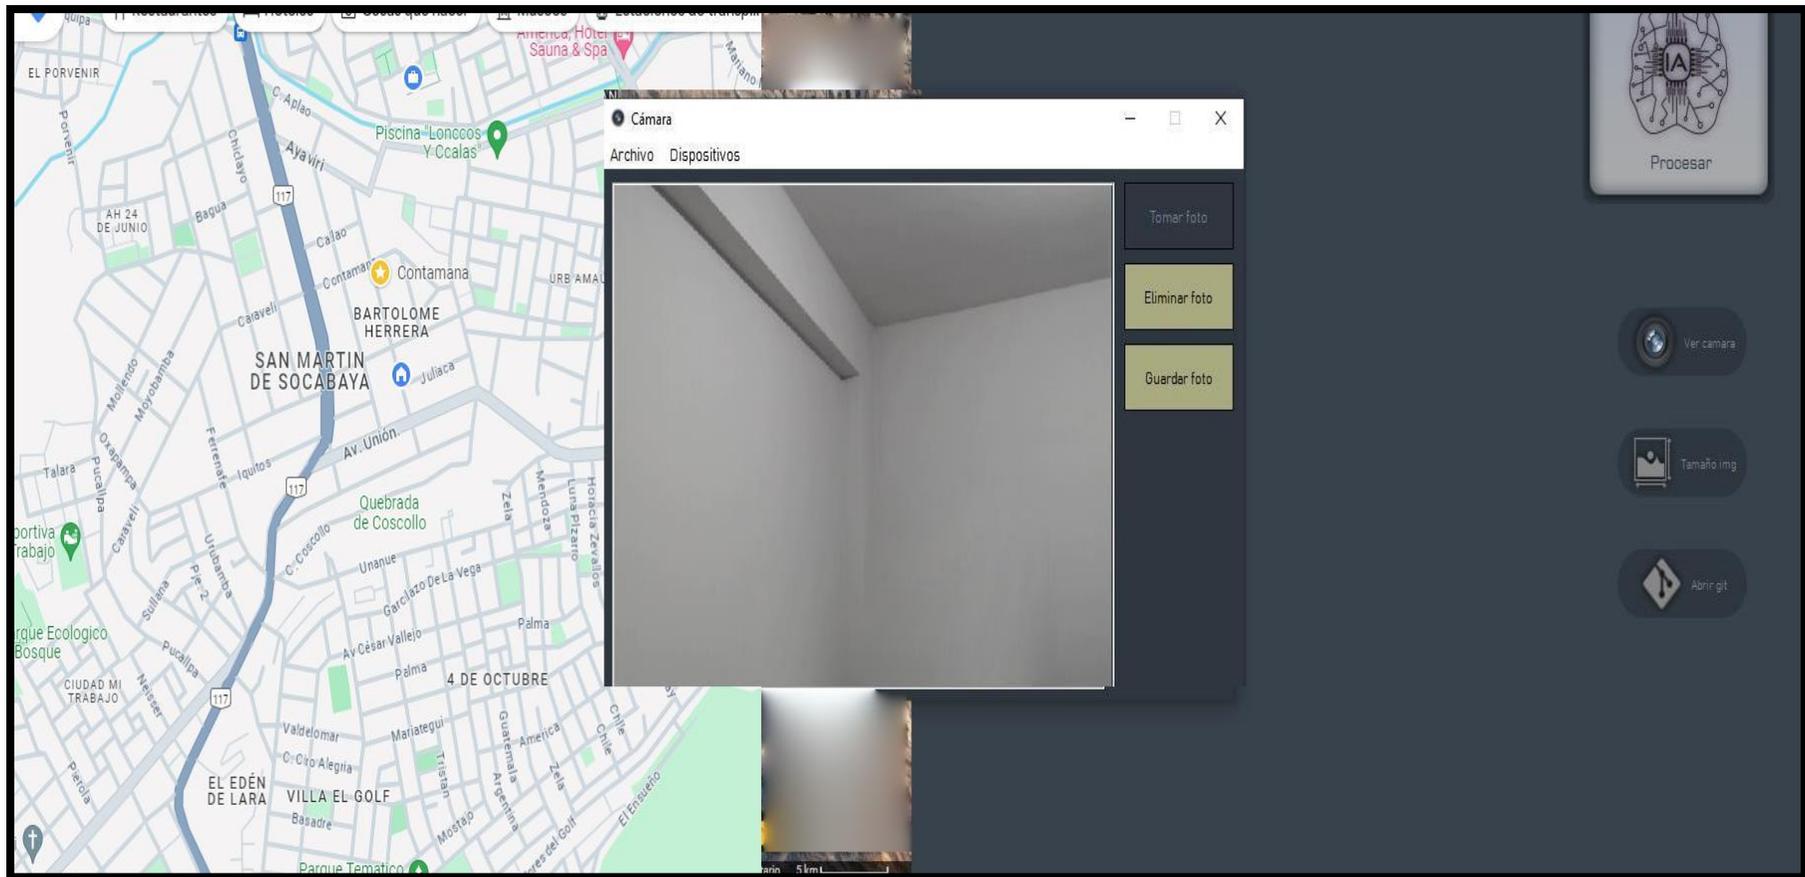


Ilustración 29: Módulo de cámara fotográfica

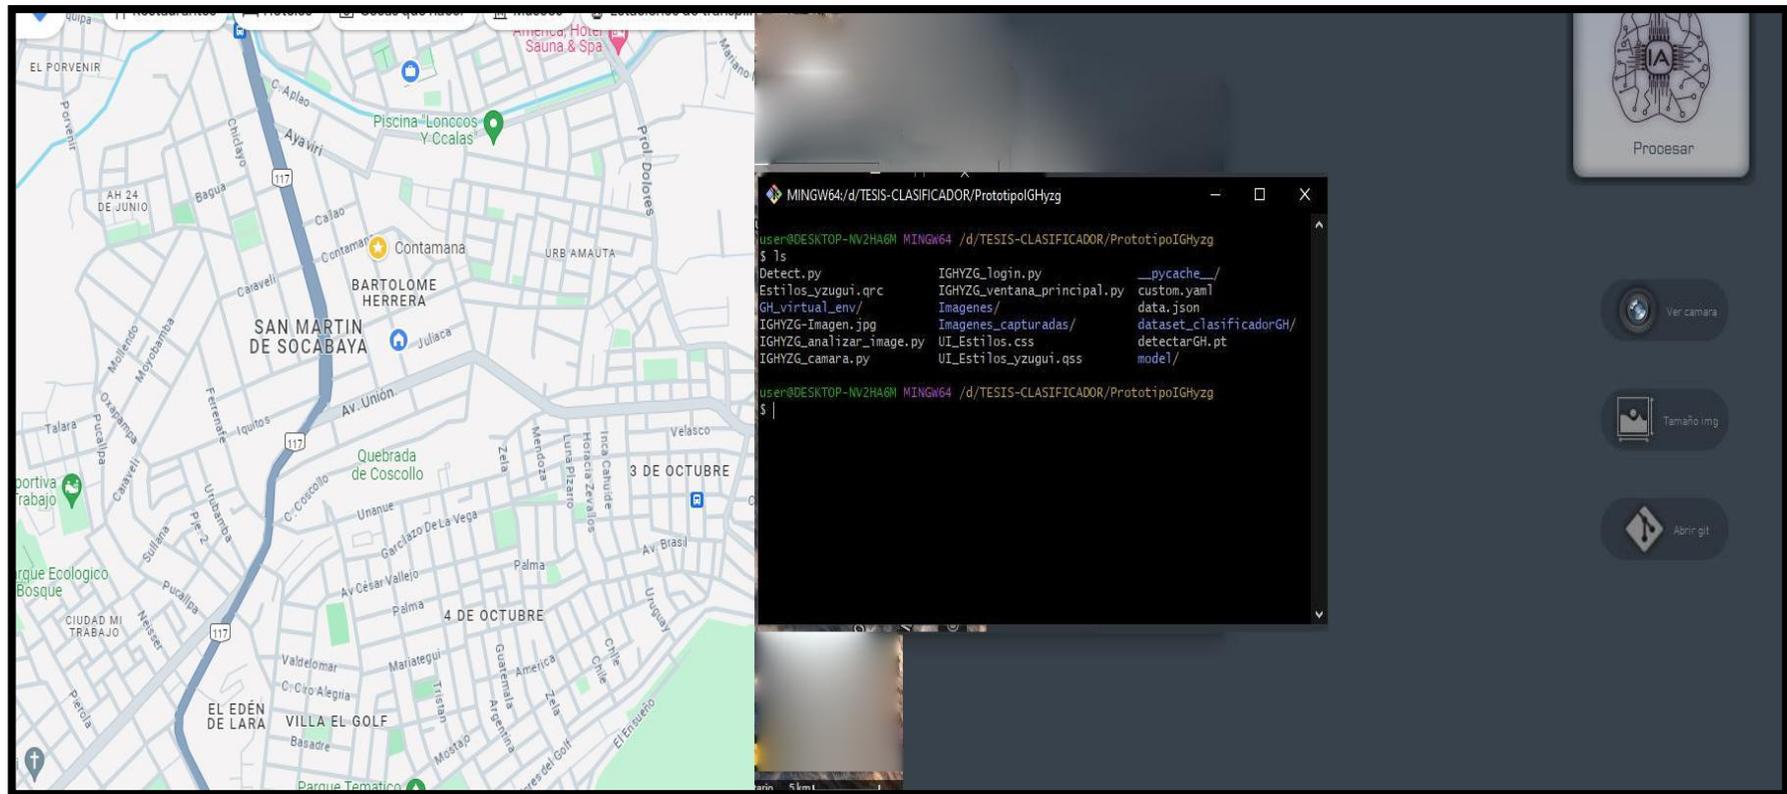


Ilustración 30: Módulo incorporado con git, para listar, configurar archivos del sistema.

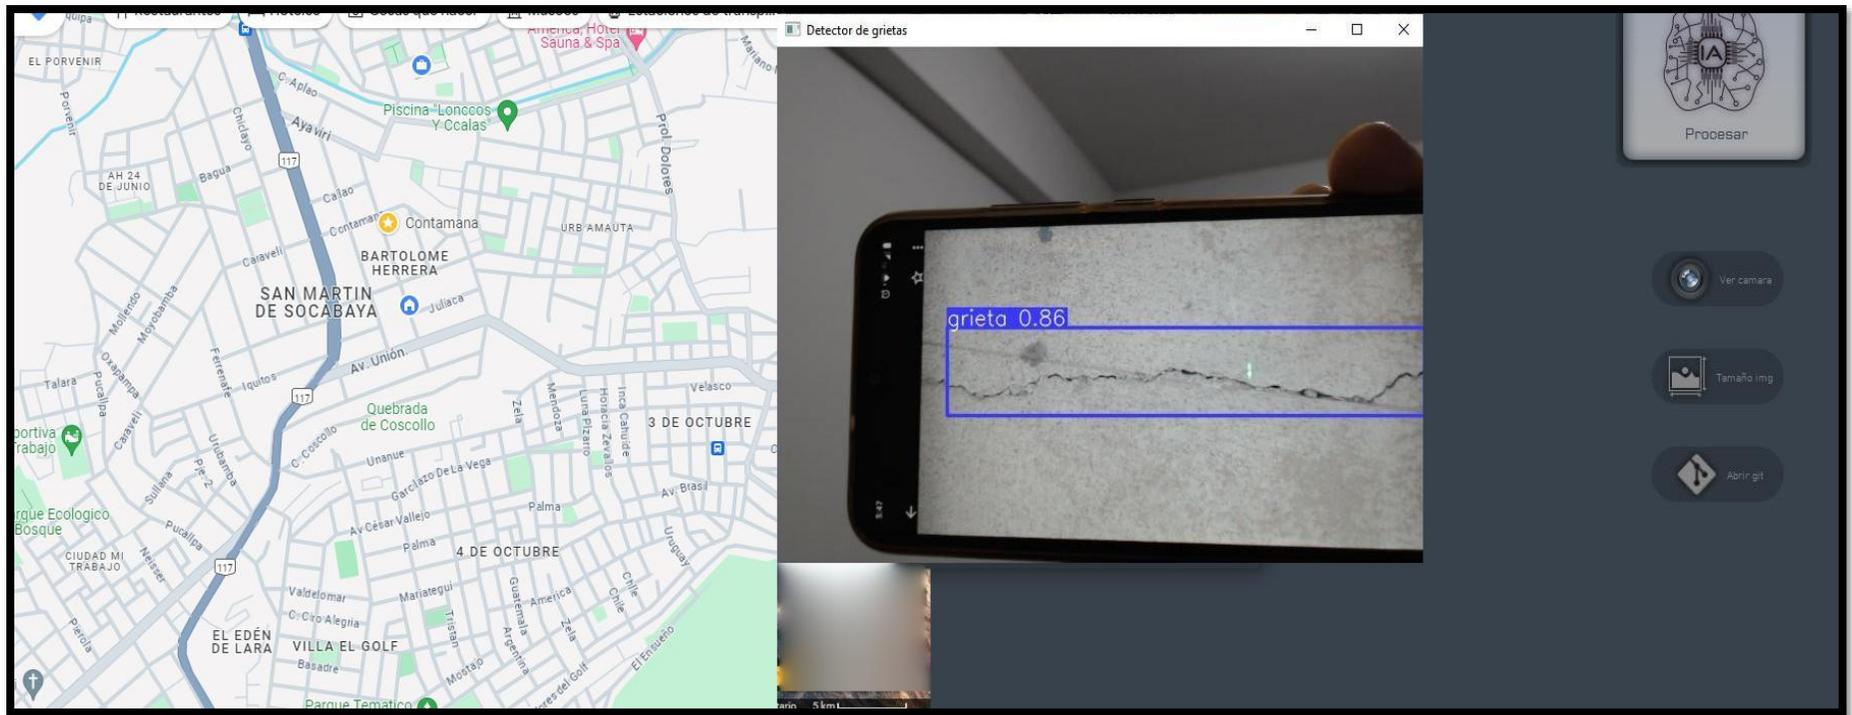


Ilustración 31: Módulo de activación IA detectando grieta con una precisión de 0.86.

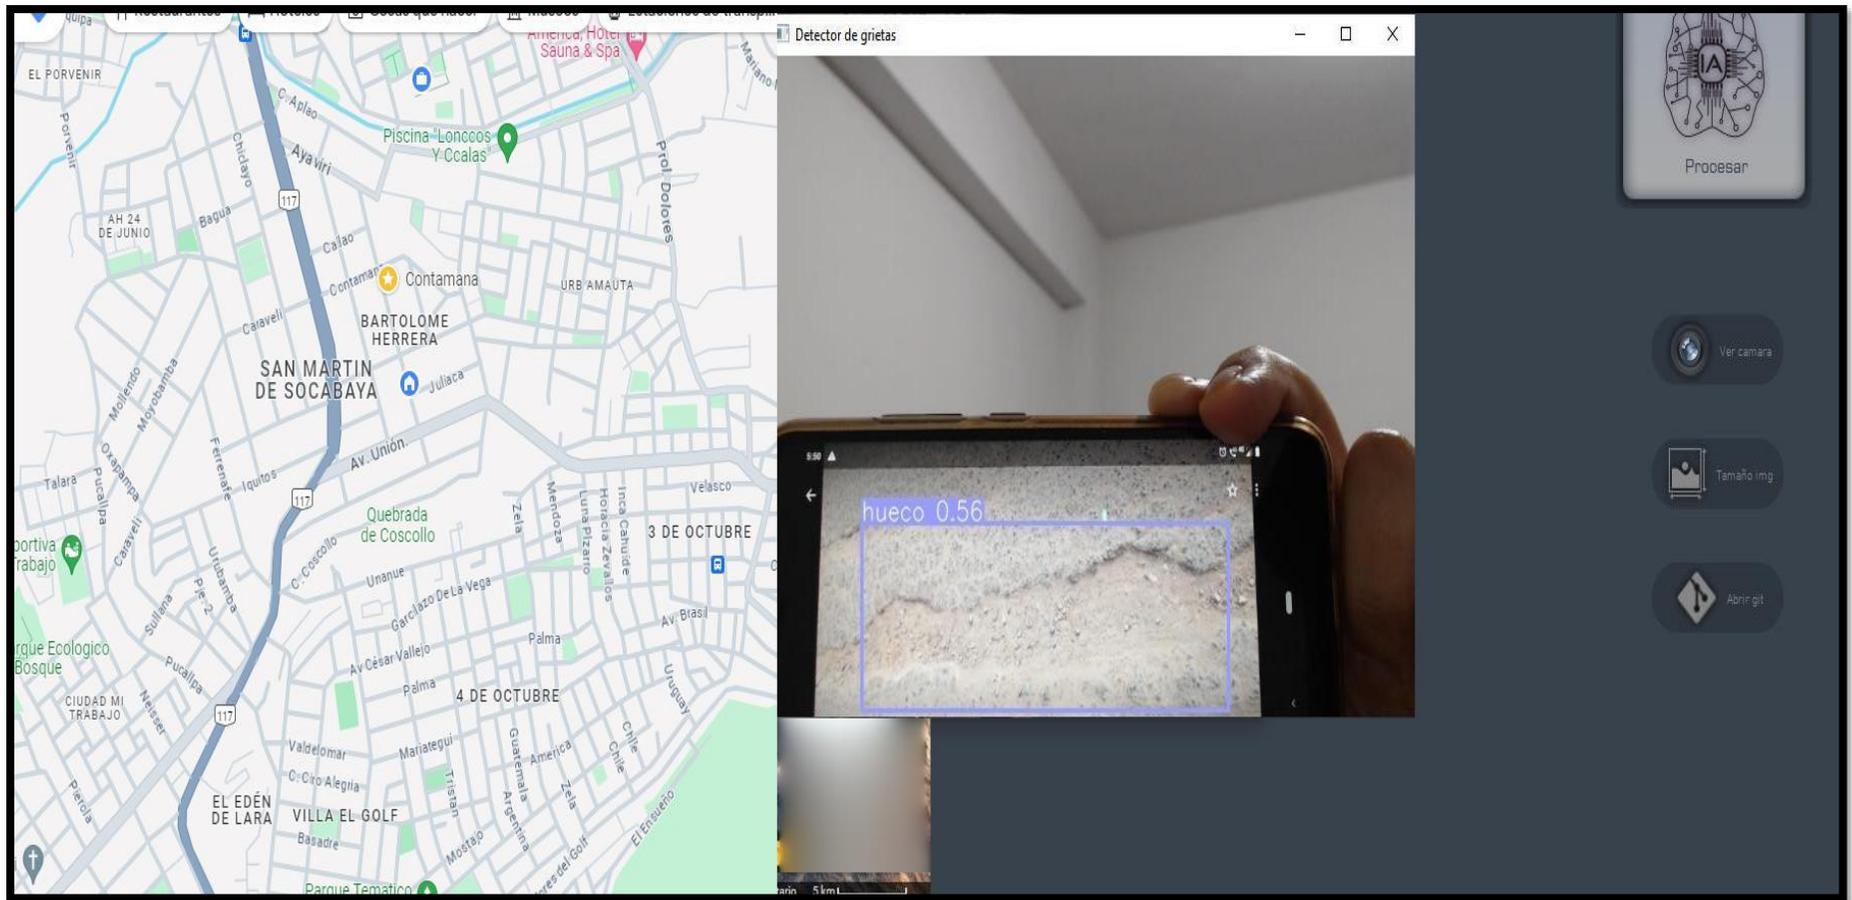


Ilustración 32: Módulo de activación IA detectando hueco con una precisión de 0.56.

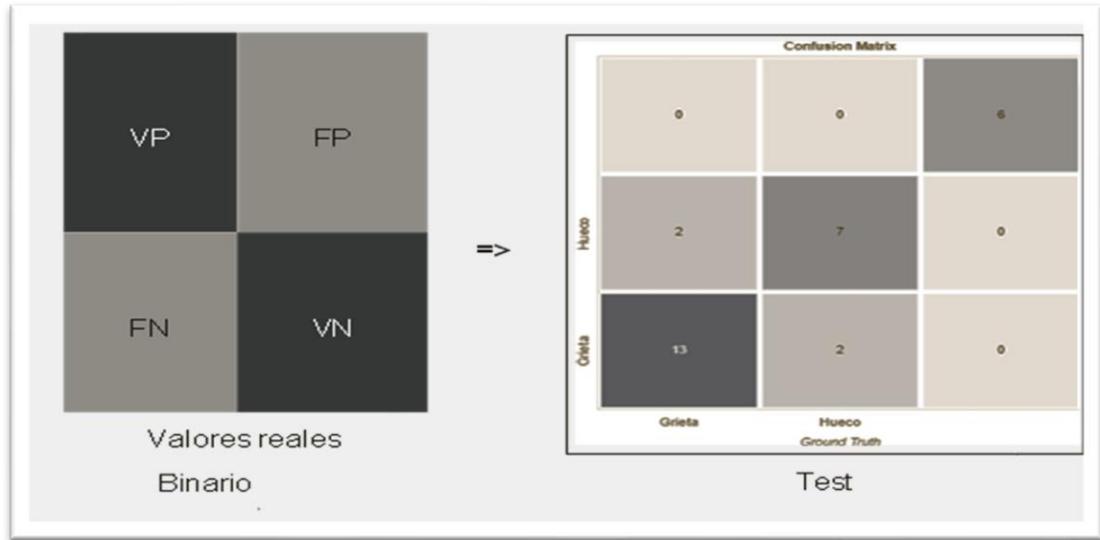


Tabla 9: Matriz de confusión

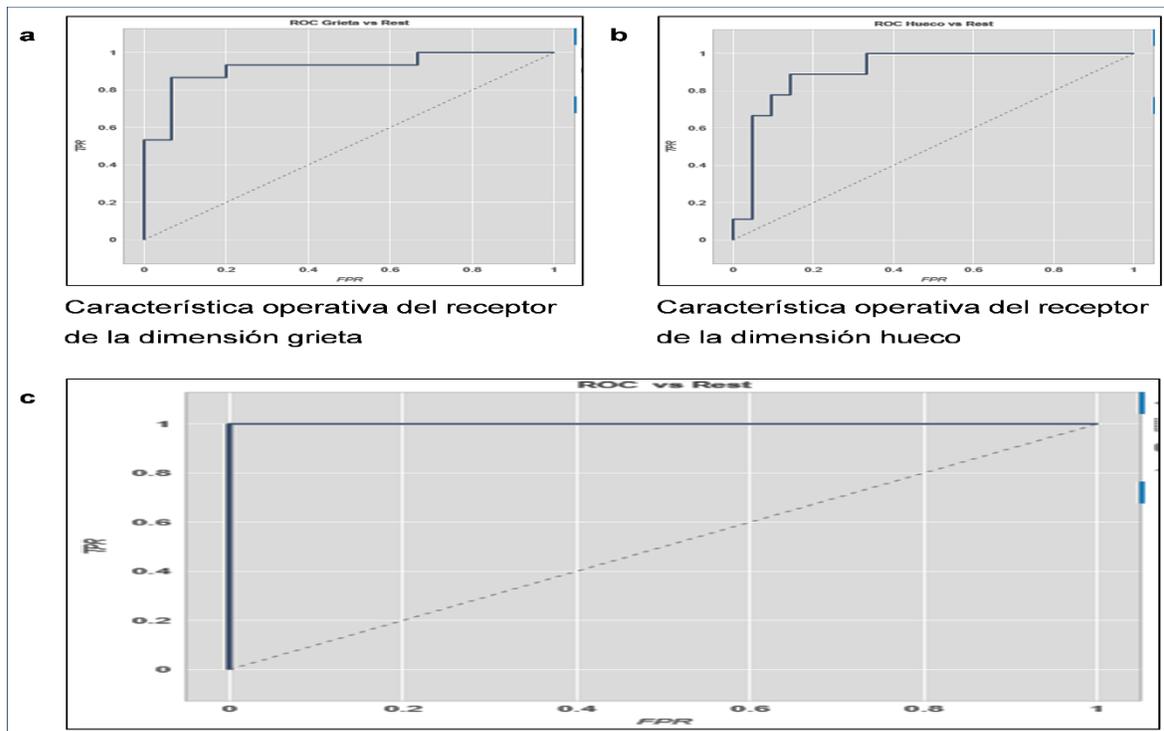


Tabla 10: Característica Operativa del Recepto (ROC) general de las dimensiones de grietas y huecos

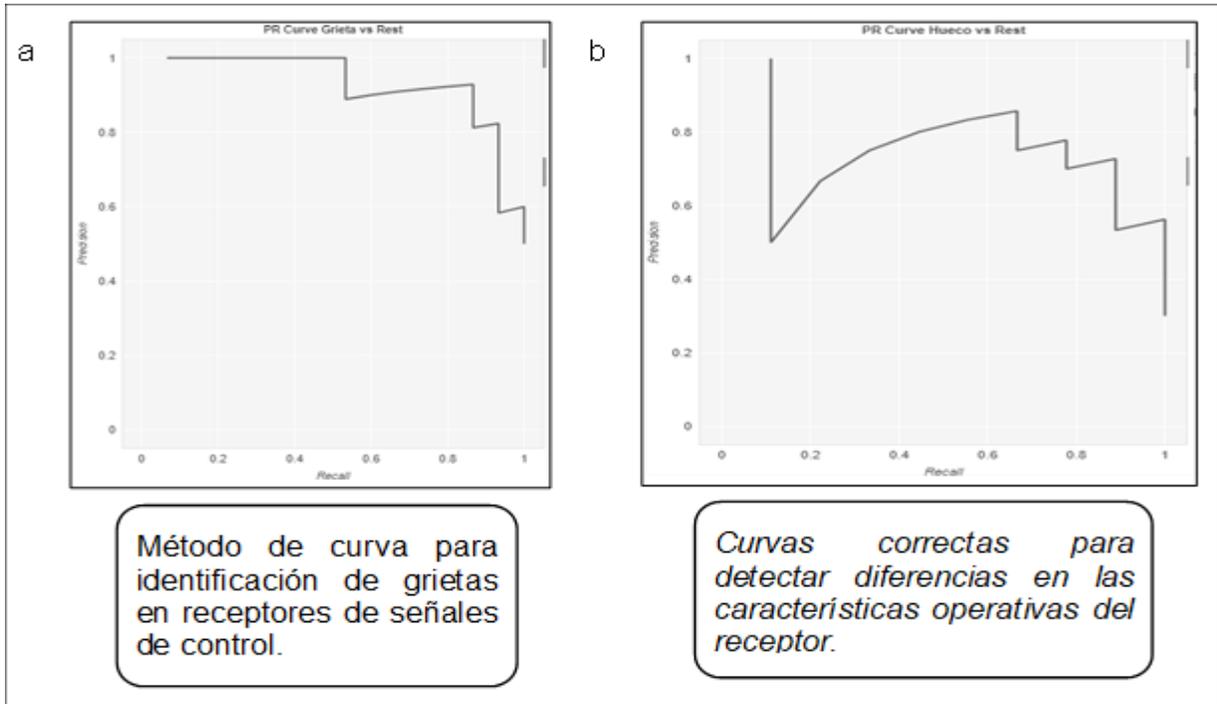


Tabla 11: Curva ROC para mediciones de grietas y huecos

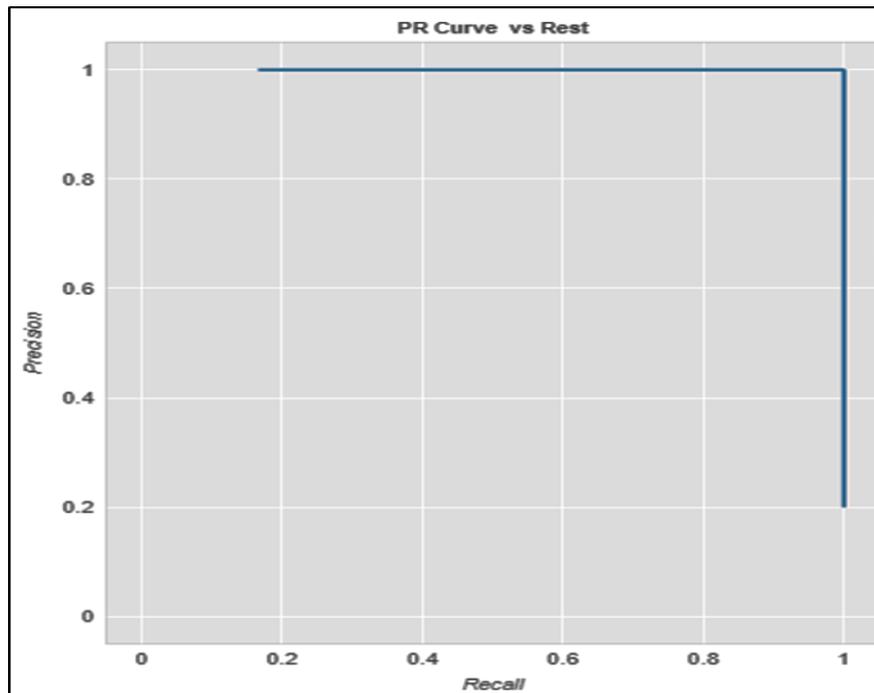


Tabla 12: Precisión de la curva del ROC bajo la sensibilidad o recall

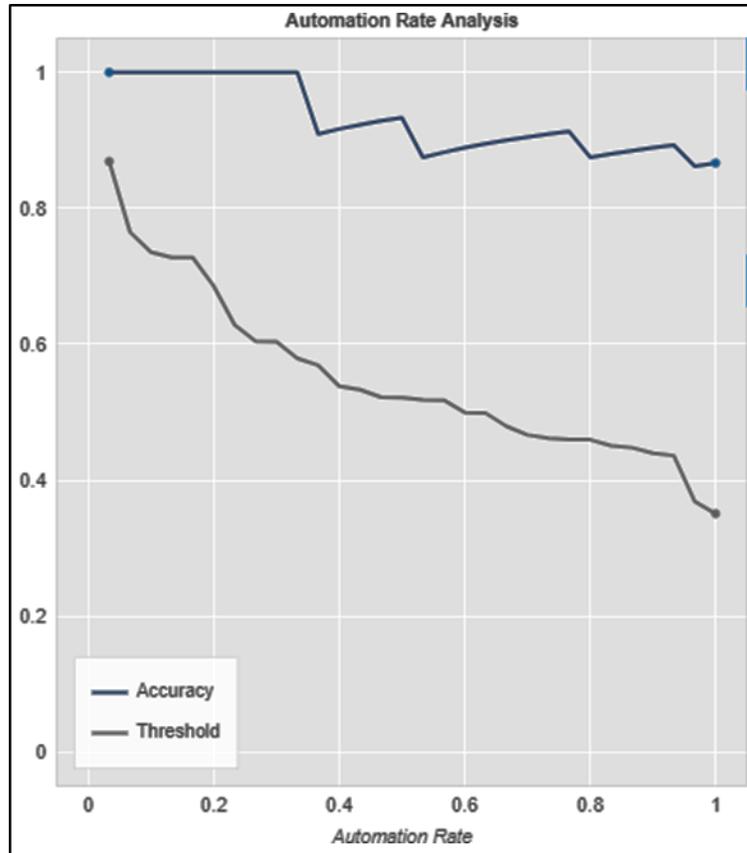


Tabla 13: Indicador del Accuracy

SOLICITUD DE AUTORIZACIÓN PARA REALIZAR UNA INVESTIGACION EN LA MUNICIPALIDAD DISTRITAL DE SOCABAYA

Asunto: Solicitud de Autorización para Realizar una Investigación

Juan Roberto Muñoz Pinto
Alcalde distrital de Socabaya
Municipalidad distrital de Socabaya

Reciba un cordial saludo. Me dirijo a usted en calidad de estudiante del Programa de Titulación de la UCV, donde actualmente desarrollo mi proyecto de investigación como parte de los requisitos necesarios para obtener mi título de Ingeniero de sistemas.

El propósito de mi comunicación es solicitar su autorización para llevar a cabo una investigación en el ámbito de una Aplicación de Deep Learning para la detección de anomalías en pavimento en una zona del distrito de “Socabaya”, Arequipa 2023. En la municipalidad distrital de Socabaya. Mi investigación tiene como identificar y evaluar el estado de los pavimentos y se llevará a cabo de acuerdo con los más altos estándares éticos y profesionales.

En este sentido, la colaboración de su organización sería de gran valor para mi proyecto, ya que se utilizará imágenes referenciales de algunas calles principales del distrito de Socabaya. Estoy comprometido/a a minimizar cualquier inconveniente y a garantizar que la investigación no interfiera con las actividades regulares de su organización. Además, cualquier dato o información confidencial que pueda surgir durante la investigación será tratado con la debida confidencialidad y no será divulgado sin su consentimiento explícito.

Aprecio sinceramente su consideración de esta solicitud y estoy a su disposición para discutir cualquier aspecto de la investigación en detalle. Espero con interés la posibilidad de colaborar con su organización y de contribuir al avance del conocimiento científico en este campo.

Agradezco de antemano su atención y respuesta a esta solicitud.



Jose Rodolfo Chino Mestas
DNI: 74999291

CARTA DE PRESENTACION

Señor: Edwar Abril Saire Peralta

Presente

Asunto: VALIDACIÓN DE INSTRUMENTOS A TRAVÉS DE JUICIO DE EXPERTO.

Nos es muy grato comunicarnos con usted para expresarle nuestros saludos y así mismo, hacer de su conocimiento que, siendo estudiante de Ingeniería de sistemas de la UCV, en la sede Ate Vitarte, requerimos validar los instrumentos con los cuales recogeremos la información necesaria para poder desarrollar nuestra investigación y con la cual optaremos el grado de Ingeniero.

El título nombre de nuestro proyecto de investigación es Aplicación de Deep Learning para la detección de anomalías en pavimento en una zona del distrito de “Socabaya”, 2024. y su efecto en la productividad es en la municipalidad de Socabaya siendo imprescindible contar con la aprobación de docentes especializados para poder aplicar los instrumentos en mención, hemos considerado conveniente recurrir a usted, ante su connotada experiencia en temas educativos y/o investigación educativa.

El expediente de validación, que le hacemos llegar contiene:

- Carta de presentación.
- Definiciones conceptuales de las variables y dimensiones.
- Matriz de operacionalización de las variables.
- Certificado de validez de contenido de los instrumentos.

Expresándole nuestros sentimientos de respeto y consideración nos despedimos de usted, no sin antes agradecerle por la atención que dispense a la presente.

Atentamente.

DEFINICIÓN CONCEPTUAL DE LAS VARIABLES Y OPERACIONALIZACIÓN

Variable y operacionalización

Variable independiente: Aplicación móvil utilizando técnicas de Deep Learning

De otra manera, Huang et al. (2023) describen que el aprendizaje profundo (Deep Learning) es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones. Estas redes imitan el funcionamiento del cerebro humano al procesar información en capas sucesivas, extrayendo características complejas a medida que avanzan.

Variable de estudio Independiente:

Aplicación móvil utilizando técnicas de Deep Learning.

Definición conceptual:

Huang et al. (2023) describen que Deep Learning es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones.

Definición operacional:

La detección y gestión de estas anomalías es de vital importancia para garantizar la seguridad vial y prolongar la vida útil de las infraestructuras pavimentadas. En este sentido, la aplicación móvil desarrollada con técnicas de Deep Learning se convierte en una herramienta esencial.

Variable dependiente: Anomalías en pavimento

Por otra parte, Martínez et al. (2023) Las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro. Estas condiciones anómalas pueden ser causadas por factores como el tráfico vehicular intenso, cambios climáticos, falta de mantenimiento adecuado o problemas de diseño. Detectar y reparar estas anomalías es crucial para mantener la seguridad

vial y la durabilidad de las infraestructuras pavimentadas.

Variable de estudio Dependiente: Anomalías en Pavimento

Definición conceptual: Por otra parte, Martínez et al. (2023) las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro.

Definición operacional:

En términos concretos, se trata de daños, irregularidades o situaciones inusuales que pueden afectar a carreteras, calles u otras áreas pavimentadas. Esta categoría abarca una variedad de condiciones anómalas, como grietas, baches, hundimientos, fisuras y desgaste excesivo, entre otros.

MATRIZ DE OPERACIONALIZACIÓN DE LAS VARIABLES

Variables de estudio	Definición conceptual	Definición operacional	Dimensión	Indicadores	Escala de medición
Independiente: Aplicación móvil utilizando técnicas de Deep Learning	Huang et al. (2023) describen que Deep Learning es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones.	La detección y gestión de estas anomalías es de vital importancia para garantizar la seguridad vial y prolongar la vida útil de las infraestructuras pavimentadas. En este sentido, la aplicación móvil desarrollada con técnicas de Deep Learning se convierte en una herramienta esencial.			
Dependiente: Anomalías en Pavimento	Por otra parte, Martínez et al. (2023) las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro.	En términos concretos, se trata de daños, irregularidades o situaciones inusuales que pueden afectar a carreteras, calles u otras áreas pavimentadas. Esta categoría abarca una variedad de condiciones anómalas, como grietas, baches, hundimientos, fisuras y desgaste excesivo, entre otros.	Medición y detección de grietas en pavimento	Precisión Recall F1	Razón
			Medición y detección de desprendimiento de agregados en pavimento		
			Medición y detección de piel de cocodrilo en pavimento		Razón

Fuente: elaboración propia

CERTIFICADO DE VALIDEZ DEL CONTENIDO

Nº	DIMENSIONES / ítems	Pertinencia ¹		Relevancia ²		Claridad ³		Sugerencias
		Si	No	Si	No	Si	No	
	INDICADOR: Calcular la precisión	Si	No	Si	No	Si	No	
1	$\text{Precisión} = \frac{TP}{TP + FP}$	X		X		X		
	INDICADOR: Determinar el puntaje	Si	No	Si	No	Si	No	
2	$F1 = \frac{2 \left(\frac{TP}{TP + FP} * \text{precisión} \right)}{\frac{TP}{TP + FN} + \text{precisión}}$	X		X		X		

Observaciones (precisar si hay suficiencia): Hay suficiencia

Opinión de aplicabilidad: Aplicable [✓] Aplicable después de corregir [] No aplicable [] Apellidos y nombres del juez validador

. Dr. Edwar Abril Saire Peralta

DNI: 40118809

CIP: 142786

Especialidad del validador:

Ingeniero Sistemas

31 Octubre del 2023

¹Pertinencia: El ítem corresponde al concepto teórico formulado.

²Relevancia: El ítem es apropiado para representar al componente o dimensión específica del constructo

³Claridad: Se entiende sin dificultad alguna el enunciado del ítem, es conciso, exacto y directo

Firma del Experto Informante

Nota: Suficiencia, se dice suficiencia cuando los ítems planteados son suficientes para medir la dimensión



CARTA DE PRESENTACION

Señor: Marco Antonio Vásquez Pauca

Presente

Asunto: VALIDACIÓN DE INSTRUMENTOS A TRAVÉS DE JUICIO DE EXPERTO.

Nos es muy grato comunicarnos con usted para expresarle nuestros saludos y así mismo, hacer de su conocimiento que, siendo estudiante de Ingeniería de sistemas de la UCV, en la sede Ate Vitarte, requerimos validar los instrumentos con los cuales recogeremos la información necesaria para poder desarrollar nuestra investigación y con la cual optaremos el grado de Ingeniero.

El título nombre de nuestro proyecto de investigación es Aplicación de Deep Learning para la detección de anomalías en pavimento en una zona del distrito de “Socabaya”, 2024. y su efecto en la productividad es en la municipalidad de Socabaya siendo imprescindible contar con la aprobación de docentes especializados para poder aplicar los instrumentos en mención, hemos considerado conveniente recurrir a usted, ante su connotada experiencia en temas educativos y/o investigación educativa.

El expediente de validación, que le hacemos llegar contiene:

- Carta de presentación.
- Definiciones conceptuales de las variables y dimensiones.
- Matriz de operacionalización de las variables.
- Certificado de validez de contenido de los instrumentos.

Expresándole nuestros sentimientos de respeto y consideración nos despedimos de usted, no sin antes agradecerle por la atención que dispense a la presente.

Atentamente.

DEFINICIÓN CONCEPTUAL DE LAS VARIABLES Y OPERACIONALIZACION

Variable y operacionalización

Variable independiente: Aplicación móvil utilizando técnicas de Deep Learning

De otra manera, Huang et al. (2023) describen que el aprendizaje profundo (Deep Learning) es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones. Estas redes imitan el funcionamiento del cerebro humano al procesar información en capas sucesivas, extrayendo características complejas a medida que avanzan.

Variable de estudio

Independiente:

Aplicación móvil utilizando técnicas de Deep Learning.

Definición conceptual:

Huang et al. (2023) describen que Deep Learning es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones.

Definición operacional:

La detección y gestión de estas anomalías es de vital importancia para garantizar la seguridad vial y prolongar la vida útil de las infraestructuras pavimentadas. En este sentido, la aplicación móvil desarrollada con técnicas de Deep Learning se convierte en una herramienta esencial.

Variable dependiente: Anomalías en pavimento

Por otra parte, Martínez et al. (2023) Las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro. Estas condiciones anómalas pueden ser causadas por factores como el tráfico vehicular intenso, cambios climáticos, falta de mantenimiento adecuado o problemas de diseño. Detectar y reparar estas anomalías es crucial para mantener la seguridad vial y la durabilidad de las infraestructuras pavimentadas.

Variable de estudio

Dependiente:

Anomalías en Pavimento

Definición conceptual:

Por otra parte, Martínez et al. (2023) las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro.

Definición operacional:

En términos concretos, se trata de daños, irregularidades o situaciones inusuales que pueden afectar a carreteras, calles u otras áreas pavimentadas. Esta categoría abarca una variedad de condiciones anómalas, como grietas, baches, hundimientos, fisuras y desgaste excesivo, entre otros.

MATRIZ DE OPERACIONALIZACIÓN DE LAS VARIABLES

Variables de estudio	Definición conceptual	Definición operacional	Dimensión	Indicadores	Escala de medición
Independiente: Aplicación móvil utilizando técnicas de Deep Learning	Huang et al. (2023) describen que Deep Learning es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones.	La detección y gestión de estas anomalías es de vital importancia para garantizar la seguridad vial y prolongar la vida útil de las infraestructuras pavimentadas. En este sentido, la aplicación móvil desarrollada con técnicas de Deep Learning se convierte en una herramienta esencial.			
Dependiente: Anomalías en Pavimento	Por otra parte, Martínez et al. (2023) las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro.	En términos concretos, se trata de daños, irregularidades o situaciones inusuales que pueden afectar a carreteras, calles u otras áreas pavimentadas. Esta categoría abarca una variedad de condiciones anómalas, como grietas, baches, hundimientos, fisuras y desgaste excesivo, entre otros.	Medición y detección de grietas en pavimento	Precisión Recall F1	Razón
			Medición y detección de desprendimiento de agregados en pavimento		
			Medición y detección de piel de cocodrilo en pavimento		Razón

Fuente: elaboración propia

CERTIFICADO DE VALIDEZ DEL CONTENIDO

Nº	DIMENSIONES / ítems	Pertinencia ¹		Relevancia ²		Claridad ³		Sugerencias
		Si	No	Si	No	Si	No	
	INDICADOR: Calcular la precisión	Si	No	Si	No	Si	No	
1	$\text{Precisión} = \frac{TP}{TP + FP}$	X		X		X		
	INDICADOR: Determinar el puntaje	Si	No	Si	No	Si	No	
2	$F1 = \frac{2(P + F * \text{precisión})}{TP + FN}$	X		X		X		

Observaciones (precisar si hay suficiencia): Hay suficiencia

Opinión de aplicabilidad: **Aplicable** **Aplicable después de corregir** **No aplicable**

Apellidos y nombres del juez validador: Marco Antonio Vásquez Pauca

DNI: 41251368

CIP: 182790

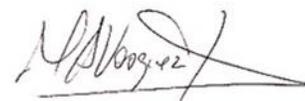
Especialidad del validador: ING. SISTEMAS E INFORMATICA

31 de Octubre del 2023

¹**Pertinencia:** El ítem corresponde al concepto teórico formulado.

²**Relevancia:** El ítem es apropiado para representar al componente o dimensión específica del constructo

³**Claridad:** Se entiende sin dificultad alguna el enunciado del ítem, es conciso, exacto y directo



Firma del Experto Informante

CARTA DE PRESENTACION

Señor: ALARCON CAJAS, YOHAN ROY

Presente

Asunto: VALIDACIÓN DE INSTRUMENTOS A TRAVÉS DE JUICIO DE EXPERTO.

Nos es muy grato comunicarnos con usted para expresarle nuestros saludos y así mismo, hacer de su conocimiento que, siendo estudiante de Ingeniería de sistemas de la UCV, en la sede Ate Vitarte, requerimos validar los instrumentos con los cuales recogeremos la información necesaria para poder desarrollar nuestra investigación y con la cual optaremos el grado de Ingeniero.

El título nombre de nuestro proyecto de investigación es Aplicación de Deep Learning para la detección de anomalías en pavimento en una zona del distrito de "Socabaya", 2024. y su efecto en la productividad es en la municipalidad de Socabaya siendo imprescindible contar con la aprobación de docentes especializados para poder aplicar los instrumentos en mención, hemos considerado conveniente recurrir a usted, ante su connotada experiencia en temas educativos y/o investigación educativa.

El expediente de validación, que le hacemos llegar contiene:

- Carta de presentación.
- Definiciones conceptuales de las variables y dimensiones.
- Matriz de operacionalización de las variables.
- Certificado de validez de contenido de los instrumentos.

Expresándole nuestros sentimientos de respeto y consideración nos despedimos de usted, no sin antes agradecerle por la atención que dispense a la presente.

Atentamente.

DEFINICIÓN CONCEPTUAL DE LAS VARIABLES Y OPERACIONALIZACION

Variable y operacionalización

Variable independiente: Aplicación móvil utilizando técnicas de Deep Learning

De otra manera, Huang et al. (2023) describen que el aprendizaje profundo (Deep Learning) es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones. Estas redes imitan el funcionamiento del cerebro humano al procesar información en capas sucesivas, extrayendo características complejas a medida que avanzan.

Variable de estudio

Independiente:

Aplicación móvil utilizando técnicas de Deep Learning.

Definición conceptual:

Huang et al. (2023) describen que Deep Learning es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones.

Definición operacional:

La detección y gestión de estas anomalías es de vital importancia para garantizar la seguridad vial y prolongar la vida útil de las infraestructuras pavimentadas. En este sentido, la aplicación móvil desarrollada con técnicas de Deep Learning se convierte en una herramienta esencial.

Variable dependiente: Anomalías en pavimento

Por otra parte, Martínez et al. (2023) Las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro. Estas condiciones anómalas pueden ser causadas por factores como el tráfico vehicular intenso, cambios climáticos, falta de mantenimiento adecuado o problemas de diseño. Detectar y reparar estas anomalías es crucial para mantener la seguridad vial y la durabilidad de las infraestructuras pavimentadas.

Variable de estudio

Dependiente:

Anomalías en Pavimento

Definición conceptual:

Por otra parte, Martínez et al. (2023) las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro.

Definición operacional:

En términos concretos, se trata de daños, irregularidades o situaciones inusuales que pueden afectar a carreteras, calles u otras áreas pavimentadas. Esta categoría abarca una variedad de condiciones anómalas, como grietas, baches, hundimientos, fisuras y desgaste excesivo, entre otros.

MATRIZ DE OPERACIONALIZACIÓN DE LAS VARIABLES

Variables de estudio	Definición conceptual	Definición operacional	Dimensión	Indicadores	Escala de medición
Independiente: Aplicación móvil utilizando técnicas de Deep Learning	Huang et al. (2023) describen que Deep Learning es un enfoque dentro del campo de la inteligencia artificial que se basa en redes neuronales artificiales con múltiples capas para procesar datos y aprender patrones.	La detección y gestión de estas anomalías es de vital importancia para garantizar la seguridad vial y prolongar la vida útil de las infraestructuras pavimentadas. En este sentido, la aplicación móvil desarrollada con técnicas de Deep Learning se convierte en una herramienta esencial.			
Dependiente: Anomalías en Pavimento	Por otra parte, Martínez et al. (2023) las anomalías de pavimento se refieren a daños, irregularidades o problemas inusuales que ocurren en superficies de carreteras, calles o áreas pavimentadas. Estas anomalías pueden incluir grietas, baches, hundimientos, desgaste excesivo, fisuras y otros tipos de deterioro.	En términos concretos, se trata de daños, irregularidades o situaciones inusuales que pueden afectar a carreteras, calles u otras áreas pavimentadas. Esta categoría abarca una variedad de condiciones anómalas, como grietas, baches, hundimientos, fisuras y desgaste excesivo, entre otros.	Medición y detección de grietas en pavimento	Precisión Recall F1	Razón
			Medición y detección de desprendimiento de agregados en pavimento		
			Medición y detección de piel de cocodrilo en pavimento		Razón

Fuente: elaboración propia

CERTIFICADO DE VALIDEZ DEL CONTENIDO

N°	DIMENSIONES / ítems	Pertinencia ¹		Relevancia ²		Claridad ³		Sugerencias
		Si	No	Si	No	Si	No	
	INDICADOR: Calcular la precisión	Si	No	Si	No	Si	No	
1	$\text{Precisión} = \frac{TP}{TP + FP}$	X		X		X		
	INDICADOR: Determinar el puntaje	Si	No	Si	No	Si	No	
2	$F1 = \frac{2 \left(\frac{TP}{TP + FP} * \text{precisión} \right)}{\frac{TP}{TP + FP} + \text{precisión}}$	X		X		X		

Observaciones (precisar si hay suficiencia): Hay suficiencia

Opinión de aplicabilidad: Aplicable Aplicable después de corregir No aplicable

Apellidos y nombres del juez validador: ALARCON CAJAS, YOHAN ROY

DNI: 46189705

CIP: 182713

Especialidad del validador: ING. SISTEMAS Y COMPUTO

31 de octubre del 2023



Firma del Experto Informante

¹**Pertinencia:** El ítem corresponde al concepto teórico formulado.

²**Relevancia:** El ítem es apropiado para representar al componente o dimensión específica del constructo

³**Claridad:** Se entiende sin dificultad alguna el enunciado del ítem, es conciso, exacto y directo

ARTICULOS CIENTIFICO

APLICACIÓN DE DEEP LEARNIG PARA LA DETECCION DE ANOMALIAS EN PAVIMENTO EN LA PROINCIA DE AREQUIPA – PERU.

CHINO MESTAS JOSE RODOLFO ([0009-0000-4198-9554](tel:0009-0000-4198-9554))

INCHICSANA HUAMANI PETER JUNIOR ([0000-0002-2796-7655](tel:0000-0002-2796-7655))

MARCO ANTONIO BARRIENTOS YNFANTE ([0000-0001-9886-7267](tel:0000-0001-9886-7267))

/

Resumen

La tesis de investigación desarrolla una aplicación móvil que utiliza algoritmos de aprendizaje profundo para analizar en tiempo real las imágenes y datos, con el objetivo de identificar y evaluar el estado de los pavimentos. Ante ello se presenta el objetivo el cual es identificar la, magnitud de la ejecución de una aplicación utilizando técnicas Deep Learning intervienen en la detección de anomalías en el pavimento las condiciones adversas en carreteras y calles, como grietas y baches, generan riesgos y costos de reparación para las autoridades locales. Además, la inspección tradicional es subjetiva, pero el aprendizaje profundo permite detectar y evaluar anomalías de manera precisa y eficiente a través del análisis automático de imágenes y datos no invasivos. de un de las zonas del distrito de Socabaya de la localidad de Arequipa- Perú. redactan que, la detección precisa de problemas en el pavimento es esencial para la seguridad vial y el mantenimiento de infraestructuras urbanas. aplicar estas técnicas para identificar y describir problemas en el pavimento, con el propósito de mejorar el planeamiento y el mantenimiento de las carreteras. sino también la seguridad y eficiencia de las carreteras.

Palabras claves: aprendizaje profundo – inteligencia artificial – Deep Learning – tecnología – red neuronal.

Abstract

The research thesis develops a mobile application that uses deep learning algorithms to analyze images and data in real time, with the aim of identifying and evaluating the condition of the pavements. Given this, the objective is presented, which is to identify the magnitude of the execution of an application using Deep Learning techniques involved in the detection of anomalies in the pavement, adverse conditions on roads and streets, such as cracks and potholes, generate risks and costs of reparation for local authorities. Additionally, traditional inspection is subjective, but deep learning enables anomalies to be detected and evaluated accurately and efficiently through automatic analysis of non-invasive images and data. from one of the areas of the Socabaya district of the town of Arequipa- Peru. They write that accurate detection of pavement problems is essential for road safety and the maintenance of urban infrastructure. apply these techniques to identify and describe pavement problems, with the purpose of improving road planning and maintenance. but also the safety and efficiency of the roads.

Keywords: deep learning – artificial intelligence – Deep Learning – technology – neural network.

INTRODUCCIÓN

A nivel global, según, Shu et al. (1) describen que, las condiciones adversas en carreteras y calles, como grietas y baches, generan riesgos y costos de reparación para las autoridades locales. Además, la inspección tradicional es subjetiva, pero el aprendizaje profundo permite detectar y evaluar anomalías de manera precisa y eficiente a través del análisis automático de imágenes y datos no invasivos.

En el entorno nacional, para INEI (6) argumenta que, en el estado de los pavimentos y carreteras en Perú puede variar debido a varios factores, como la falta de mantenimiento, el clima adverso, el tráfico intenso y la calidad de la construcción inicial. Algunos departamentos muestran un aumento en el mal estado de los pavimentos, como Amazonas (13%) y Ancash (6.2%). En contraste, otros departamentos experimentan mejoras, como Cusco (11.3%), Apurímac (-5.9%), y Arequipa (-4.5%). Varios departamentos enfrentan una disminución significativa en la calidad de los pavimentos, como Huancavelica (-21.7%), Huánuco (-22.3%), Loreto (-19.2%), San Martín (-28.4%), y Ucayali (-24.2%).

Se propone desarrollar una aplicación móvil que utilice algoritmos de aprendizaje profundo para analizar en tiempo real imágenes y datos, con el objetivo de identificar y evaluar el estado de los pavimentos.

Ante ello, se presenta la problemática general ¿En qué magnitud la ejecución de una aplicación móvil utilizando técnicas de Deep Learning interviene en la identificación de anomalías en pavimento del distrito de "Socabaya", 2023?

Justificación teórica, según Qureshi et al. (7) argumentan que, el uso de algoritmos de aprendizaje profundo ha demostrado ser eficaz en interpretar datos complejos, como imágenes y patrones, permitiendo una identificación precisa y automatizada del estado del pavimento. Estos algoritmos se basan en modelos matemáticos y

redes neuronales que pueden aprender y mejorar con la experiencia, lo que es esencial en el análisis de datos de infraestructura vial.

Justificación operativa, así mismo Quresshi et al. (7) mencionan que la implementación de una aplicación móvil con algoritmos de aprendizaje profundo para analizar pavimentos mejora considerablemente la inspección y el mantenimiento de carreteras. Actualmente, evaluar el estado de los pavimentos es costoso y manual, además de llevar mucho tiempo. La propuesta permitirá inspecciones en tiempo real, agilizando la toma de decisiones.

Justificación Tecnológica, para Quresshi et al. (7) se centra en la capacidad de los algoritmos de aprendizaje profundo para procesar grandes cantidades de datos complejos de manera rápida y precisa. La aplicación móvil propuesta aprovecha esta capacidad y la combina con la capacidad de los dispositivos modernos para capturar datos en tiempo real.

El objetivo general es determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep Learning interviene en la identificación de anomalías en pavimento del distrito de "Socabaya", 2023; Del mismo modo los objetivos específicos son: (a) Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep interviene en la medición y detección de grietas en pavimento de una zona del distrito de Socabaya, 2023; (b) Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep interviene en la medición e identificación de desprendimiento de agregados en pavimento de una zona del distrito de Socabaya, 2023; (c) Determinar en qué magnitud la ejecución de una aplicación móvil utilizando Deep interviene en la medición y detección de piel de cocodrilo en pavimento de una zona del distrito de Socabaya, 2023.

METODOLOGÍA

El tipo de investigación es aplicada se enfocó en el desarrollo de un sistema inteligente utilizando Deep Learning para la detección y diagnóstico de anomalías del pavimento y el enfoque es cuantitativo, son dos elementos fundamentales en la investigación científica, haciendo referencia al conjunto de pasos, técnicas y

herramientas utilizadas para la investigación con el propósito de obtener resultados y conclusiones válidas y confiables.

Se implementó un diseño de investigación pre experimental, enfoque básico en la investigación científica que implica la manipulación de una variable independiente para observar su efecto en una variable dependiente, sin la inclusión de un grupo de control. Es decir, no se establece una comparación directa entre grupos, lo que limita la capacidad de establecer relaciones causales sólidas.

El estudio del diseño pre experimental permitió verificar el comportamiento de un antes y después de los indicadores.

Variable independiente: Aplicación móvil utilizando técnicas de Deep Learning.

Variable dependiente: Anomalías en pavimento

Por lo tanto, la población del estudio consta de 250 fotografías tomadas en las principales calles pavimentadas de San Martín de Socabaya, ubicado en el Distrito de Socabaya. Estas imágenes fueron capturadas en cinco calles específicas que están pavimentadas con asfalto en la mencionada zona.

Tabla 1.
Principales Calles de la zona de San Martín de Socabaya

Distrito	Zona	Tipo	Nombre	Distancia en kilómetros	Cantidad imágenes
Socabaya	San Martín de Socabaya	Av.	San Martín	1.27	80
		Calle	Oroya	0.74	50
		Av.	Unión	0.72	45
		Calle	Caraveli	0.84	65
		Calle	Huancayo	0.66	40

Nota. Elaboración propia.

La muestra en la presente investigación fueron 280 fotografías que se obtuvieron desde un teléfono inteligente en el distrito de Socabaya siendo el punto focalizado San Martín de Socabaya donde se obtuvo los datos para la siguiente investigación.

Por lo que, del resultado determinamos y asignamos el universo que se aplicó en la muestra de la presente investigación siendo un total de 152 fotografías capturas a través del teléfono inteligente de la zona de estudio.

La unidad de análisis para la investigación fue pavimento de la zona del distrito de Socabaya.

Por ende, el muestreo probabilístico del estudio debido a que calculo la muestra para las zonas pavimentadas que presenta anomalías de tipo de grietas, huecos y piel de cocodrilo que se necesita para el estudio a través de las fotografías segmentadas las cuales serán tomadas de las principales calles pavimentadas de la zona de San Martín de Socabaya del distrito de Socabaya.

El estudio se utilizó la técnica de observación e instrumento guía de observación para tomar nota de los resultados de los indicadores como como la precisión, recall, f1.

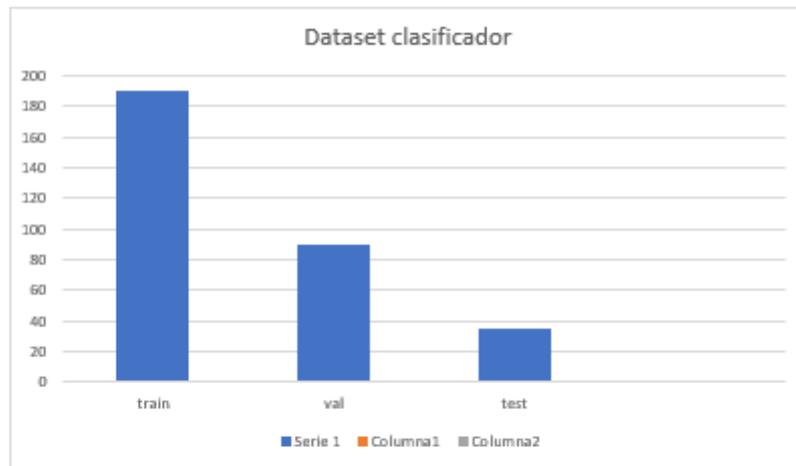
- *Se Llevo a cabo la selección de estudio para determinar la población para toma de datos mediante imágenes para la construcción de la data set.*
- *Se procedió a etiquetar los datos, identificando áreas con anomalías y problemas en el pavimento.*
- *Procesamiento / segmentación de imágenes*
- *Se utilizo el aprendizaje profundo para el desarrollo del modelo de detección de anomalías. Esto implicó la creación y entrenamiento de la red neuronal convolucional (CNN) que analizo las imágenes y resalto las áreas de interés. Durante el proceso de entrenamiento, el modelo aprendió a identificar patrones asociados con diferentes tipos de anomalías en el pavimento.*
- *Posteriormente, se realizó la fase de validación y ajuste fino del modelo utilizando datos adicionales. Una vez que el modelo alcanzo un nivel adecuado de precisión y confiabilidad, se integró en una aplicación o plataforma que permitió a los administradores de infraestructuras y autoridades locales supervisar el estado del pavimento y tomar medidas preventivas de mantenimiento.*
- *Se desarrollo la aplicación móvil*

RESULTADOS

Los resultados presenta la información obtenida durante el proceso de aprendizaje profundo, mostrando la caracterización y validación de los conceptos.

Análisis descriptivo

Para el análisis descriptivo es importante mencionar la zona de estudio donde se recolectaron imágenes a través de teléfonos móviles, ya que es similar al presente estudio y fue elegida para ayudar a identificar grietas y agujeros.



Conjunto de imágenes que representa la ~~dataset~~ dataset

La parte "Train" contiene 200 fotografías durante el entrenamiento, 100 fotografías en la parte "Val" como datos para confirmar sus secretos y tratar de hacerlo más fácil, y 30 fotografías tomadas como indicación del fracaso de la prueba. Intentaremos analizar los resultados de la muestra de entrenamiento, lo que revelará la medición de la variable dependiente y nos permitirá obtener nueva información.

Análisis de las métricas del entrenamiento.

Se obtuvieron las métricas del resultado del desarrollo de entrenamiento de las redes neuronales donde se aprecia a detalle todos los indicadores como la precisión, recall o sensibilidad, arrojando los equivalentes de puntuación.

Con conocimientos de las métricas donde se visualiza la gráfica de las mAP el cual representa la medición del efecto en los enfoques que están etiquetadas en pixeles ejecutados en el rendimiento. Está es una de las formas de segmentación semántica es el método más común para obtener la precisión media de la media representada por las iniciales (mAP). En la primera grafica de la selección de métricas, encontramos el margen de la media al 0.5 mientras que en la segunda grafica se puede ver la gráfica estadística del margen del 0.5 al 0.95, así como la precisión y el recuento responsables de la recuperación de información. Además, las gráficas de la perdida ocurrida durante el proceso de optimización se puede visualizar en la segunda fila.

Las imágenes agrupadas en la fila de validación (val) muestran los resultados obtenidos durante el entrenamiento y la fila de la variable "x", que representa el sesgo y el peso proporcionado por la red neuronal dentro de los límites de las épocas indicadas. hasta 150.

La matriz que se muestra en la figura anterior representa el conjunto de datos como porcentaje de respuesta correctas, teniendo en cuenta ciertas características y criterios de elegibilidad, dividido por el corte que permitió respuestas a las preguntas formuladas. En una hipótesis que planteo las siguientes preguntas: ¿Deep Learning permitirá detectar defectos en el pavimento en la zona el distrito de Socabaya en el 2023? Y permite resultados positivos para la detección de

grietas y agujeros de alta precisión utilizando técnicas de aprendizaje profundo en una arquitectura neuronal convolucional.

En este sentido, la función de la matriz de confusión jugo un papel importante en el desarrollo de esta investigación, debido a los argumentos denominados negativos y positivos que conducen a la unión de operaciones lógicas son valores parametrizados en valores de 0 y 1 que serán usados por los log-los o perdida logarítmica. indicando el valor de las etiquitas es 0 representa a la confianza obstante si es valor de 1 con aproximación del 0.51 de probabilidad, sin embargo, el margen de error se encuentra en el punto de corte del 0.5.

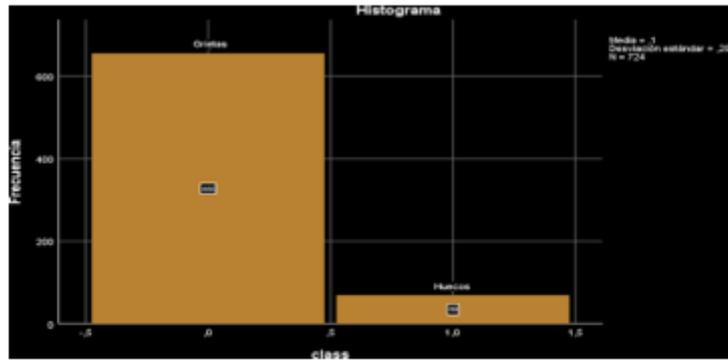
Análisis del resultado de validación de imágenes.

Con este fin, realizamos experimentos en un subconjunto de 30 imágenes de dataset_clasificacionGH para evaluar el rendimiento de confianza y analizar las mediciones obtenidas.

deteccion de clases						
	valido		perdidos		total	
	N	porcentaje	N	porcentaje	N	porcentaje
clases	726	100.00%	0	0.00%	726	100.00%

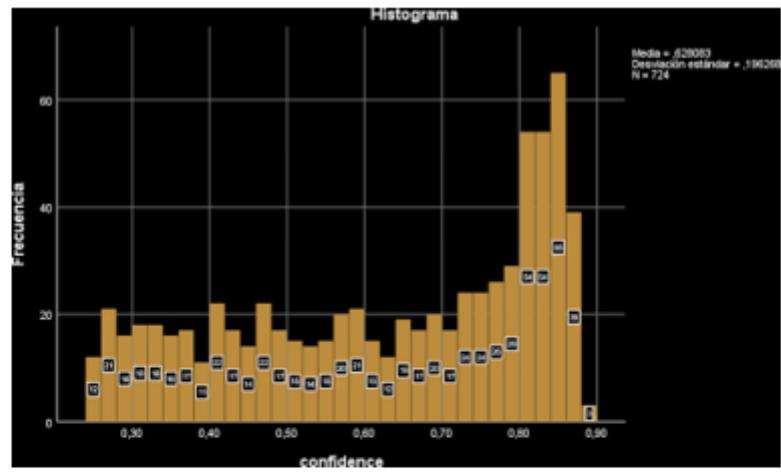
Dónde:

N = representa el número total de iteraciones de imágenes a probar y validar y las categorías que se perderán en el proceso. Clase = representa el número de clases (grietas y huecos) encontradas en N secciones.



Histograma de la detección de tipos de clases (grietas y hueco) en 30 imágenes,

donde:



Histograma de confianza obtenido de 30 verificaciones de imágenes tiene un valor promedio superior al 50%, un índice de 0,62 y la diferencia llega a 0,19 cuando se repite 724 veces.

Tipo de Métrica	resultado
Accuracy	0.867
ROC AUC Macro Unidad	0.943
ROC AUC Micro Unidad	0.946
F1 - Score Macro Unidad	0.881
F1 - Score Micro Unidad	0.867
ROC AUC GRIETA	0.92
ROC AUC HUECO	0.91
Unidad de precisión Grieta	0.933
Unidad de precisión Hueco	0.775
F1 - score Grieta	0.867
F1 - Score Hueco	0.778

Elaboración propia

Del estudio de las respuestas de las pruebas realizadas se obtuvieron resultados de medición similares, como que la precisión promedio del área fue de 0,93% y 0,77%, mientras que la transparencia de las grietas alcanzó 0,92% y 0,91% en algunos lugares, y finalmente, algunas encontramos grietas llega al 0,86%, y en algunos lugares llegan al 0,77%.

Desarrollo del Aplicativo

Después de encontrar nuevos conjuntos de datos que podrían implementarse en sistemas inteligentes, continuamos diseñando y desarrollando programas en el lenguaje de programación Python, utilizando algunas de las bibliotecas descritas. Utilice los métodos y procedimientos de este artículo para preparar el sistema para su uso con los indicadores y funciones, para obtener información sobre las imágenes que se muestran en las secciones 17 a 34 del Apéndice. Por lo tanto, a través de los parámetros establecidos en la demostración, se obtuvieron mediciones utilizando los ajustes en la matriz, dando como resultado la

identificación de grietas y huecos en caminos estructurales como concreto y grava en el área de estudio.

Discusión

Los resultados obtenidos fueron óptimos para la detección de grietas y surcos en estructuras viales como asfalto y concreto en el área de estudio, principalmente en las zonas dañadas. Para ello se han implementado varios procesos utilizando métodos de aprendizaje profundo y herramientas tecnológicas. Por ejemplo, se puede observar que algunos métodos tienden a capturar imágenes estáticas para estudiar la detección de grietas (Fan et al. (2020)). 0,19 y 0,92, y la recuperación osciló entre 0,67 y 0,93 en F1 y 0,28 y 0,92 en F1 para imágenes con resoluciones de 768x512, 991x462 y 311x462 píxeles. Los indicadores obtenidos de las obras alcanzan los indicadores entre 0.32 como parte de la confiabilidad.

1920x1080 Píxeles Resolución 0.85.

Las tareas bañadas se basan en rutas que se pueden usar en estructuras de carreteras, incluidas las transacciones de píxeles de las estructuras de carreteras, incluidas las transacciones de píxeles de píxeles. Identificar la brecha (entonces otras personas). 2020), método utilizado para desarrollar este artículo.

La detección de grietas y agujeros se determinó mediante aprendizaje profundo utilizando un método de recopilación de datos de una aplicación de fotografías para teléfonos inteligentes implementado por Maeda et al. (2018), que arrojó resultados positivos en la detección de grietas y agujeros en esta dirección del tráfico. Se lograron los objetivos utilizados en este estudio.

CONCLUSIONES

El objetivo de este estudio se logró mediante un método de investigación profundo para identificar grietas y baches en caminos de cemento o asfalto en las vías principales del distrito de Socabaya en la ciudad de Arequipa. Los errores que ocurren en la construcción de carreteras se identifican a través de un sistema desarrollado bajo una arquitectura de red neuronal, que analiza la ubicación de grietas y huecos de manera estable a través de imágenes recopiladas con teléfonos móviles.

Asimismo, el cálculo de los efectos y la determinación de las diferencias entre ellos se determina mediante métodos de aprendizaje profundo basados en modelos e implementados en un sistema inteligente que se puede ver directamente mediante una cámara. Además, para el segundo indicador de precisión de grieta, incluida la sensibilidad y los gráficos, determinado por las herramientas utilizadas en el estudio, se mostrarán los mismos indicadores en el próximo capítulo.

Además, este estudio utilizó el algoritmo YOLOv5, que es uno de los sistemas más optimizados para detectar grietas y agujeros en asientos, además, también utilizó este modelo para entrenar una red neuronal y tuvo muchos resultados. En concreto, se podrían utilizar capacidades futuras para evaluar diferentes tipos de grietas que aparecen al tomar fotografías o mirar video.

REFERENCIAS

1. *Large-scale evaluation of pavement performance models utilizing automated pavement condition survey data.* **SHU, Xiang [et al.]**, s.l. : *International Journal of Transportation Science and Technology*, 11, 1-12, 2022.
2. *A systematic review of steel bridge deck pavement in China.* **CHEN, Leilei [et al.]**, s.l. : *Journal of Road Engineering*, 1-15, 2023.
3. *Predicciones automáticas de daños en el pavimento utilizando varios algoritmos de aprendizaje automático: evaluación y comparación.* **NYIRANDAYISABYE, Ritha [et al.]**, s.l. : *Resultados en Ingeniería*, 16, 1-11, 2022.
4. **ARRELLANO, Saúl.** *Estas son las entidades con peores calles y avenidas.* *MexicoSocial* . [En línea] 2020. <https://www.mexicosocial.org/las-entidades-con-peores-calles-y-avenidas/>.
5. **LA REPUBLICA.** *Del total de la red vial terciaria con la que cuenta Colombia, 96% está en mal estado. Del total de la red vial terciaria con la que cuenta Colombia, 96% está en mal estado.* [En línea] 2019. <https://www.larepublica.co/infraestructura/del-total-de-la-red-vial-terciaria-con-la-que-cuenta-colombia-96-esta-en-mal-estado-2828335>.
6. **INSTITUTO NACIONAL DE ESTADÍSTICA E INFORMÁTICA.** *Indicador de la Actividad Productiva Departamental - Cuarto Trimestre 2021. Indicador de la Actividad Productiva Departamental - Cuarto Trimestre 2021.* [En línea] 2022. <https://m.inei.gob.pe/biblioteca-virtual/boletines/produccion-nacional-departamental-9836/2022/1/#lista>.

7. *Deep learning framework for intelligent pavement condition rating: A direct classification approach for regional and local roads.* **QURESHI, Waqar [et al.]**. s.l. : *Automation in Construction*, 153, 1-20, 2023.
8. **MAYORGA, Diego**. *Diseño de un modelo de aprendizaje de máquina para reconocimiento y clasificación de daños en pavimento para vías de Sogamoso.* s.l. : *Universidad Nacional de Colombia*, 1-31, 2023. *Tesis Maestría*.
9. **ORTEGA, Julian**. *Aprendizaje profundo para la detección automática de fisuras de hormigón usando redes neuronales convolucionales.* s.l. : *Universidad Politécnica de Valencia*, 1-115, 2021. *Tesis Maestría*.
10. **RODRÍGUEZ, Francisco**. *Sistema automático para la detección y clasificación de grietas en pavimentos.* s.l. : *Universidad de Córdoba*, 1-183, 2020. *Tesis Pregrado*.
11. **TELLO, Lizette [et al.]**. *Detección de grietas en el pavimento usando técnicas de procesamiento de imágenes y redes neuronales artificiales.* s.l. : *Universidad del Valle*, 1-9, 2021.
12. *Clasificación y detección automatizadas de múltiples imágenes de deterioro del pavimento basadas en aprendizaje profundo.* **LIA, Deru [et al.]**. s.l. : *Journal of Traffic and Transportation Engineering*, 10, 1-15, 2023.
13. **ZÚÑIGA, Yenmy**. *Deep Learning Para la Detección de Fallas en Pavimentos de una Deep Learning Para la Detección de Fallas en Pavimentos de una.* s.l. : *Universidad César Vallejo*, 1-126, 2022.

14. **BACA, María; SIHUACOLLO, Julio.** *sistema inteligente basado en deep learning para mejorar el correcto uso personal de mascarillas en el supermercado wong.* s.l. : Universidad César Vallejo, 1-81, 2022.
15. **HUAROTE, Raul.** *Deep learning para la mejora en la gestión de reservas hospitalarias en el Hospital Mariano Molina Scippa de Comas, Li,a-2020.* s.l. : Universidad César Vallejo, 1-70, 2021.
16. **ESPARZA, Jose.** *Rede neuronales convolucionales en la detección de efeccciones respiratorias de los sistemas locales de salud: Un resvisión sistemática entre los años 2010 y 2020.* s.l. : Universidad Privada del Norte, 1-34, 2020.
17. **HERNANDEZ, Antonio.** *Identificación automatica de gatos mediante reconocimiento de imágenes usando redes neuronales convolucionales.* s.l. : Universidad Señor de Sipán, 1-83, 2022.
18. *Informática industrial avanzada hacia carreteras inteligentes, seguras y sostenibles: un estado del arte.* **YAO, Hui [et al.],** s.l. : *Journal of Traffic and Transportation Engineering*, 10,1-16, 2023.
19. *Monitoreo de la salud in situ de pavimentos de cemento y concreto basado en tecnología de detección de fibra óptica.* **WANG, Huaping [et al.],** s.l. : *Revista de ingeniería vial*, 3, 1-11, 2023.
20. **GLINICKI, Michal.** *Diagnosis of ASR damage in highway pavement after 15 years of service in wet-freeze climate region.* s.l. : *Case Studies in Construction Materials*, 17, 1-15, 2022.

21. *Comprehensive assessment of the durability deterioration of asphalt pavement in salt environment: A literature review.* **Jiang, Qi [et al.]**. 2023, Vols. *Case Studies in Construction Materials*, 17, 1-22.
22. **MURRAGARRA, Ana; Ruiz, Jenny.** *Gestión de mantenimiento de pavimento de carreteras en base al modelo HDM-4 en diferentes países. una revisión sistemática.* s.l. : Universidad priva del norte, 1-51, 2021.
23. *A review of machine learning and deep learning applications in wave energy forecasting and WEC optimization.* **SHADMANI, Alireza [et al.]**. s.l. : *Energy Strategy Reviews*, 49, 1-20, 2023.
24. *Ensemble deep learning: A review.* **Ganaie, M.A [et al.]**. s.l. : *Engineering Applications of Artificial Intelligence*, 115, 1-10, 2022.
25. *Redes neuronales artificiales u sus aplicaciones.* **BASOQAIN, Xabier.** s.l. : *Escuela Superior de Ingeniería de Bilbao EHU*, 1-79, 2023.
26. *The Tong Test: Evaluating Artificial General Intelligence Through Dynamic Embodied Physical and Social Interactions.* **PENG, Yujia [et al.]**. s.l. : *Engineering*, 9, 1-34, 2023.
27. *Deep learning for anomaly detection in log data: A survey.* **LANDAUER, Max [et al.]**. s.l. : *Machine Learning with Applications*, 12, 1-19, 2023.
28. **SIERRA, J y SANTOS, M.** *Redes neuronales y aprendizaje por refuerzo en el control de turbinas eólicas.* s.l. : *Revista Iberoamericana de Automática e Informática industrial*, 18(4), pp. 327–335., 2021.

29. *Un estudio integral sobre la detección del cáncer de piel mediante redes neuronales artificiales (ANN) y redes neuronales convolucionales (CNN).* **SHAHA, Aarushi [et al.]**. s.l. : eSalud clínica, 6, 1-9, 2023.
30. *Adaptive filters in Graph Convolutional Neural Networks.* **APICELLA, Andrea [et al.]**. s.l. : Pattern Recognition, 144, 1-11, 2023.
31. *A novel recurrent neural network based online portfolio analysis for high frequency trading.* **CAO, Xinwei [et al.]**. s.l. : Expert Systems with Applications, 233, 1-11, 2023.
32. *SHERSTINSKY, Alex. ndamentos de la red neuronal recurrente (RNN) y la red de memoria a corto plazo (LSTM).* s.l. : Physica D: Fenómenos no lineales, 404, 1-12, 2020.
33. *CASTAÑEDA, María. The scientificity of quantitative, qualitative and emerging methodologies.* s.l. : Revista Digital de Investigación en Docencia Universitaria, 16, 1-12, 2022.
34. *A review of deep learning in dentistry.* **HUANG, Chenxi [et al.]**. s.l. : Neurocomputing, 554, 1-13, 2023.
35. *Generalized Morse Wavelets parameter selection and transfer learning for pavement transverse cracking detection.* **MARTINEZ, Erick [et al.]**. s.l. : Engineering Applications of Artificial Intelligence, 123, 1-25, 2023.
36. *Evaluación de procedimientos empleados para determinar la población y muestra en trabajos de investigación de posgrado.* **MUCHA, Luis [et al.]**. s.l. : Desafíos, 12, 1-8, 2021.
37. *SÁNCHEZ, Diana. Técnicas e instrumentos de recolección de datos en investigación.* s.l. : TEPEXI Boletín Científico de la Escuela Superior Tepeji del Río, 9, 38-39, 2022.