



FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

**Deep Learning Para la Detección de Fallas en Pavimentos de una
Zona del Distrito de Villa María del Triunfo 2022**

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:
Ingeniero de Sistemas

AUTOR:

Zúñiga Guisado, Yenmy (ORCID:0000-0002-0185-912X)

ASESOR:

Mgtr. Ing. Alarcon Cajas, Yohan Roy (ORCID:0000-0001-5382-3754)

LÍNEA DE INVESTIGACIÓN:

Sistemas de Información y Comunicaciones

LIMA – PERÚ

2022

DEDICATORIA

El presente trabajo de tesis está dedicado a Dios, a mis padres, hermanos (as) quienes fueron el principal motor de seguir adelante con mis sueños, asimismo a mi familia y en especial a mi prometida por todo el apoyo moral e incondicional durante todo este tiempo ya que sin ellos nada hubiera sido posible alcanzar los objetivos trazados.

AGRADECIMIENTO

A todas las personas que de alguna forma contribuyeron con el logro del presente trabajo, asimismo a mi familia quienes estuvieron presentes en todo momento.

Índice de Contenidos

I.	INTRODUCCIÓN.....	11
II.	MARCO TEÓRICO.....	18
III.	METODOLOGÍA	34
3.1.	Tipo y diseño de investigación	35
3.2.	Variables y operacionalización	37
3.3.	Población, muestra y muestreo	37
3.4.	Técnicas e instrumentos de recolección de datos	41
3.5.	Procedimientos	42
3.6.	Métodos de análisis de datos	47
3.7.	Aspectos éticos	48
IV.	RESULTADOS.....	51
V.	DISCUSIÓN.....	75
VI.	CONCLUSIONES.....	77
VII.	RECOMENDACIONES.....	79
	REFERENCIAS	81
	ANEXOS	94

Índice de tablas

Tabla 1. Principales calles de la zona de José Carlos Mariátegui.	38
Tabla 2. <i>Características para la captura de imagen</i>	42
Tabla 3. <i>Resumen de procesamiento en la detección de clases</i>	65
Tabla 4. <i>Resumen del resultado de las métricas</i>	66

Índice de figuras

<i>Figura 1.</i> Índice de inversión en el sector construcción según zona geográfica.....	13
Figura 2. Mapa del distrito de Villa María del Triunfo	14
<i>Figura 3.</i> Adaptación sobre la red neuronas artificiales: a) representa neurona con una entrada mientras que en b) son múltiples entradas (Sarmiento, 2020).....	23
<i>Figura 4.</i> Estructura U-net con CNN (Lee et al., 2019).....	24
Figura 5. Arquitectura AlexNet, aplicada con CNN (Turay, 2022)	25
Figura 6. Adaptación del modelo estructurado de red neuronal convolucional multicapas (Ramalingam et al., 2021).....	25
Figura 7. Arquitectura de red neuronal convolucional de forma unitaria (Fan et al., 2020).....	26
Figura 8. Adaptación del esquema general de la metodología CommonKADS.....	27
Figura 9. Adaptación de la metodología SCRUM para el desarrollo del trabajo (Soukaina et al., 2021), (Shahzad et al., 2022).....	29
Figura 10. Adaptación del cuadro estadístico sobre la calificación de lenguajes de programación registrado a junio de 2022, según el reporte emitida por TIOBE.....	31
Figura 11. Diseño general de la investigación.....	36
Figura 12. Metodología general.....	36
Figura 13. Recolección de imágenes.....	40
Figura 14. Proceso de captura de imágenes.....	43
Figura 15. Modelo de la red convolucional.....	46
Figura 16. Filtro en diferentes estados de la dilatación convolucional.....	46
Figura 17. Dimensiones de la imagen para el entrenamiento.....	47
Figura 18. Conversión de imágenes a matrices, mediante la técnica del etiquetado en el sistema MakeAlphaSense.....	53
Figura 19. Conjunto de imágenes que representa la dataset.....	54
Figura 20 Instalación de la arquitectura YOLOv5.....	55
Figura 21 Proceso de entrenamiento	56
Figura 22. Métricas de la precisión, recall, mAP (Sun et al., 2021)	57
Figura 23. Métricas de la validación, así como el registro de salidas.....	58

Figura 24. Curva del puntaje (F1) durante la confianza en el entrenamiento de 149 épocas.....	58
Figura 25. Precisión durante la recuperación de información en la curva de ROC. .	59
Figura 26. Precisión y confianza.....	59
Figura 27. Recuperación de información durante la confianza.....	60
Figura 28. Matriz de confusión	60
Figura 29. Resumen del resultado de las métricas ocurridas durante el entrenamiento de las imágenes.	61
Figura 30. Registro de resultados obtenidos durante el entrenamiento de la dataset_clasificacionGH , asimismo vemos la precisión en la detección de grietas y huecos clasificadas en indicadores 0 y 1.	62
Figura 31. Resultado de las redes neuronales convolucionales aplicadas para detectar grietas y huecos sobre estructuras viales en pavimentos como asfaltado o concreto.	63
Figura 32. Imagen con recuadros de identificación de grietas y huecos sobre pavimento de asfaltado.	64
Figura 33. Imagen con recuadros de identificación de grietas y huecos sobre pavimento de asfaltado.	64
Figura 34. Histograma de la detección de tipos de clases (grietas y hueco) en 30 imágenes, donde.....	65
Figura 35. Histograma sobre la confianza obtenida de la validación de 30 imágenes, donde la media supera el 50% siendo el indicador de 0.62, mientras que la desviación alcanza a 0.19 en un total de 724 iteraciones.	66
Figura 36. Matriz de confusión	68
Figura 37. Característica Operativa del Recepto (ROC) general de las dimensiones grietas y huecos.	69
Figura 38. Curva de ROC de las dimensiones de grieta y hueco.....	70
Figura 39. Precisión de la curva del ROC bajo la sensibilidad o recall.....	71
Figura 40. Indicador del Accuracy	72
Figura 41. Matriz de imágenes capturas, donde se evidencia las dimensiones de grietas y huecos sobre los pavimentos de asfaltado y concreto.....	73

RESUMEN

La tesis de investigación desarrolla un sistema de inteligencia artificial basado en el aprendizaje profundo que detecta fallas en pavimentos de una zona del distrito de Villa María del Triunfo mediante arquitecturas de redes neuronales convolucionales. Asimismo, la razón del desarrollo de este sistema se debe a que actualmente existen grietas y huecos, producto por diferentes causas.

Motivo por el cual su objetivo es determinar mediante técnicas del aprendizaje profundo la existencia de grietas y huecos sobre estructuras de pavimentos asfaltados o de cemento empleando metodologías de CommonKAD'S el cual permitió desarrollar un sistema inteligente haciendo uso del algoritmo YOLOv5, así como lenguaje de programación Python, bibliotecas de OpenCV, Numpy, TensorBoard, Pytorch, Matplotlib, Qt, herramientas tecnológicas como PyCharm, Spyder. Asimismo, el tipo de investigación es aplicada bajo un enfoque cuantitativo.

El estudio se desarrolló en la zona de Jose Carlos Mariátegui siendo la población 420 imágenes capturadas a través del teléfono inteligente de estructuras viales que contengan grietas y huecos, analizando una muestra de 201 imágenes. El muestreo de la investigación es probabilístico por lo que es por conveniencia aplicando ficha de registro.

Por consiguiente, se realizó el test de 30 imágenes alcanzando el nivel de confianza promedio de 0.62% de un total de 724 iteraciones, siendo los resultados en la precisión de grietas 0.93% y en huecos 0.77%, mientras que la sensibilidad en grietas 0.92% y en huecos alcanza a 0.91%, por último, en grietas alcanzo 0.86% y en huecos alcanza el 0.77%.

Palabras clave: Aprendizaje profundo - Inteligencia artificial - Tecnología
- Convolucional- Red neuronal.

ABSTRACT

The research thesis develops an artificial intelligence system based on deep learning that detects faults in pavements in an area of the district of Villa María del Triunfo through convolutional neural network architectures. Likewise, the reason for the development of this system is due to the fact that there are currently cracks and holes, due to different causes.

Reason why its objective is to determine, through deep learning techniques, the existence of cracks and holes on asphalt or cement pavement structures using CommonKAD'S methodologies, which allowed the development of an intelligent system using the YOLOv5 algorithm, as well as the Python programming language. , OpenCV libraries, Numpy, TensorBoard, Pytorch, Matplotlib, Qt, tech tools like PyCharm, Spyder. Likewise, the type of research is applied under a quantitative approach.

The study was carried out in the Jose Carlos Mariátegui area, with the population being 420 images captured through the smartphone of road structures that contain cracks and holes, analyzing a sample of 201 images. The sampling of the investigation is not probabilistic, so it is for convenience by applying a registration form.

Therefore, the test of 30 images was carried out, reaching the average confidence level of 0.62% of a total of 724 iterations, with the results in the accuracy of cracks being 0.93% and in holes 0.77%, while the sensitivity in cracks was 0.92%. and in holes it reaches 0.91%, finally, in cracks it reaches 0.86% and in holes it reaches 0.77%.

Keywords: Deep learning - Artificial intelligence - Technology - Convolutional- Neural network.

I. INTRODUCCIÓN

A nivel mundial existen pavimentos en buen estado, debido a una buena calidad en la composición de los componentes de sus estructuras en asfaltados o en concretos, esta calidad también se debe a una buena gestión de monitoreos que se deben realizar de manera constante por parte de las autoridades competentes, los mismos que deben analizar y realizar los mantenimientos correspondientes sobre estas anomalías que se generan en el tiempo en las superficies viales, asimismo cabe mencionar que en otras partes del mundo como en Europa su población se encuentra satisfecho por la calidad de sus estructuras viales, mientras que la puntuación en números decimales en América latina sobre la calidad empleada abarca el 3,6 punto una ligera mejora entre los años 2007 y 2008 donde alcanzó 3,2 puntos, en comparación a los años 2015 y el 2016 en el cual alcanza 3,5 puntos (Chauvet y Albertone, 2018), mientras que en América del Norte específicamente en México según el Instituto Nacional de Estadística y Geografía - INEGI el promedio total del buen estado de sus vías de transportes abarca a un 17.3% de aprobación (Arellano, 2020), de sus estructuras superficiales que se encuentran deterioradas o agrietadas (Moriyoshi *et al.*, 2021), a causa de diferentes factores como la baja calidad de los componentes en las estructuras de los asfaltados de pistas o concretos los cuales se encuentran propensos a agrietarse, asimismo están expuestos a cambios climáticos así como el incremento de transporte público, transportes de cargas pesadas, falta de señalización (Li, Liu, Li, Guo, Wu, 2021); factores que debilitan y ocasionan accidentes por su mala infraestructura (Chun y Ryu 2019) impactando en la población, y congestionando el tráfico en el transporte público (Azimjonova y Özmen, 2021).

En el Perú la calidad de sus infraestructuras viales en términos generales alcanza a un nivel de insatisfacción por parte de la comunidad, ya que la inversión y ejecución en el rubro del sector de construcción sólo durante el cuarto trimestre del 2021 alcanzó a un índice muy bajo del -5,8% el cual acredita que el Estado no ejecuta adecuadamente la inversión en el sector, donde se encuentran rubros importantes de inversión en infraestructuras viales, sistemas de saneamientos entre otros que permitan que las vías de transportes se encuentren en buenas condiciones, solo durante el último trimestre del 2021 ejecutaron los departamentos de: Amazonas -

30.6%, Ancash 6.2%, Apurímac -5.9%, Arequipa -4.5%, Ayacucho -13.2%, Cajamarca -5.1%, Cusco 11.3%, Huancavelica -21.7%, Huánuco -22.3%, Ica 9.6%, Junín 11.3%, La Libertad -14.2%, Lambayeque -4.4%, Lima -2.7%, Loreto -19.2%, Madre de Dios -6.0%, Moquegua -9.0%, Pasco -22%, Piura -13%, Puno -10.8%, San Martín -28.4%, Tacna -4.8%, Tumbes -8.1%, Ucayali -24.2% (Instituto Nacional de Estadística e Informática, 2022), en la siguiente figura se aprecia la inversión aplicada en cada departamento.

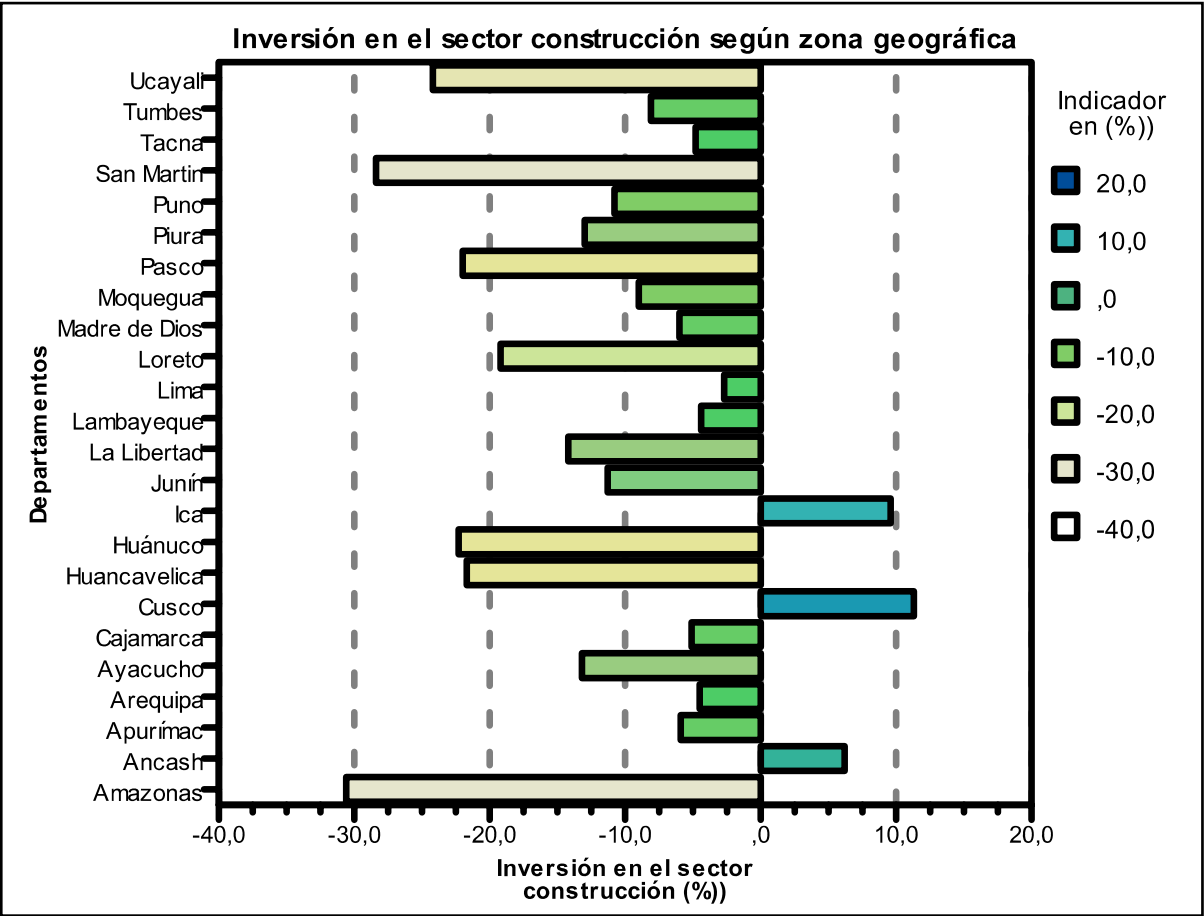


Figura 1. Índice de inversión en el sector construcción según zona geográfica.

Fuente: Indicador de la actividad productiva departamental del cuarto trimestre del 2021 con información disponible al 03-03-2022 del Instituto Nacional de Estadística e Informática.

Como se visualiza en la Figura 1, el departamento de Lima registra un indicador negativo alcanzando el -2.7% en el sector de construcción el cual se ve reflejado en el estado de las estructuras viales de la región, así como de sus provincias, mientras que en el distrito de Villa María del Triunfo la infraestructura vial solo mejoró el 26.61% durante el 2019, equivalente a 121,721.45 m² (Municipalidad Villa María del Triunfo, 2019).




Figura 2. Mapa del distrito de Villa María del Triunfo

Fuente: Adaptación de planos estratificados de Lima Metropolitana – INEI.

Bajo ese contexto uno de los problemas que atraviesa la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo son sus estructuras viales donde existen grietas y huecos, por lo que se plantea identificar estas zonas defectuosas con la ayuda de la tecnología y desarrollar un sistema inteligente que detecta grietas y huecos de las superficies viales en la zona de José Carlos Mariátegui, siendo las principales calles como: Av. Luis Pardo, Calle Arguedas, Av. José Carlos Mariátegui,

Av. Primavera, Av. Bolívar, Calle. Inti Raymi, Calle Julio César Tello, asimismo el presente trabajo de investigación se apoyó en estudios basados con *Deep Learning* y estructuras algorítmicas de redes neuronales que permiten automatizar los procesos de detección de grietas y huecos a través del aprendizaje profundo en un corto tiempo; además servirá estandarizar modelos de análisis que permita mitigar errores durante el proceso de análisis.

En lo que corresponde a la justificación práctica se puede mencionar que a través del aprendizaje profundo facilita realizar análisis de grietas (Fu *et al.*, 2021), el cual se estandariza a partir de una imagen previo al entrenamiento a fin de extraer y visualizar fallas de los pavimentos asfaltados o de concretos (Cheng, Patel, Wen, Bullock, Habib, 2020), esto consiste en rasterizar las imágenes usando arquitecturas y modelos (Zhang *et al.*, 2020) a fin de obtener resultados deseados durante el proceso de identificación de grietas (Arbaoui *et al.*, 2021), para contribuir con la estandarización de los modelos teóricos. Además, existe otras metodologías de redes neurales para detectar como YOLOv3 (Opara *et al.*, 2021), asimismo los antecedentes internacionales, donde se emplearon técnicas para detectar o identificar objetos (Coluccia *et al.*, 2021), gracias a la visión por computadoras se aplica diferentes algoritmos de redes neuronales para el reconocimiento de imágenes (Morales, Sarabakha y Kayacan, 2020), así como el aprendizaje profundo que permita detectar grietas en pavimentos (Shatnawi, 2018), de estructuras como el concreto (Shim *et al.*, 2020), usando umbrales para la segmentación del tratado de imágenes (Yusof *et al.*, 2021).

Asimismo, el desarrollo del sistema inteligente contribuirá con mejorar el estilo de vida de la sociedad donde se implemente, ya que existe en la región y otros una red vial donde se presenta anomalías superficiales como grietas, huecos que afecta indirecta o directamente el transporte de sus pobladores, así como económicamente, ambientalmente, es por ello que al aplicar estos tipos de sistemas inteligentes podremos obtener valores que nos permitan generar reportes estandarizados a fin de informar a las autoridades competentes quienes se encargan de supervisar y mantener

en buen estado, asimismo el sistema podrá contribuir con la estandarización de otras actividades que permita mejorar la calidad de vida de una región o estado.

Una de las importancias del sistema inteligente es que se desarrolla en base a software de código abierto que no generan un costo en la adquisición de las herramientas tecnológicas ya que estos son flexibles y se pueden adaptar para el análisis de datos de otras actividades relacionadas al rubro del transporte como la señalización vial, estado vial, tráfico vial que contribuyan con mejorar el transporte público, información que suma para el estudio de mejoras de la población. Asimismo, a través de estos sistemas mejorara la vida social de la comunidad gracias a las planificaciones y acciones que tomen los encargados del sector, en lo que corresponde a las medidas correctivas que identifiquen de aquellas enfermedades estructurales que vienen a travesando las calles del sector producto de diferentes causas, las cuales deben ser detectadas a tiempo y mantenerlas en buen estado para el normal funcionamiento de estas vías.

En los antecedentes nacionales, hallamos a Erech (2020), quien aplico el *Deep Learning* de forma exitosa mediante las redes neuronales convolucionales, aprendizaje que también se aplica en otros campos como la agricultura (Kienbaum, Correa Abandonado, Blas, Schmid, 2021), maderera (Ravindran *et al.*, 2021), forestal (Vizcarra, Bermejo, Mauricio, Zarate, Dianderas, 2021), desastres naturales (Shim, Kim, Cho, Lee, 2020).

Para el presente trabajo de investigación y en concordancia con la realidad problemática se planteó la siguiente pregunta del problema general ¿De qué manera Deep Learning permite la Detección de Fallas en Pavimentos de una Zona del Distrito de Villa María del Triunfo 2022?, asimismo se plantearon las siguientes preguntas del problema específico como: a) ¿De qué manera se medirá las grietas y huecos en las superficies de estructuras viales de las calles principales de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo usando el Deep Learning en el 2022?; b) ¿De qué manera se obtendrá con la detección de grietas y huecos aplicando las

redes neuronales multicapas en las principales calles de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo en el 2022?.

Bajo ese contexto el objetivo primordial fue determinar con Deep Learning la detección de fallas que se presentan en las principales calles pavimentadas de una zona de José Carlos Mariátegui del distrito de Villa María del Triunfo en el 2022.

- **Objetivo específico 1:** Determinar con Deep Learning la detección de huecos en pavimentos de las principales calles pavimentadas de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo en el 2022.
- **Objetivo específico 2:** Determinar con Deep Learning la detección de grietas en pavimentos de las principales calles pavimentadas de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo en el 2022.

Como hipótesis global se consigna que, a través de Deep Learning permite detectar fallas en pavimentos de una zona del distrito de Villa María del Triunfo en el 2022.

- **Hipótesis específico 1:** Deep Learning permite detectar huecos en las principales calles pavimentadas de una zona de José Carlos Mariátegui del distrito de Villa María del Triunfo en el 2022, ya que existe una alta precisión de resultados positivos aplicando *Deep Learning* bajo las arquitecturas de Redes Neuronales Convolucionales donde se utiliza la función de activación Relu, el cual permite aprender de manera óptima (De Ryck, Lanthaler y Mishra, 2021).
- **Hipótesis específico 2:** Deep Learning permite detectar grietas en las principales calles pavimentadas de una zona de José Carlos Mariátegui del distrito de Villa María del Triunfo en el 2022.

II. MARCO TEÓRICO

Las estructuras viales son muy importantes en una nación para su desarrollo económico, pero no es una tarea sencilla poder mantener en buen estado debido a que implica factores gubernamentales, financieros, participación ciudadana entre otros, que ameritan implementar métodos eficientes que pueda detectar anomalías que se generan sobre las estructuras viales en el tiempo como grietas y huecos en pavimentos de forma automática utilizando algunas funciones que se adquieran en el proceso de selección de información (Opara *et al.*, 2021).

Generalmente la composición de las estructuras viales está compuesta por diferentes tipos de materiales como el hormigón (Shim *et al.* 2020), este tipo de material en el tiempo se debilita ocasionando el desgaste de sus componentes los cuales están expuestas a ocasionar un grado de peligro en el transporte vial.

Según Moriyoshi *et al* (2021) menciona que el desgastamiento que ocurre sobre las estructuras viales en pavimentos de asfaltado o concreto se produce a consecuencia de las grietas, huecos o deterioros debido a que los componentes que forman estas estructuras son débiles en el sentido que no cuentan con materiales que garanticen la calidad y la vital útil de estas estructuras, por lo que es importante detectar estas fallas que ocurre sobre los pavimentos a través de las técnicas del aprendizaje profundo así como afrontando las limitaciones que se pueda presentar como las condiciones de variación de texturas, iluminación o estados que ocurren durante el cambio climático, para lo cual es importante que las redes neuronales estén preparados para identificar estas zonas defectuosas utilizando las técnicas basada en la visión computacional el cual mejore la precisión gracias al entrenamiento, pruebas del rendimiento, métodos aplicados con el aprendizaje profundo (Puly *et al.*, 2017) y el uso de herramientas tecnológicas para el etiquetado (Aizam *et al.*, 2021) (Skalski, 2022).

A fin de obtener los indicadores de la sensibilidad, precisión, puntuación se aplicó las siguientes formulas:

$$Precision = \frac{TP}{TP + FP} \quad Recall = \frac{TP}{TP + FN} \quad F1 = \frac{2Recall * Precision}{Recall + Precision}$$

Donde: Verdadero positivo será representado por TP, falsos positivos por FP y los falsos negativos por FN (Opara *et al.*, 2021), (Slami y Yun, 2021), (Qiao *et al.*, 2021). Estas fórmulas son aplicadas con metodologías y técnicas del aprendizaje profundo para obtener resultados en la detección de grietas y huecos sobre estructuras de pavimentos.

Es por ello que, Yusof *et al* (2021) enfatiza en la importancia de las vías, debido a que a través de ellas se interconecta diferentes pueblos, comunidades, distritos, países y hasta continentes. En ese sentido es común que se presenten desgastes o fallas sobre las superficies de los pavimentos debido al alto índice de transporte de diferentes tipos de cargas pesadas o livianos, interrumpiendo el objetivo de estas vías; es por ello que se requiere mantener estas vías en buen estado, para ello se debe realizar un mantenimiento adecuado y monitoreo constante a través de las capturas de imágenes el cual permita recolectar, clasificar y analizar.

Según Sabino. El proceso de la investigación define la muestra como un proceso que sea manejable sobre los elementos de la población que está compuesto por un conjunto de elementos también conocido como el universo que sea capaz de reducir en pequeñas partes para que sean accesibles al momento de analizar los datos que serán las muestras, para ello y bajo ese concepto el tipo de muestra será probabilístico ya que se analizar los grupos pequeños de la población de forma aleatoria asignando un número a cada elemento que estarán en la muestra, y estos puedan ser analizados a través de sistemas inteligentes. Mientras que Arias. El proyecto de investigación en la muestra lo define como un proceso global donde se conoce la probabilidad de cada individuo que conforma la muestra.

Sin embargo, nuevas tecnologías han desarrollado sistemas sofisticados e inteligentes fusionadas con el aprendizaje profundo que tiene la finalidad de detectar grietas y huecos que se generan a través del tiempo y estas puedan ser analizadas mediante técnicas basadas en datos. Según Cheng *et al* (2020) propone una metodología basada en umbral intenso que estandariza las supervisiones mediante estrategias del

Deep Learning el cual utiliza datos etiquetados facilitando el entrenamiento para las redes neuronales.

Hasta ahora se han implementado múltiples metodologías que detectan fallas en estructuras utilizando algoritmos que desarrollan técnicas para su mantenimiento, pero este se ha detectado más en estudios de microgrietas donde se aplica el reconocimiento de patrones de imágenes usando el aprendizaje profundo, según Yusof *et al* (2021) utilizó el método umbralización de imágenes debido a que esta metodología se prepara mediante una herramienta de etiquetado, para analizar las grietas sobre los pavimentos. Por otro lado, Shatnawi (2018), utilizó otra metodología para extraer grietas de los pavimentos mediante la captura de imágenes, permitiendo un análisis más preciso en la identificación de las formas de grietas superficiales, donde se puede determinar las características de la imagen como dimensiones (alto, ancho), tamaño, información que es importante para un entrenamiento mediante el reconocimiento de patrones de las redes neuronales.

El primer diseño o modelo sobre las redes neuronales nace por la década de 1943 planteado por Warren McCulloch, neurofisiólogo, y Walter Pitts, matemático, crearon una red neuronal utilizando los circuitos eléctricos y elaboraron un modelo informático que permitió calcular las redes neuronales basado en las matemáticas y el algoritmo umbral lógica dirigida a la inteligencia artificial (Chagas, 2019). Asimismo, la red neuronal perceptrón es un pilar fundamental en las redes neuronales artificiales, ya que es un modelo de aprendizaje el cual tiene como objetivo aprender automáticamente, así como reconocer patrones, tomar decisiones, comportamientos, entre otras actividades gracias a la entrada de datos (Sarmiento, 2020), este puede relacionar las variables de salida o el objetivo que se desea obtener.

En base al primer diseño de redes neuronales nace la historia de la inteligencia artificial por la década de 1950, con un grupo de expertos en la informática y el gran aporte del brillante matemático Alan Turing, quien escribió el artículo denominado “Computing Machines and Intelligence” haciéndose una pregunta si las computadoras podrían

“pensar” como los seres humanos, hecho que fue reconocido como el padre de la Inteligencia Artificial. Como tal, la inteligencia artificial es un campo muy amplio que abarca varias ramas, siendo las más importantes como el aprendizaje automático y el aprendizaje profundo, además incluye varios enfoques que no involucran precisamente al aprendizaje automático, ya que “Las aplicaciones de inteligencia artificial y el aprendizaje profundo se han vuelto vitales para la gestión de la infraestructura de mantenimiento” (Opara et al. 2021).

Asimismo, en dicha década se originó la metodología del aprendizaje profundo gracias al incremento masivo de datos, el cual permitió programar unidades de procesamiento gráfico, mediante el cual procesan operaciones matemáticas complejas como vectores o matrices que generalmente se encuentran en los modelos de Inteligencia Artificial, en ese sentido el aprendizaje profundo o Deep Learning facilita tareas de automatización de máquinas por si sola en base a los errores, esto era una nueva forma de aprendizaje de información basada en capas continuas o multicapas de redes neuronales.

Asimismo, la inteligencia artificial fue reforzada por la década de 1956 con una conferencia de John McCarthy, mientras que Michael Jordan incorpora una arquitectura de las “RNNs” para el aprendizaje profundo por el año 1986, no obstante, esta arquitectura alcanza a su mayor estudio y aplicación en la industria a partir del año 2015 aplicando librerías de código abierto como TensorFlow, PyTorch para el desarrollo del aprendizaje automático (Abeliuk y Gutierrez, 2021).

Además, el aprendizaje profundo implica varias capas continuas de redes neuronales, así como algoritmos complejos en capas no lineales aplicadas en la inteligencia artificial, lo que ha logrado un aprendizaje de patrones en poco tiempo, a partir del año 2010 la industria de la inteligencia artificial revolucionó a gran escala logrando grandes avances tecnológicos, como el reconocimiento de imágenes, reconocimiento de voz entre otros (Revista Bits de Ciencia, 2021), es decir que estos avances está conformado por un conjunto de algoritmos enlazados entre sí, siendo el objetivo

simular los comportamientos que hace el ser humano como reconocer una gama de objetos y diferenciar de ellos que es una función básica de las neuronas. Para Jaafari et al. (2021), define que el campo del Deep Learning fue testigo del gran avance de la ciencia que ha sido capaz de llegar al punto que las máquinas tengan esa capacidad de poder entender y manipular datos para tomar una decisión y procesarlas. Entonces podemos mencionar que los principales algoritmos que se aplican en el aprendizaje profundo son los supervisado o generativas e híbridas.

Bajo este concepto podemos mencionar que la estructura de las redes neuronales aplicadas en la inteligencia artificial tiene similitud con la estructura de la red neuronal biológica, como entrada de información a través de las dendritas el cual está unida mediante la sinapsis con el núcleo donde se procesa la información para que a través del conducto del axón emita la salida de datos procesados, este evento conlleva al aprendizaje interconectada y almacenada por el ser humano.




Figura 3. Adaptación sobre la red neuronas artificiales: a) representa neurona con una entrada mientras que en b) son múltiples entradas (Sarmiento, 2020).

No obstante, en el mundo de la inteligencia artificial existen varios tipos de redes neuronales siendo las más importantes los modelos perceptrón multicapas, redes convolucionales y las redes recurrentes, para cada tipo la certeza de probabilidad es altamente considerado por la precisión en sus cálculos que procesa los algoritmos en emitir un resultado.

Las redes neuronales o perceptrón multicapas es un modelo de red neuronal artificial donde su arquitectura, está formada por una capa de entrada, pueden existir una a más capas ocultas y una capa de salida, clasificada como múltiples capas (Bienvenido, Marín, Sánchez, Fernández, Moyano, 2019). La capa de entrada contiene varias neuronas como categorías que se puede asignar a las variables dependientes, mientras que la capa de salida serán las variables independientes o respuestas.

Mientras que la red neuronal convolucional, es un modelo CNN (Convolutional Neural Network), que tiene características valiosas para el procesamiento de imagen, a raíz de los errores que va identificando estos los utiliza para las actualizaciones de los parámetros de forma automática y toma la imagen como entrada a fin de extraer las características del mismo para su reconocimiento a través de la capa de neuronas que están enlazadas al núcleo el cual comparten información entre las mismas, este proceso agiliza profundamente la complejidad y velocidad de entrenamiento (Zhang,2021). Según los estudios realizados por Enzo et al (2021), analizó que los parámetros de información obtenidas a partir de la etapa de validación y prueba fueron exitosas o erróneas esto va depender mucho de la calidad de entrenamiento que se haya realizado a las imágenes a través de la metodología de clasificación y las arquitecturas que se apliquen, en las siguientes graficas se muestra los modelos de tipos de arquitecturas que se aplican las CNN.




Figura 4. Estructura U-net con CNN (Lee et al., 2019).

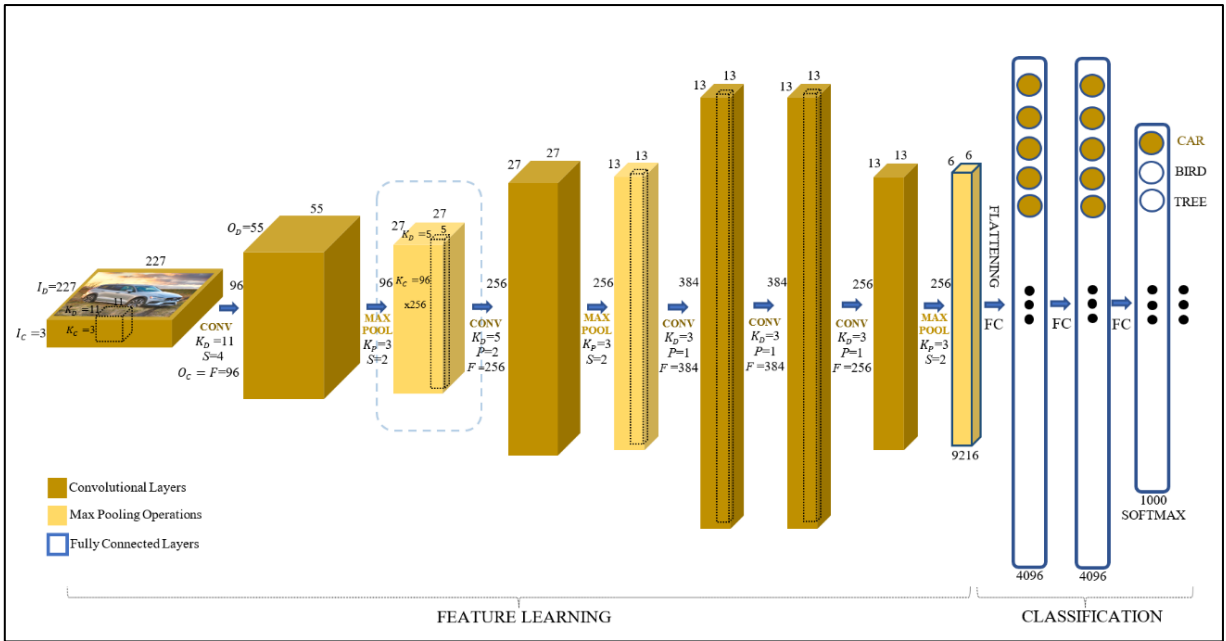


Figura 5. Arquitectura AlexNet, aplicada con CNN (Turay, 2022)

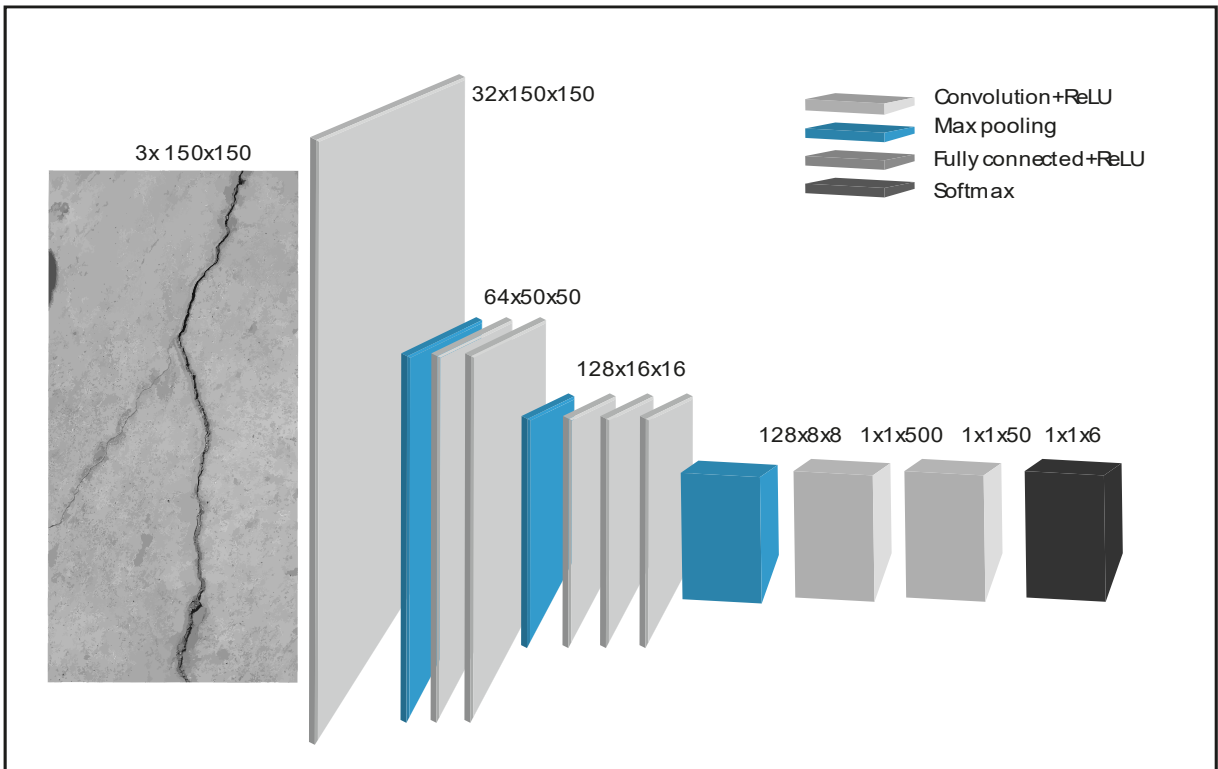


Figura 6. Adaptación del modelo estructurado de red neuronal convolucional multicapas (Ramalingam et al., 2021).

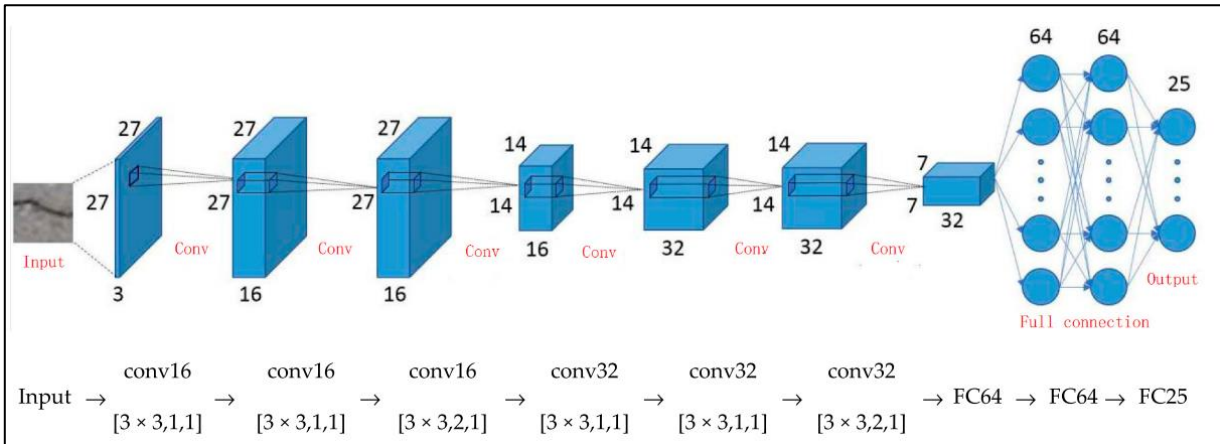


Figura 7. Arquitectura de red neuronal convolucional de forma unitaria (Fan et al., 2020).

Así como las redes neuronales recurrentes que se encuentran bajo un modelo dinámico RNN (Recurrent Neural Networks), estos son útiles al momento de analizar secuencias de gran tamaño de variables, reproducir y asociar temporalmente hasta que finalizar su proceso, generalmente son usadas en las predicciones no líneas, así como en los modelamientos de sistemas dinámicos o tratamientos que se pueden dar en las secuencias, usando la metodología de las redes profundas el cual permite ubicar puntos específicos (Almeida et al. 2021), lo que conlleva a procesarlas con redes neuronales convolucionales (CNN) para su activación mediante la función ReLu (Rectified Lineal Unit), y el aprendizaje profundo (Kumar et al., 2021), en estructuras denominadas CrackDFAN (Qiao et al., 2021), debido al alto nivel de precisión en detectar grietas en pavimentos basados a través del entrenamiento con las redes neuronales (CNN), que usa una arquitectura Encoder-Decoder, en fusión con el modelo DeepLabv3+ (Zhang et al. 2020) para el procesamiento de las imágenes.

Además, una de las redes neuronales del aprendizaje profundo muy conocido es YOLOv3, método que se utiliza para la detección de objetos y posicionamiento a partir de una imagen, este proceso es fundamental para la detección de tipos de agrietamiento y huecos en superficies de pavimentos (Opara et al., 2021).

Asimismo, para el análisis y desarrollo del sistema inteligente se usará la metodología y técnica especializada CommonKADS el mismo que garantizará resultados positivos gracias a los aspectos esenciales que ofrece esta metodología como los niveles contextuales que abarcan los módulos de la organización, tareas, agentes, así como el nivel conceptual compuesto por el conocimiento y la comunicación, como último nivel se encuentra el artefacto que incorpora el diseño (Palma y Morales, 2008), todos estos niveles y modelos se encuentran relaciones entre si con un objetivo tal como se puede visualizar en la siguiente gráfica.




Figura 8. Adaptación del esquema general de la metodología CommonKADS.

Fuente: Inteligencia Artificial José T. Palma M. Roque M.

A través del esquema CommonKADS, compuesto por tres niveles fundamentales y sus respectivos módulos permitió gestionar y desarrollar adecuadamente las diferentes actividades que se aplicaron para el desarrollo del sistema donde se

documentó a través de las plantillas que se encuentran anexas en la sección de anexos.

1. **Nivel contextual:** se genera un documento detallado sobre los objetivos, así como otros elementos que se usaran durante el desarrollo del presente proyecto, considerando los siguientes módulos.
 - Modelo de organización (OM): a través de los formularios se recolectará la información para su análisis basado en el conocimiento y poder identificar los problemas, así como las oportunidades que existan.
 - Modelo de tareas (MT): adquiere las principales tareas que soluciona el sistema.
 - Modelo agente: encargado de ejecutar las tareas ya sea a través de una persona o un sistema informático, el mismo que deberá detallar las funciones, características, autorizaciones y limitaciones del agente.

2. **Nivel conceptual:** describe la estructura, conocimiento y tareas que se implementaran con los siguientes módulos.
 - Modelo de conocimiento: señala tipos y estructuras del conocimiento a nivel de tareas.
 - Modelo de comunicaciones: se encargará de interactuar la información entre el agente involucrado y las tareas.

3. **Nivel de artefacto:** menciona como pasar del nivel conceptual a la implementación del software señalando su arquitectura y sistema.
 - Módulo de diseño: a través de este módulo encargado de recolectar las especificaciones técnicas del sistema previo recorrido de los puntos antes señalados, ya que se detallar la arquitectura del sistema para su implementación y ejecución del mismo, basados en los conocimientos y métodos.

La metodología Scrum nace por la década de 1990 para administrar procesos que se desarrollan en la construcción de sistemas compuestos por un equipo de recursos humanos el cual tiene la finalidad de crear sistemas flexibles y este puede optimizar la gestión de trabajo en forma sistémica (Soukaina *et al.*, 2021), es así que para el desarrollo del marco de trabajo se aplicó la metodología ágil Scrum que es muy utilizada en los proyectos modernos para el desarrollo de software aplicada en sistemas inteligentes el cual se caracteriza por su trabajo colaborativo en equipo, integración de varios procesos y por su complejidad en tecnologías innovadoras, técnicas robustas que permiten mejorar los resultados en base a nuevos enfoques y soluciones (Prokopenko *et al.* 2021), definiendo una serie de actividades para ser ejecutadas durante en el desarrollo del trabajo en base a etapas denominados sprint (Adel, 2022).

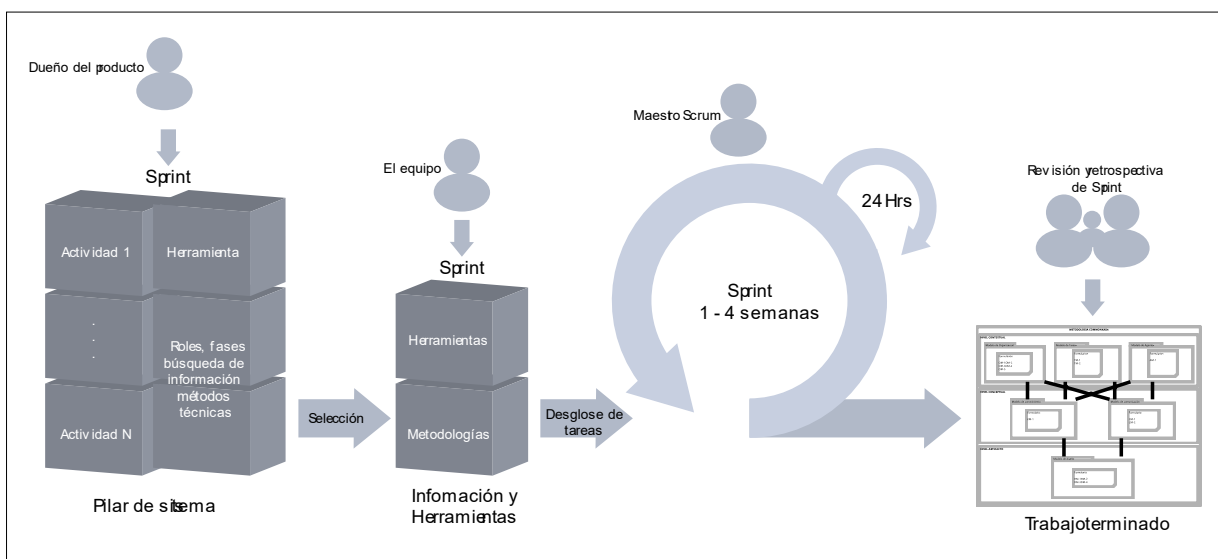


Figura 9. Adaptación de la metodología SCRUM para el desarrollo del trabajo (Soukaina *et al.*, 2021), (Shahzad *et al.*, 2022).

También, existe el modelo de proceso unificado (RUP) dividida en fases para el desarrollo de software como la concepción, elaboración, construcción y transición, a estas fases podríamos aplicar una programación extrema (XP) ya que este proceso

conlleva a niveles extremos en los requerimientos expresados en escenarios a través de una serie de tareas, generalmente este tipo de procesos son ejecutados por usuarios en pares donde realizan las buenas prácticas como el desarrollo incremental, la inclusión del cliente, las personas involucradas en el proyecto, los constantes cambios y mantener su simplicidad durante la escritura de código (Sommerville, 2011).

Para detectar fallas en estructuras de las calles a través del aprendizaje profundo es necesario adquirir algunos componentes como: CPU (Central Processing Unit) Intel(R) Core (TM) i7-10700 (2.90GHz) RAM 16GB con sistema operativo de Windows 10 basado en (64 bits), para realizar el entrenamiento de las Redes Neuronales, un teléfono inteligente con cámara integrada de 13MB (Maeda et al. 2018), (Kumar et al. 2021), que nos permitirá recolectar la información (MaXiaohe et al. 2021), luego de la captura se tendrá que realizar el etiquetado de las imágenes a través de la herramienta MakeAlphaSense a fin de etiquetar de forma manual las imágenes en pixel y convertir en formato json; asimismo existe una variedad de herramientas que permiten el etiquetado (Qiao et al., 2021) tal como se visualiza en el Anexo 16, para su análisis se usó tecnologías de software libre Python, Tensor Flow, Keras, Pytorch, YOLOv5, Colab, Google Maps, que nos permitirá estructurar los algoritmos así como el aplicativo a través de la escritura de códigos, por lo que se aplicará una investigación Pre-Experimental, que consistirá en capturar datos, procesar los modelos de segmentación, clasificar imágenes así como el reconocimiento de formas (Bouguezzi et al. 2021).

Bajo ese concepto de requerimientos es importante mencionar sobre las herramientas tecnológicas que se usaron durante el desarrollo del sistema inteligente, así como las librerías que se incorporaron al sistema, en los siguientes párrafos se describe sobre cada una de ellas.

Python, es un tipo de lenguaje de programación muy usada en la industria tecnológica el cual fue creado por Guido Van Rossum por el año 1989, siendo uno de los lenguajes más usados en el mercado según el reporte de encuestas emitida por la compañía Tiobe Software (Jansen, 2022), en el cual se recopila información sobre el uso de los

lenguajes de programación activa hasta el mes de junio de 2022 (Cass, 2021), tal como se aprecia en la siguiente figura.




Figura 10. Adaptación del cuadro estadístico sobre la calificación de lenguajes de programación registrado a junio de 2022, según el reporte emitida por TIOBE.

En la figura anterior se aprecia en primera fila con una calificación de 12.20% acredita al lenguaje de programación Python, gracias a la cantidad de librerías disponibles a la población de forma gratuita en su portal oficial (['https://www.python.org/'](https://www.python.org/)), el cual se utilizó con la importación de diferentes librerías necesarias para la implementación del sistema inteligente, así como para el entrenamiento de las redes neuronales, bajo ese contexto la versión aplicada en el proyecto se utilizó Python 3.9.

Asimismo, a través del servicio Colab se realizó la programación y ejecución de YOLO, así como la de sus librerías de forma óptima el cual garantizó la confiabilidad gracias a su arquitectura (Opara et al. 2021), asimismo la escritura de código bajo este servicio de Colab no requiere realizar configuraciones, también se tiene acceso a GPU's o Unidad de Procesamiento Gráfico de forma gratuita el cual optimiza el procesamiento de información en grandes lotes del aprendizaje profundo. No obstante, el servicio de la compañía Google ofrece una gama de recursos y productos gratuitos, así como

API's para incorporar en proyectos, es por ello que se adiciona los servicios de Google Maps.

Por otro lado la participación de PyTorch fue importante para desarrollar el sistema inteligente ya que brinda un conjunto de bibliotecas de tensores estructurados multidimensionales que están especialmente optimizadas para implementar el presente trabajo de investigación gracias a los aprendizajes profundos de la inteligencia artificial siendo sus principales características numpy y la redes neuronales profundas que se utilizan mediante las unidades de procesamiento gráfico GPU o a través de las unidades central de procesamiento CPU, asimismo esta arquitectura es muy usada en reconocimiento y detección de clases sobre estructuras pavimentos como grietas, huecos el cual hace uso de algoritmos de redes neuronales convolucionales (Arbaoui et al., 2021), (Shim et al., 2020), sofisticados en la precisión y velocidad del proceso (Qiao et al., 2021).

Asimismo, se utilizó las herramientas tecnológicas que ofrece la compañía esri fundada por Jack Dangermond como ArcGIS Pro y ArcMap que permitió la edición, diseño, tratamiento y publicación de información geográfica que está relacionado a la zona de estudio, también una organización más estructurada sobre la ubicación geográfica que se requirió para el flujo de trabajo optimizado en la recolección de capturas de imágenes de las pistas con grietas y huecos.

Para contribuir con el párrafo anterior se utilizaron las herramientas tecnológicas de Adobe Inc. que se aplicaron en la vectorización, redimensionamiento, creación de figuras geométricas para el aplicativo y esta tenga como producto de calidad en la estética visual para el usuario. Sin embargo, se complementa con el uso del software Visual Paradigm en su versión 16.3 donde se estructuró los diferentes procesos para el desarrollo del aplicativo, así como Bizagui Modeler, Archi – archimate modelling en su versión 4.8.1 que complementa con el diseño y flujo del trabajo sistémico

Para visualizar y calcular figuras estadísticas se utilizó la herramienta tecnológica de IBM denominado IBM SPSS Statistics en su versión 26, que permitió extraer

información estadística de forma eficaz el cual contribuye con la precisión de datos, así como la gestión y análisis requerida para la investigación.

La codificación de código es fundamental para el proceso, en ello se utilizaron las herramientas como Pycharm Community, Spyder, Anaconda 3, Anaconda Navigator, Qt Designer, aplicativos esenciales que permitieron organizar, estructurar el flujo de desarrollo de trabajo, a ello se incorporaron librerías gratuitas como PyQt5, cv2, Numpy, Keras, PyTorch, Pandas, json, yaml, así como hojas de estilo en sus formatos css, qss y otras que requeridas en el desarrollo del sistema.

III. METODOLOGÍA

EL presente trabajo de investigación, se basará en la metodología aplicada debido a que se usará herramientas tecnológicas bajo un enfoque cuantitativo, esto permitirá un horizonte claro en la aplicación del aprendizaje profundo, usando técnicas de procesamiento de imágenes. Asimismo, con esta metodología nos permitirá ubicar puntos específicos en un mapa de fotogramas (Almeida *et al.* 2021), lo que conllevará obtener formas.

La población donde se aplicará estará delimitada por siete principales calles de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo, asimismo se recolectará información para analizar las variables dependientes que se tiene como dimensiones grietas, huecos y de esta forma se mostrará los resultados.

3.1. Tipo y diseño de investigación

Por consiguiente, el tipo de investigación es aplicada por que estará orientada a resolver los problemas, así como a mejorar el funcionamiento de los sistemas conjuntamente con el aporte indispensable de la tecnología, tal como lo define Hernández, Fernández y Batista (2014), el cual cumple con dos propósitos esenciales como son: producir conocimiento, teorías que abarca la investigación básica y la de resolver problemas que corresponde al campo de la investigación aplicada, que quiere resolver un problema en la identificación de grietas y huecos a través del aprendizaje profundo.

En ese sentido el diseño que se aplicará será pre-experimental de una sola prueba, según Hernández, Fernández y Batista (2014), está diseñado por dos grupos, uno que recepciona el tratamiento experimental y el no experimental, es decir que el nivel que alcanzará la manipulación de la variable independiente será a los niveles de presencia o ausencia, al finalizar se adicionará la medición de la variable dependiente siendo el siguiente diseño:




Figura 11. Diseño general de la investigación.

GP = Grupo preexperimental, dentro de este campo se realizará la recolección de información para su análisis.

X = Evaluación de la variable dependiente (grietas, huecos y el porcentaje en detectar), mediante la ejecución del aprendizaje profundo.

0 = Resultados obtenidos del proceso de imagen.

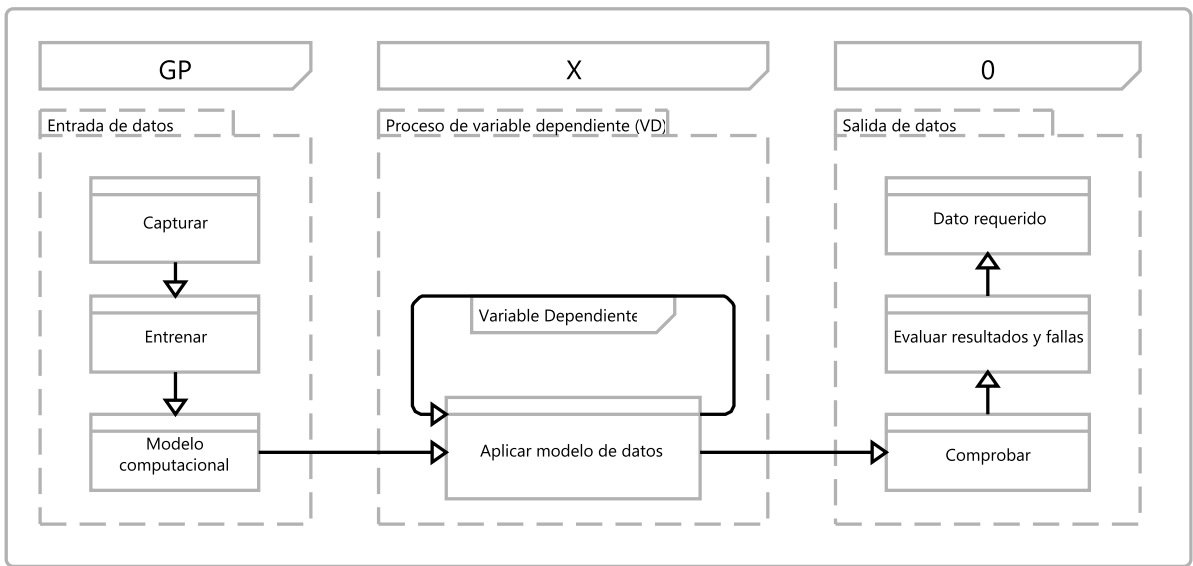


Figura 12. Metodología general

Como se visualiza en la imagen N° 10, está distribuida en tres grupos definidas como GP=grupo preexperimental donde se realizará la recolección de información, X=será la variable dependiente a analizar los tipos de grietas que existan en las superficies de los pavimentos y mostrar el porcentaje de precisión, finalmente 0=será visualizar los resultados analizados de la variable dependiente no obstante se detalla a mayor precisión los siguientes puntos:

- Entrada de datos: Capturar datos de las zonas dañadas a través del uso de un teléfono inteligente para realizar el análisis de las imágenes, asimismo mediante pruebas de modelos de segmentación se aplicó la limpieza de datos a fin de que nos permita elegir un modelo apropiado para el entrenamiento de la data set.
- Proceso de variable dependiente (VD): Aplicamos el modelo de los datos elegidos para identificar los tipos de grietas que existan en las principales calles de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo.
- Salida de datos: En esta etapa podremos comprobar la información procesada a través del aprendizaje profundo y muestre como resultados los tipos de fallas en un tiempo determinado.

3.2. Variables y operacionalización

En este punto tenemos como variable independiente (VI) el Deep Learning y como variable dependiente (VD) los tipos de pavimentos que serán capturadas a través de un dron para el análisis de las imágenes. Para profundizar a más detalles se incorpora al presente trabajo de investigación una tabla de cuadro de operaciones de variables que se muestra en la sección de anexos.

3.3. Población, muestra y muestreo

Asimismo, la población del presente trabajo de investigación estará compuesto por un conjunto de calles de las cuales se realizaron la captura de 420 imágenes de siete principales avenidas pavimentadas entiéndase los asfaltados y concretos que conforman la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo excluyéndose aquellas calles consideradas como trochas y arenales para la investigación.

Tabla 1. Principales calles de la zona de José Carlos Mariátegui.

Distrito	Zona	Tipo	Nombre	Distancia en kilómetros	Cantidad imágenes
VMT	José Carlos Mariátegui	Av	Luis Pardo	1.56	130
		Calle	Arguedas	0.37	80
		Av	José Carlos Mariátegui	3.00	50
		Av	Primavera	1.21	40
		Av	Bolívar	1.71	50
		Calle	Inti Raymi	0.38	20
		Calle	Julio César Tello	0.91	50

Fuente: elaboración propia.

La muestra según Arias (2012) y Sabino (1992), lo define como un subconjunto de información que se extrae de la población de forma representativa o finita y que sea accesible a los datos como tamaño y características que permitan analizar, obtener resultados con un margen de error, para ello se usa la técnica del muestreo.

Bajo ese concepto de muestra en la presente investigación se aplicó un conjunto de 420 imágenes obtenidas a través de la captura de imagen desde un teléfono inteligente, para ello es importante mencionar la ubicación geográfica el cual se complementa con la Figura 2, en la siguiente figura visualizamos la zona de estudio (ver Anexo 11) ubicado en el distrito de Villa María del Triunfo siendo el punto focalizado de nombre Jose Carlos Mariátegui donde se obtuvo los tipos de clases denominados grietas y huecos que obran en pavimentos de asfaltado y concreto superficies de las viales de tránsito.

En el cual se aplicó la siguiente formula donde:

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

Siendo las siguientes características:

n = Universo de la muestra

Z = Representa el nivel de confianza al 95% (1.96) para la investigación

N = Representa la población de la zona de estudio

p = Probabilidad de éxito representado en 0.5

q = Probabilidad del fracaso representado en 0.5

E = Margen de error considerado al 5%

Aplicando la formula con los valores obtenidos se visualiza la siguiente información como resultado.

$$n = \frac{1.96^2 * 420 * 0.5 * 0.5}{(420 - 1) * 0.05^2 + 1.96^2 * 0.5 * 0.5} = 200.89 = 201$$

Por lo que, del resultado determinamos y asignamos el universo que se aplicó en la muestra de la presente investigación siendo un total de 201 imágenes capturadas a través del teléfono inteligente de la zona de estudio.

En lo que corresponde al muestreo de la investigación será por conveniencia, debido a que en las zonas detalladas en la tabla 2, existen tipos de grietas y huecos que se requiere para el estudio a través del reconocimiento de imágenes segmentadas en pixeles (Fu *et al.* 2021) las cuales serán capturadas de las principales calles pavimentadas de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo. Por otro lado, es importante mencionar que para el objetivo se aplicara modelos y arquitecturas que está dividida en múltiples módulos jerárquicos (Fan *et al.* 2020), para un análisis adecuado de las imágenes que se capturen Zhang *et al.* (2020), a través de un teléfono inteligente y estas sean descargadas para sus respectivos procesos haciendo uso de los principios de validación (Sun *et al.* 2021). En consecuencia, se hará un registro de las principales características y dimensiones, así

como el registro del tipo de algoritmo para su entrenamiento a fin de medir el tiempo de demora en la prueba de *Testing*, y otras características que se considere durante el proceso.

Para lo cual se ha desarrollado un registro de recolección de imágenes especialmente de grietas y huecos que obran en las superficies viales de la población de estudio de los cuales se capturo 420 imágenes.




Figura 13. Recolección de imágenes.

Para mayor detalle se visualiza el Anexo 12, donde se considera una serie de campos que se tomaron en consideración para la recolección de datos como: defecto, tipo de pavimento, tipo de inspección, formato, tamaño real de la captura de imagen, asimismo se realizaron la redimensión de las imágenes para que este pase a la fase de preparación de imágenes, estos datos son esenciales para preparar la dataset que se usaran para el entrenamiento.

3.4. Técnicas e instrumentos de recolección de datos

Después de seleccionar el diseño de investigación apropiada, así como la muestra relacionada a la formulación del problema y la hipótesis, se debe recoger cierta información que nos permita medir las características de nuestras variables de forma sistemática el cual garantice el grado de confiabilidad, eficacia, a fin de realizar los análisis adecuados (Hernández, Fernández y Batista, 2014) a través del método cuantitativo observacional. Asimismo, la técnica que se utilizó fue el fichaje ya que nos permitió recolectar la información de la variable dependiente asignando un valor, bajo ese concepto es que se utilizó el instrumento de ficha donde se realizó el registro de los elementos de la población que fue utilizado en el muestreo.

Asimismo, es importante mencionar la herramienta del teléfono inteligente que nos permita recolectar capturar imágenes de alta calidad tal como lo sustenta (Maeda et al. 2018) y (Shatnawi, 2018) en diferentes condiciones de iluminación y aparatos garantizando la variedad y complejidad de aquellas superficies de pavimentos (Eslami y Yun, 2021), que se encuentren con diversas fallas o agrietas, detalles que son muy importante para un debido proceso a través del aprendizaje profundo, este mecanismo también permite una accesibilidad altamente segura y en un menor tiempo, el cual disminuye el malestar anímico que se pueda generar durante su proceso de recolección de datos en pleno tráfico o evitar accidentes (Opara et al.,2021), por otro lado estas metodologías nos permitirá realizar ciertas observaciones sobre las imágenes capturadas para su respectivo procesamiento y análisis (Eslami y Yun, 2021), el cual estará clasificada por las siguientes características como son: tipo de pavimento, clase de defecto, tamaño de la imagen capturada, tipo de color de las imágenes capturadas que contengan como valor el canal RGB (Blue, Green, Red) también conocida como colores reales.

Tabla 2. *Características para la captura de imagen.*

Tipo de pavimento	Clase	Defecto	Tamaño	Tipo
Asfaltado y concreto (flexibles - rígidos)	Grieta	transversal	1920x1080	RGB
		longitudinal	1920x1080	RGB
		cocodrilo	1920x1080	RGB
	Hueco	Cubierta de pozo	1920x1080	RGB

Fuente: Elaboración propia

La información establecida en la Tabla 2 denominada “Características para la captura de imagen” se tomó como base de la información establecida en la Tabla 1 “Principales calles de la zona de José Carlos Mariátegui”, a fin de identificar las grietas y huecos de las vías de tránsito.

3.5. Procedimientos

En esta etapa es importante mencionar los detalles para el procesamiento adecuado de las imágenes, debido a que se usara las redes neuronales a través de su arquitectura convolucional, es por ello que se agruparan las imágenes juntamente por tamaño a fin de incrementar la capacidad receptiva del proceso y este emita resultados de muestra segmentada en píxeles, para ello la base del tamaño de la imagen será de 1920 x 1080 píxeles, en ese sentido el proceso estará involucrada por las siguientes áreas e instrumentos esenciales para lograr el objetivo como: área o zonas de pavimentos agrietadas, mediante el teléfono inteligente se recolecto la información para ser enviadas a una memoria de almacenamiento y estas inicien con el procesamiento de imágenes mediante técnicas a través del aprendizaje profundo, para mayor precisión se muestra la siguiente gráfica.




Figura 14. Proceso de captura de imágenes.

Como se visualiza en la Figura N° 11, el proceso de capturas de imágenes estará dividida en dos fases captura de imagen y redimensionamiento de imagen, el cual consisten en:

- Identificar las zonas agrietadas en pavimentos o que se encuentren con diferentes fisuras superficiales.

- Utilizar el instrumento de recolección de datos “teléfono inteligente”, para la captura de imágenes y envío a una memoria de almacenamiento para su clasificación y análisis correspondiente.
- Redimensionamiento y clasificación de las imágenes a través de herramientas tecnológicas como Adobe Photoshop CC en su versión 2019.
- Etiquetar imágenes, mediante la herramienta que ofrece Make Alpha Sense, ya que las grietas en pavimentos de asfaltado o concreto tienen diferentes formas y dimensiones, esta herramienta facilita el uso de los trazos geométricos el cual permite crear, editar una gama de formas como rectángulos, cuadrados, círculos, polígonos, puntos, tira de líneas.
- Centro de procesamiento de imágenes, esta área es el encargado de procesar las imágenes a través de técnicas de aprendizaje profundo. Asimismo, dicha área ejecuto secuencialmente tareas como la adquisición de imágenes, procesamiento previo, entrenamiento de los modelos y finalmente detectar las clases de grietas y huecos aplicando los modelos del aprendizaje profundo en nuevas imágenes que se incorporan al sistema.

Bajo ese enfoque, para analizar las capturas de imágenes obtenidas desde el teléfono inteligente haremos uso la ficha de registro que se detalla en el Anexo 14 a fin de agrupar las características y clases establecidas de la Tabla N° 2, y esta genere la transición a la etapa de procesamiento, así como al entrenamiento de imágenes, ya que es necesario clasificar algunas propiedades como el color, las escalas de tonalidad, la adaptación de las nuevas imágenes ya entrenadas y aplicar en diferentes modelos. En consecuencia, como objetivo principal analizaremos las nuevas imágenes obtenidas del entrenamiento en base a la información introducida en la ficha de registro y estas cumplan con identificar las diferentes clases de grietas en pavimentos asfaltados o concretos.

Para poder analizar los indicadores estadísticamente usaremos la herramienta de visualización IBM SPSS Statistics 26, TensorBoard, Colab, PyTorch el cual nos permite analizar la hipótesis general y específica acorde a los datos propuestos para determinar su validez o no de la información.

En ese sentido es importante mencionar las clases y estructuras de las redes neuronales que se aplicaron en la presente investigación siendo la arquitectura convolucional conformada por una serie de capa de entrada que será el ingreso de la dataset este a fin de pasar a la siguiente capa convolucional para aplicar la filtración de las redes neuronales de 3x3, este proceso sucesivo del aprendizaje profundo permitió detectar las grietas y hueco sobre los pavimentos viales asfaltados o de concreto aplicando algoritmos basados en las CNN que permitió detectar las formas automáticamente. Asimismo, los algoritmos basados en la CNN mejoran la precisión en píxeles (Fan et al., 2020), este resultado también se puede obtener mediante las redes neuronales recurrentes RNN, las imágenes capturadas en píxeles con dimensiones (1920 × 1080 píxeles) se ingresaron en la red neuronal mediante la técnica de YOLOv5 aplicada con librerías de Pytorch, lo que genero una sobrecarga para la memoria en la unidad central de proceso. Fan et al., propone una red estructurada de conjunto que permite realizar la detección de las clases de grietas y huecos para medir las grietas en los pavimentos. Sin embargo, Maeda et al. adoptó una arquitectura de red diferente que permite la detección de imágenes de grietas a través de la transferencia de información a un teléfono inteligente, esta técnica y arquitectura de red permitió realizar la detección de las clases como grietas y huecos de las vías de tránsito en diferentes resoluciones adaptativas al dispositivo inteligente el cual facilita al operador obtener resultados confiables gracias a la arquitectura de YOLOv5 y las redes neuronales empleada en la presente investigación, en la siguiente gráfica visualizamos el modelo de la CNN.

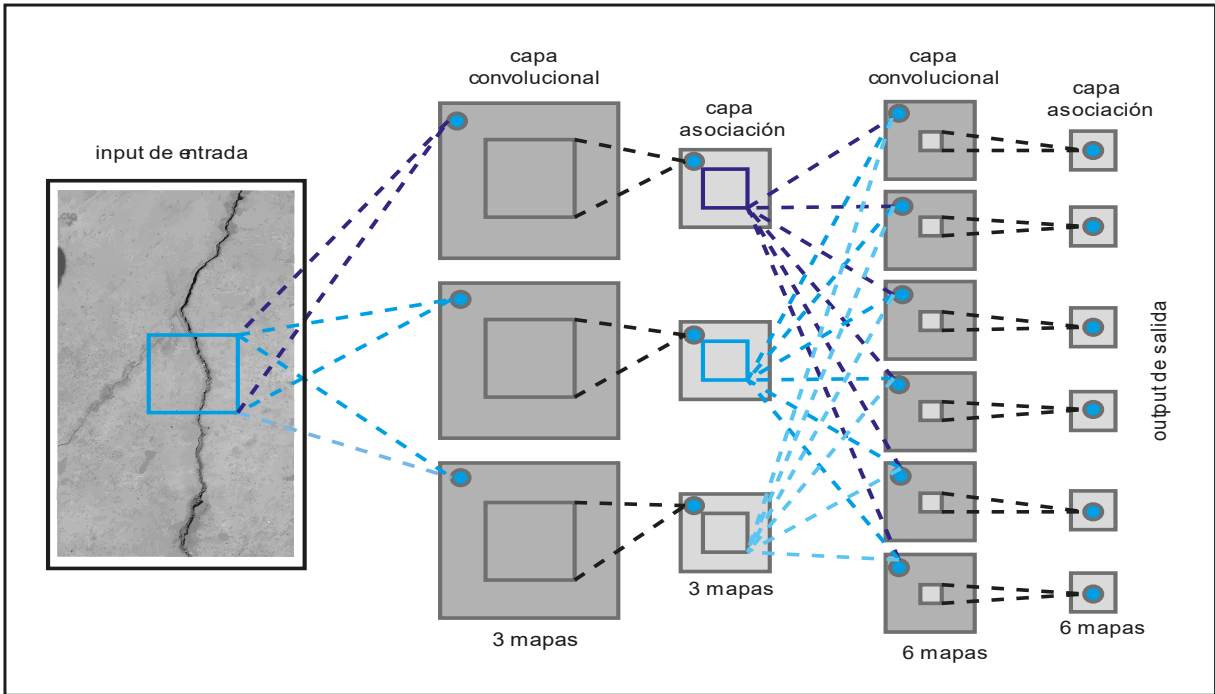


Figura 15. Modelo de la red convolucional.




Figura 16. Filtro en diferentes estados de la dilatación convolucional.

Debido a la complejidad de las vías de tránsito por su topología y nivel se aplican más de una convolución para obtener las formas de las clases grietas y huecos para ello en la figura anterior se aprecia la dilatación de las imágenes en diferentes estados donde: A) representa la tasa de filtración de 2 operaciones convolucionales, mientras que en los siguientes estados B), C) y D) se visualiza la expansión de los píxeles en 4, 8 y 16 operaciones para obtener las características de las clases en imágenes con dimensiones \geq a 1920x1080 píxeles (Fan et al., 2020).




Figura 17. Dimensiones de la imagen para el entrenamiento.

Este proceso de entrenamiento se realizó a través del servicio de Colab haciendo uso de una gama de librerías que proporciona PyTorch, OpenCV, asimismo la biblioteca de TensorBoard se utilizó para generar las gráficas del resultado, y así poder expresar y exportar el nuevo modelo de la dataset este a fin de ser implemente en un aplicativo y utilizar sus funcionalidades para el cual fue diseñada con el objetivo de obtener las grietas y hueco de los pavimentos.

3.6. Métodos de análisis de datos

En el presente trabajo de investigación se utilizará el enfoque analístico cuantitativo de forma sistemática, toda vez que nos permitirá cumplir con los objetivos planteados. Asimismo, según Shim et al. (2020) menciona que la metodología de análisis de datos consiste en evaluar el rendimiento a fin de comparar dos datos, mientras que Opara et al. (2021) señala que muchas técnicas del aprendizaje profundo han sido creadas para

analizar e identificar objetos haciendo uso de diferentes tipos de algoritmos, asimismo Ferreira et al. (2021) menciona que a través del instrumento de medición t-Student se obtiene resultados confiables, por otro lado esta metodología es respaldada por la mayoría de los expertos a nivel mundial (Torri, Giacometti y Paterlini, 2019).

3.7. Aspectos éticos

Está constituido por una serie de registros de citas y referencias que ameritó incorporar en el trabajo de investigación, acatando a cabalidad toda fuente bibliográfica así como el cumplimiento de lo normado en la referencia ISO 690 y 690-2, asimismo señalar que los elementos que se incorporen como capturas de imágenes estarán controladas de forma exhaustiva respetando la privacidad de los habitantes que involucre la zona urbana de estudio en pavimentos asfáltico o concreto, generando la originalidad y a su vez evitando el plagio.

Es importante mencionar el marco normativo legal donde establece los protocolos y normas a seguir sobre un trabajo de investigación, como:

- El Ministerio de Educación con fecha 09 de julio de 2014 publicó a través del diario oficial El Peruano la Ley N° 30220 – Ley Universitaria, donde establece en su artículo 48°, sobre la investigación en el cual señala lo siguiente: “La investigación constituye una función esencial y obligatoria de la universidad, que la fomenta y realiza, respondiendo a través de la producción de conocimiento y desarrollo de tecnologías a las necesidades de la sociedad, con especial énfasis en la realidad nacional. Los docentes, estudiantes y graduados participan en la actividad investigadora en su propia institución o en redes de investigación nacional o internacional, creadas por las instituciones universitarias públicas o privadas”.

- Código de Ética en Investigación de la UCV (Universidad César Vallejo, 2020), establece en su artículo 3° sobre los principios de ética que se deben de aplicar en los trabajos de investigación siendo los siguientes literales:

“a) Autonomía: Las personas que participen en la investigación tienen la capacidad de elegir su participación o retiro de las investigaciones en el momento que lo requieran.

b) Beneficencia: La investigación debe procurar el bienestar o procurar beneficios a los participantes del estudio.

c) Competencia profesional y científica: Las personas deben cumplir los niveles adecuados de preparación según lo requerido por la investigación, que garanticen el rigor científico en la realización de todo el proceso de investigación hasta su publicación.

d) Cuidado del medio ambiente y biodiversidad: Las investigaciones deben asegurar el cuidado de la naturaleza, promoviendo el respeto de los seres vivos y los ecosistemas.

e) Integridad humana: Se reconoce al ser humano por encima de los intereses de la ciencia, independientemente de la procedencia, estatus social o económico, etnia, género, cosmovisión cultura u otra característica.

f) Justicia: Es el trato igualitario de los participantes en la investigación, sin exclusión alguna, para el mejor desarrollo de la misma.

g) Libertad: Las investigaciones deben desarrollarse de manera libre e independiente de intereses económicos, políticos, religiosos o de otro tipo.

h) No Maleficencia: Se debe realizar un análisis riesgo/beneficio antes de realizar investigaciones para respetar la integridad física y psicológica de las personas que participen en la investigación.

i) Probidad: Se debe actuar con honestidad durante toda la investigación. Esto incluye presentar de manera fidedigna los resultados y evitar modificaciones en el

protocolo aprobado sin previa autorización por parte del comité de ética, y la incorporación de autores que no han tenido un aporte a la investigación.

j) Respeto de la propiedad intelectual: El personal investigador debe respetar los derechos de propiedad intelectual de otros investigadores, incluyendo evitar el plagio de manera total o parcial de las investigaciones de otros autores.

k) Responsabilidad: Los investigadores asumen las consecuencias de los actos derivados del proceso de investigación o productos de divulgación.

l) Transparencia: La investigación deba ser divulgada de tal modo que sea posible replicar la metodología y verificar la validez de los resultados (excepto en casos de patentes).

m) Precaución: aunque existan dudas sobre los riesgos y repercusiones negativas de determinada investigación, se deben tomar todas las medidas precautorias disponibles en el sentido de evitar daños futuros. “

Asimismo, para validar la originalidad de la información del presente trabajo de investigación se aplicó el sistema de software denominado Turnitin que compara la existencia de otros estudios análogos. Bajo ese contexto y lo señalado en los puntos anteriores se establece que se viene desarrollando el presente trabajo respetando los límites que señala la normatividad vigente.

IV. RESULTADOS

En esta sección del capítulo de resultados se detalla la información obtenida mediante el sistema del aprendizaje profundo, en el cual se describe las características y la validación de la hipótesis.

4.1. Análisis descriptivo

4.1.1. Recolección de datos de la zona de estudio

Sobre el análisis descriptivo es importante mencionar la zona geográfica de estudio (ver Anexo 11) donde se realizaron la recolección de imágenes a través del teléfono inteligente ya que guarda relación con la presente investigación las cuales fueron clasificadas para su respectivo tratamiento sobre la identificación de grietas y huecos que obren en las estructuras viales de asfaltado y concreto.

Para ello se realizó una serie de estructura sistemática de actividades que se detalla en el Anexo 12 y 13, el cual permitió recolectar la información a fin de asignar un nombre específico a cada imagen bajo las características planteadas en la ficha de recolección de datos adjuntada en el Anexo 14.

4.1.2. Etiquetado de imagen

Asimismo, culminada con la selección se procedió a utilizar técnicas de diseño para redimensionamiento las imágenes a un tamaño estándar de 1920x1080 pixeles a través de las herramientas de Adobe Cloud a fin de seleccionar la herramienta tecnológica MakeAlphaSense que permitió el etiquetado, así como la conversión de imágenes a matrices a fin de exportar el conjunto de archivos compatibles con YOLO, toda vez que cada imagen contenga la información de las matrices requeridas para realizar el entrenamiento a través del servicio de Google Colaboratory y arquitectura YOLO, la herramienta seleccionada para este punto se encuentra en el Anexo 16, donde se visualiza su estructura asimismo su funcionalidad es de fácil uso gracias a su diseño y simplicidad en el proceso del etiquetado, que permitió etiquetar de forma sistémica en el desarrollo.

Conversion de imagen a matriz

Clase	Matriz	Nombre de imagen y tipo de extensión	Ancho	Altura
Hueco	81 284 1766 330	grieta_1.jpg	1920	1080
Hueco	58 172 1198 447	grieta_10.jpg	1920	1080
Grieta	45 314 1004 223	grieta_100.jpg	1920	1080
Grieta	45 306 1868 301	grieta_101.jpg	1920	1080
Grieta	391 489 1249 302	grieta_102.jpg	1920	1080
Grieta	472 473 468 159	grieta_103.jpg	1920	1080
Hueco	313 418 122 103	grieta_103.jpg	1920	1080
Grieta	742 390 544 193	grieta_104.jpg	1920	1080
Grieta	475 521 232 221	grieta_104.jpg	1920	1080
Grieta	204 291 1668 413	grieta_105.jpg	1920	1080
Grieta	117 750 430 313	grieta_105.jpg	1920	1080
Grieta	405 10 1118 746	grieta_106.jpg	1920	1080
Grieta	19 613 351 176	grieta_106.jpg	1920	1080
Grieta	531 495 175 486	grieta_107.jpg	1920	1080
Grieta	1276 15 276 425	grieta_107.jpg	1920	1080
Grieta	1074 481 205 574	grieta_107.jpg	1920	1080
Grieta	44 221 1800 447	grieta_108.jpg	1920	1080
Grieta	390 423 285 114	grieta_109.jpg	1920	1080
Hueco	355 289 1098 661	grieta_11.jpg	1920	1080
Hueco	1361 69 549 597	grieta_11.jpg	1920	1080
Hueco	47 111 516 257	grieta_11.jpg	1920	1080
Grieta	265 439 957 237	grieta_110.jpg	1920	1080
Grieta	69 323 177 321	grieta_111.jpg	1920	1080
Hueco	714 448 488 170	grieta_112.jpg	1920	1080
Grieta	614 330 1226 245	grieta_113.jpg	1920	1080
Grieta	59 451 415 207	grieta_113.jpg	1920	1080
Grieta	377 707 142 357	grieta_113.jpg	1920	1080
Grieta	332 389 592 259	grieta_114.jpg	1920	1080
Grieta	48 244 1812 497	grieta_115.jpg	1920	1080
Grieta	48 44 826 516	grieta_116.jpg	1920	1080
Grieta	321 18 983 725	grieta_117.jpg	1920	1080
Hueco	642 68 1052 935	grieta_118.jpg	1920	1080
Grieta	28 225 1838 482	grieta_119.jpg	1920	1080
Hueco	471 476 982 556	grieta_12.jpg	1920	1080
Hueco	611 155 626 274	grieta_12.jpg	1920	1080
Grieta	33 135 1838 888	grieta_120.jpg	1920	1080
Grieta	44 238 1826 446	grieta_121.jpg	1920	1080
Hueco	658 361 123 117	grieta_121.jpg	1920	1080
Hueco	726 350 482 329	grieta_123.jpg	1920	1080
Hueco	729 258 248 90	grieta_124.jpg	1920	1080
Grieta	122 348 1726 326	grieta_125.jpg	1920	1080
Grieta	201 356 376 262	grieta_126.jpg	1920	1080
Grieta	1036 476 639 287	grieta_126.jpg	1920	1080
Hueco	514 462 852 499	grieta_127.jpg	1920	1080
Grieta	1399 411 461 391	grieta_127.jpg	1920	1080
Grieta	386 378 1326 636	grieta_128.jpg	1920	1080
Hueco	104 57 1089 993	grieta_129.jpg	1920	1080
Hueco	221 437 765 323	grieta_13.jpg	1920	1080
Hueco	497 24 256 73	grieta_13.jpg	1920	1080
Hueco	128 129 374 167	grieta_13.jpg	1920	1080
Hueco	577 149 478 170	grieta_13.jpg	1920	1080
Hueco	1451 224 439 321	grieta_13.jpg	1920	1080
Hueco	207 810 997 259	grieta_13.jpg	1920	1080
Hueco	1466 74 321 94	grieta_13.jpg	1920	1080
Grieta	137 15 1212 856	grieta_130.jpg	1920	1080
Grieta	36 18 731 362	grieta_131.jpg	1920	1080
Grieta	923 336 876 334	grieta_131.jpg	1920	1080
Grieta	1579 529 304 150	grieta_132.jpg	1920	1080
Grieta	287 93 1338 637	grieta_133.jpg	1920	1080
Grieta	497 24 256 73	grieta_133.jpg	1920	1080
Grieta	884 15 946 1010	grieta_134.jpg	1920	1080
Hueco	429 34 768 594	grieta_135.jpg	1920	1080
Grieta	179 409 1668 281	grieta_136.jpg	1920	1080
Grieta	87 397 810 187	grieta_137.jpg	1920	1080
Grieta	997 492 904 196	grieta_137.jpg	1920	1080
Grieta	64 386 1805 285	grieta_138.jpg	1920	1080
Hueco	276 32 1568 765	grieta_139.jpg	1920	1080
Grieta	37 875 683 157	grieta_139.jpg	1920	1080
Hueco	106 49 938 405	grieta_14.jpg	1920	1080
Hueco	136 524 746 482	grieta_14.jpg	1920	1080
Hueco	940 137 190 547	grieta_14.jpg	1920	1080
Hueco	170 197 1398 743	grieta_140.jpg	1920	1080
Hueco	561 208 439 458	grieta_141.jpg	1920	1080
Grieta	1100 521 778 464	grieta_141.jpg	1920	1080
Hueco	670 355 549 343	grieta_142.jpg	1920	1080
Hueco	1442 205 266 377	grieta_142.jpg	1920	1080
Grieta	1356 668 358 380	grieta_142.jpg	1920	1080
Grieta	30 417 323 379	grieta_142.jpg	1920	1080
Grieta	86 138 539 218	grieta_142.jpg	1920	1080
Hueco	1188 395 327 214	grieta_143.jpg	1920	1080
Hueco	268 521 240 148	grieta_143.jpg	1920	1080
Grieta	550 395 413 195	grieta_143.jpg	1920	1080
Grieta	1172 672 224 390	grieta_143.jpg	1920	1080
Hueco	62 523 425 461	grieta_144.jpg	1920	1080
Hueco	22 690 307 372	grieta_145.jpg	1920	1080
Hueco	128 213 1048 708	grieta_146.jpg	1920	1080
Hueco	299 440 1527 549	grieta_147.jpg	1920	1080
Hueco	195 149 1641 899	grieta_148.jpg	1920	1080
Grieta	42 309 1337 315	grieta_149.jpg	1920	1080
Grieta	1488 245 405 290	grieta_149.jpg	1920	1080
Hueco	492 116 239 157	grieta_15.jpg	1920	1080
Hueco	938 34 224 92	grieta_15.jpg	1920	1080
Grieta	1661 309 104 598	grieta_15.jpg	1920	1080
Grieta	305 325 1276 441	grieta_150.jpg	1920	1080
Grieta	47 334 1811 330	grieta_151.jpg	1920	1080
Grieta	48 272 1636 636	grieta_152.jpg	1920	1080
Hueco	745 314 1002 455	grieta_153.jpg	1920	1080
Grieta	1613 13 137 220	grieta_153.jpg	1920	1080
Hueco	20 423 365 305	grieta_153.jpg	1920	1080
Hueco	307 286 1032 464	grieta_154.jpg	1920	1080
Grieta	95 127 1764 757	grieta_155.jpg	1920	1080
Grieta	67 88 1789 767	grieta_156.jpg	1920	1080
Grieta	505 325 1938 438	grieta_157.jpg	1920	1080
Grieta	51 278 1823 402	grieta_158.jpg	1920	1080
Grieta	65 274 1685 450	grieta_159.jpg	1920	1080
Hueco	126 104 1027 751	grieta_16.jpg	1920	1080
Grieta	55 300 1559 377	grieta_160.jpg	1920	1080
Hueco	899 384 189 435	grieta_161.jpg	1920	1080
Hueco	807 79 129 154	grieta_161.jpg	1920	1080
Grieta	33 311 1830 383	grieta_162.jpg	1920	1080
Grieta	50 263 1831 365	grieta_163.jpg	1920	1080
Grieta	51 384 1588 315	grieta_164.jpg	1920	1080
Grieta	898 99 210 977	grieta_165.jpg	1920	1080
Grieta	466 15 913 277	grieta_166.jpg	1920	1080
Hueco	991 328 399 268	grieta_166.jpg	1920	1080
Hueco	444 342 181 165	grieta_166.jpg	1920	1080
Hueco	634 884 142 128	grieta_166.jpg	1920	1080
Hueco	62 501 171 104	grieta_166.jpg	1920	1080
Grieta	83 155 1730 874	grieta_167.jpg	1920	1080
Grieta	190 76 1669 949	grieta_168.jpg	1920	1080
Grieta	142 316 1713 265	grieta_169.jpg	1920	1080
Hueco	1217 699 239 179	grieta_17.jpg	1920	1080
Hueco	798 161 1007 207	grieta_17.jpg	1920	1080
Grieta	94 66 1788 639	grieta_170.jpg	1920	1080
Grieta	142 35 1713 1007	grieta_171.jpg	1920	1080
Grieta	366 134 1732 785	grieta_172.jpg	1920	1080
Hueco	664 395 706 452	grieta_173.jpg	1920	1080
Grieta	143 27 1515 1001	grieta_174.jpg	1920	1080
Grieta	123 253 1515 418	grieta_175.jpg	1920	1080
Hueco	50 55 634 793	grieta_176.jpg	1920	1080
Hueco	711 188 203 268	grieta_176.jpg	1920	1080
Hueco	42 21 1540 856	grieta_177.jpg	1920	1080
Hueco	288 7 1373 589	grieta_178.jpg	1920	1080
Hueco	296 175 1226 684	grieta_179.jpg	1920	1080
Hueco	45 32 1308 919	grieta_18.jpg	1920	1080
Hueco	140 23 1745 865	grieta_180.jpg	1920	1080
Hueco	147 35 1727 712	grieta_181.jpg	1920	1080
Grieta	51 19 1774 983	grieta_182.jpg	1920	1080
Grieta	92 30 1738 917	grieta_183.jpg	1920	1080
Hueco	117 76 1548 965	grieta_184.jpg	1920	1080
Grieta	50 27 1649 510	grieta_185.jpg	1920	1080
Hueco	740 562 284 418	grieta_185.jpg	1920	1080
Grieta	100 30 1326 690	grieta_186.jpg	1920	1080
Hueco	123 397 1735 642	grieta_187.jpg	1920	1080
Hueco	126 305 1446 672	grieta_188.jpg	1920	1080
Hueco	365 297 1205 681	grieta_189.jpg	1920	1080
Hueco	246 44 1524 923	grieta_19.jpg	1920	1080
Hueco	50 89 1340 835	grieta_190.jpg	1920	1080
Hueco	175 60 746 794	grieta_191.jpg	1920	1080
Hueco	34 163 1308 826	grieta_192.jpg	1920	1080
Hueco	672 76 669 563	grieta_193.jpg	1920	1080
Hueco	517 182 92 84	grieta_193.jpg	1920	1080
Hueco	78 30 934 665	grieta_194.jpg	1920	1080
Hueco	443 199 935 703	grieta_195.jpg	1920	1080
Hueco	209 258 199 581	grieta_195.jpg	1920	1080
Hueco	113 520 483 443	grieta_196.jpg	1920	1080
Hueco	1200 54 688 715	grieta_197.jpg	1920	1080
Hueco	508 544 968 502	grieta_198.jpg	1920	1080
Hueco	592 35 799 596	grieta_199.jpg	1920	1080
Hueco	391 651 349 419	grieta_2.jpg	1920	1080
Hueco	67 241 228 293	grieta_199.jpg	1920	1080
Hueco	664 225 503 505	grieta_2.jpg	1920	1080
Grieta	929 465 72 175	grieta_20.jpg	1920	1080
Hueco	374 197 1378 686	grieta_200.jpg	1920	1080
Hueco	164 163 1487 775	grieta_201.jpg	1920	1080
Grieta	112 456 1627 285	grieta_21.jpg	1920	1080
Hueco	1454 499 243 137	grieta_22.jpg	1920	1080
Hueco	215 46 700 318	grieta_23.jpg	1920	1080
Hueco	246 378 1040 566	grieta_23.jpg	1920	1080
Hueco	284 19 1340 1008	grieta_24.jpg	1920	1080
Hueco	171 41 123 173	grieta_24.jpg	1920	1080
Hueco	720 138 580 541	grieta_25.jpg	1920	1080
Hueco	729 125 874 849	grieta_26.jpg	1920	1080
Hueco	28 426 650 538	grieta_26.jpg	1920	1080
Hueco	793 389 511 482	grieta_27.jpg	1920	1080
Hueco	447 150 630 729	grieta_28.jpg	1920	1080
Hueco	262 454 801 218	grieta_29.jpg	1920	1080
Hueco	64 295 1000 358	grieta_3.jpg	1920	1080
Hueco	436 365 1036 394	grieta_30.jpg	1920	1080
Hueco	148 297 288 207	grieta_31.jpg	1920	1080
Hueco	26 529 999 246	grieta_32.jpg	1920	1080
Hueco	1004 341 92 319	grieta_32.jpg	1920	1080
Grieta	545 461 714 112	grieta_33.jpg	1920	1080
Grieta	214 409 1424 195	grieta_34.jpg	1920	1080
Grieta	486 627 898 182	grieta_34.jpg	1920	1080
Hueco	226 30 1247 787	grieta_35.jpg	1920	1080
Grieta	641 616 759 140	grieta_36.jpg	1920	1080
Hueco	951 484 209 156	grieta_37.jpg	1920	1080
Grieta	62 370 1412 365	grieta_38.jpg	1920	1080
Grieta	61 375 516 209	grieta_39.jpg	1920	1080
Hueco	993 302 221 187	grieta_39.jpg	1920	1080
Hueco	1548 77 179 162	grieta_39.jpg	1920	1080
Hueco	279 72 1068 521	grieta_4.jpg	1920	1080
Hueco	266 34 1226 944	grieta_40.jpg	1920	1080
Hueco	623 372 419 146	grieta_41.jpg	1920	1080
Hueco	1528 786 1			

En la figura anterior se visualiza la transformación de datos que serán empaquetados en formato Zip, el cual representa un conjunto de datos de las clases que serán sometidas al entrenamiento, así como la validación y testeo a fin de obtener las dimensiones planteadas en la presente investigación que consisten en identificar las grietas y huecos sobre las superficies de pavimentos viales estos bien ser en tipos asfaltados o concretos.

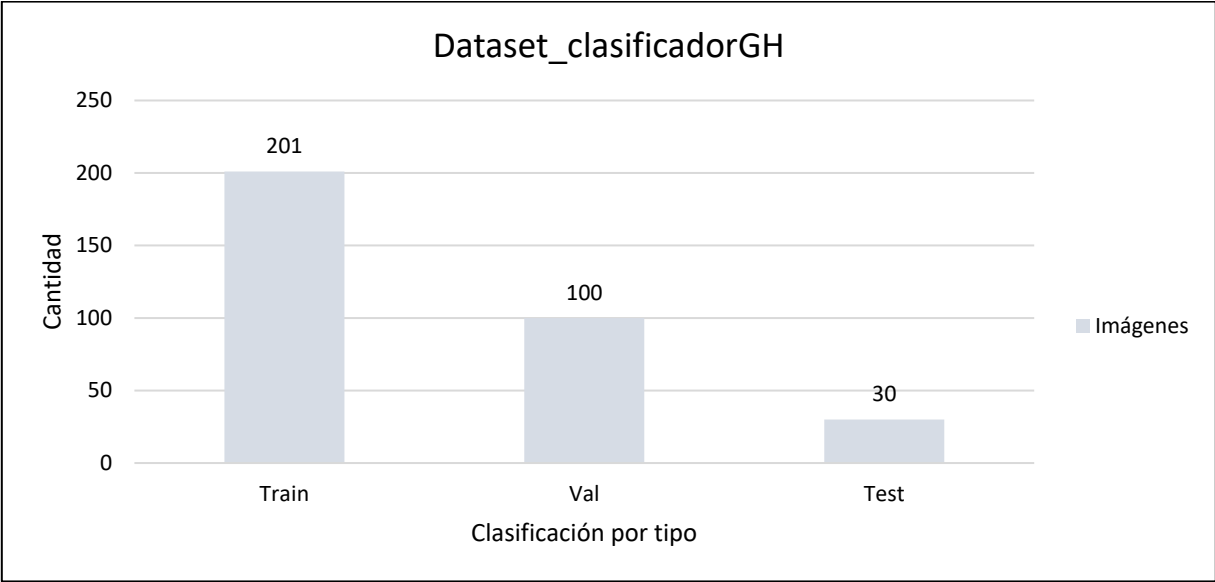


Figura 19. Conjunto de imágenes que representa la dataset.

Donde la columna denominada Train será las 201 imágenes puestas en el entrenamiento, mientras que las 100 imágenes de la columna denominada Val será el conjunto de datos para validar su confianza y para el testeo por conveniencia se tomara 30 imágenes el cual representa la columna del Test que será puesta en el testeo para analizar los resultados del modelo de entrenamiento, asimismo con ello podemos obtener las dimensiones de nuestras variables dependientes que nos permitirán adquirir el nuevo dataset.

4.1.3. Instalación de la arquitectura YOLOv5 y configuraciones de Google Colaboratory (Colab)

Asimismo, al ejecutar la arquitectura YOLOv5 se efectúa una serie de configuraciones, así como incorporar el archivo con formato yaml donde se codifican las principales

características como: el nombre de las clases, número de clases, la ruta de las carpetas train, val y test. Estas características complementan la comunicación entre YOLOv5 y el conjunto de datos “dataset_clasificadorGH”.

```

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.

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.
alBumentations 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()

```

Figura 20 Instalación de la arquitectura YOLOv5

4.1.4. Proceso de desarrollo del entrenamiento de las redes neuronales

Terminada con las configuraciones se incorpora la dataset en formato .ZIP para descomprimir las carpetas que están preparadas para el entrenamiento, y codificar en el lenguaje de programación Python los argumentos como el tamaño de la imagen, el número de lote que representa un conjunto de imágenes en una época, es decir a

mayor tamaño de lote será más rápido el proceso de entrenamiento de salida en la red neuronal para lo cual se ha optado un lote de 16 y una época de 150, asimismo definimos la ruta del archivo yaml configurado, los pesos que transforman los datos de ingreso a las capas ocultas de la red neuronal convolucional, la versión de YOLOv5 en su clase de tipo yolov5x el cual permitirá de forma eficiente el proceso de entrenamiento de las redes neuronales, tal como se visualiza en las imágenes del Anex

```

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

train: weights=yolov5x.pt, cfg=/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: Python-3.7.13 torch-1.11.0+cu113 CUDA:0 (Tesla T4, 15110MiB)

hyperparameters: lr=0.01, lrf=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 https://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% 160M/160M [00:26<00:00, 6.64MB/s]

Overriding model.yaml nc=80 with nc=2

      from  n  params module                    arguments
  0      -1  1    8000  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  4699840  models.common.SPPF          [1280, 1280, 5]
 10      -1  1  828480  models.common.Conv          [1280, 640, 1, 1]
 11      -1  1  0         torch.nn.modules.upsampling.Upsample [None, 2, 'nearest']
 12      [-1, 0] 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  47193  models.yolo.Detect          [2, [[10, 13, 16, 30, 33, 23], [30, 61, 62, 45, 59, 119], [116, 90, 156, 198, 373,
Model summary: 567 layers, 86224543 parameters, 86224543 gradients, 204.6 GFLOPs

```

```

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

YOLOv5: Python-3.7.13 torch-1.11.0+cu113 CUDA:0 (Tesla T4, 15110MiB)
YOLOv5: version 6.1.12 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, 2260.0oci
train: New cache created: /content/dataset_clasificadorGH/labels/train.cache
train: Caching images (0.1GB ram): 100% 201/201 [00:10<00:00, 15.40157/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, 1204.781t/s]
val: New cache created: /content/dataset_clasificadorGH/labels/val.cache
val: Caching images (0.1GB ram): 100% 100/100 [00:05<00:00, 17.151t/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  0.03227  0.02923  44      640: 100% 13/13 [00:17<00:00, 1.37s/it]
Class   Images  Labels  P      R      mAP@0.5  mAP@0.5:95  100% 4/4 [00:02<00:00, 1.991t/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@0.5  mAP@0.5:95  100% 4/4 [00:01<00:00, 2.181t/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@0.5  mAP@0.5:95  100% 4/4 [00:01<00:00, 2.321t/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]

```

Figura 21 Proceso de entrenamiento

4.1.5. Análisis de las métricas del entrenamiento.

De la ejecución del numeral 4.1.4, se obtuvo las métricas como resultado del entrenamiento donde se aprecia a detalle sobre los indicadores como precisión, el

recall o sensibilidad, así como el F1 equivalente a la puntuación, tal como se visualiza en las siguientes imágenes.




Figura 22. Métricas de la precisión, recall, mAP (Sun et al., 2021)

En la figura se muestra una fila del resultado de las métricas donde se visualiza la gráfica de la mAP en el cual representa la medición del efecto de los enfoques que están etiquetados en píxeles ocurrido en el rendimiento, esta es una de las formas de segmentación semántica más utilizada para conseguir la precisión media de la media representada por las iniciales (mAP). Bajo este concepto en la primera gráfica de la sección de las métricas encontramos el margen de la media al 0.5, mientras que en la segunda imagen se aprecia la gráfica estadística del margen del 0.5 al 0.95, así como la precisión y el recall que se encarga en recuperar la información. Asimismo, en la segunda fila se aprecia las gráficas de la pérdida ocurrida durante el proceso de optimización.

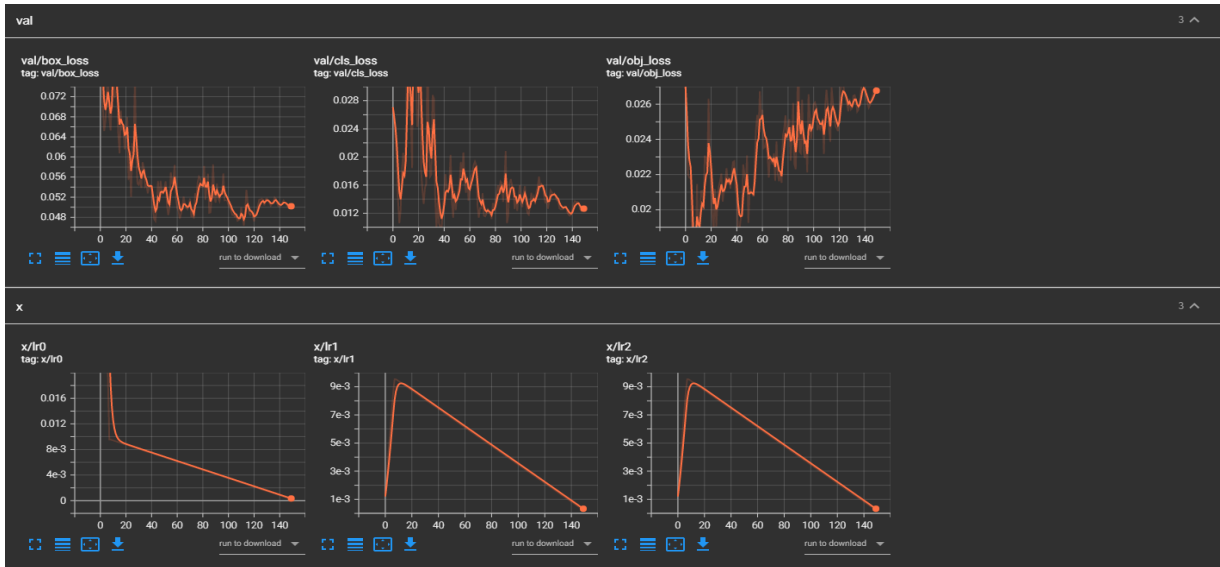


Figura 23. Métricas de la validación, así como el registro de salidas.

Las imágenes que se agrupa dentro de la fila de validaciones (val) muestran los resultados obtenidos durante el entrenamiento, así como la fila de la variable “x” el cual representa el sesgo y peso que da la red neuronal dentro de la cantidad de épocas asignada a 150.




Figura 24. Curva del puntaje (F1) durante la confianza en el entrenamiento de 149 épocas.




Figura 25. Precisión durante la recuperación de información en la curva de ROC.




Figura 26. Precisión y confianza




Figura 27. Recuperación de información durante la confianza.




Figura 28. Matriz de confusión

La matriz que se aprecia en la imagen anterior representa un conjunto de información en porcentajes de aciertos donde contempla ciertas características y criterio de calificación, el cual está dividida mediante un punto de corte esto permitió dar respuesta a la preguntas formuladas en la hipótesis en el cual se plantearon las siguientes preguntas ¿Deep Learning permite detectar fallas en pavimentos de una zona del distrito de Villa María del Triunfo en el 2022?, así como permitió detectar grietas y huecos con una alta precisión de resultados positivos aplicando técnicas del *Deep Learning* bajo las arquitecturas de Redes Neuronales Convolucionales.

En ese sentido la funcionalidad de la matriz de confusiones tuvo un rol fundamental en el desarrollo del presente trabajo de investigación toda vez que los argumentos denominados negativos y positivos que conllevan a la unión con operadores lógicos, estos se parametrizan en valores de 0 y 1 que serán usadas por los Log-loss o pérdida logarítmica que ocurre durante la clasificación, asimismo este indicador si su valor en la etiqueta es 0 representa la confianza mientras que si el valor es 1 con aproximación de una probabilidad del 0.51 corresponde a una clasificación sin embargo el margen de error se encuentra en el punto de corte del 0.5.




Figura 29. Resumen del resultado de las métricas ocurridas durante el entrenamiento de las imágenes.

En la figura anterior se visualiza dos filas de registros en la primera los gráficos estadísticos del entrenamiento (box_loss, obj_loss, cls_loss), así como las métricas de la precisión y el recall, donde:

- Box_loss.- Representa la pérdida de la regresión del error cuadrático medio
- Obj_loss.- Representa la confianza de la presencia de objetos.
- Cls_loss.- Representa la pérdida de la clasificación.
- Precisión. - Mide las predicciones de box son correctas, es decir los VP / VP + FP.
- Recall .- Mide cuántos verdaderos hay en box_loss, de los cuales se predijeron correctamente es decir VP / VP + FN, esto representa a un valor del mAP_0.5 que viene a ser la precisión promedio (mAP) en el umbral de la intersección de 0.5 hasta 0.95 que viene a ser el promedio sobre diferentes umbrales que existan.




Figura 30. Registro de resultados obtenidos durante el entrenamiento de la dataset_clasificacionGH , asimismo vemos la precisión en la detección de grietas y huecos clasificadas en indicadores 0 y 1.

En la figura anterior del conjunto de imágenes o matriz, se muestra 60 marcos con valores de 0 y 1, donde el 36.67% identifica huecos y 63.33% identifico grietas, en pavimentos de asfaltados y concreto.




Figura 31. Resultado de las redes neuronales convolucionales aplicadas para detectar grietas y huecos sobre estructuras viales en pavimentos como asfaltado o concreto.

Asimismo, los indicadores registrados muestran puntos entre 0.3 a 0.9, donde existe puntos superiores a 0.5 que representa el 50% del margen de error.




Figura 32. Imagen con recuadros de identificación de grietas y huecos sobre pavimento de asfaltado.

```

[x] [ ] !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
  
```

Figura 33. Imagen con recuadros de identificación de grietas y huecos sobre pavimento de asfaltado.

4.2. Análisis inferencial

4.2.1. Análisis del resultado de validación de imágenes.

Para ello, se ejecutó un test sobre una porción de 30 imágenes del dataset_clasificacionGH a fin de evaluar el rendimiento del nivel de confianza y analizar las métricas obtenidas.

Tabla 3. Resumen de procesamiento en la detección de clases.

Clases detectados						
	Válido		Perdidos		Total	
	N	Porcentaje	N	Porcentaje	N	Porcentaje
Clases	724	100,0%	0	0,0%	724	100,0%

Fuente. Elaboración propia

Donde:

N = Representa al total de iteraciones de imágenes puestas en el test, para obtener la validación, así como las clases pérdidas durante el proceso.

Clases = Represente el número de clases (grietas y huecos) detectados durante la iteración de N.

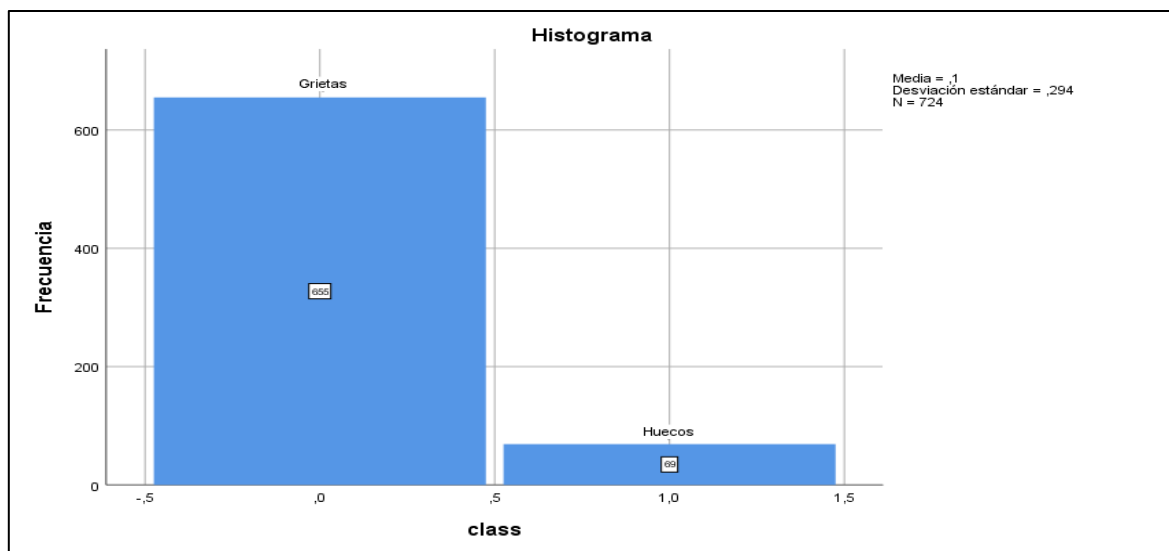


Figura 34. Histograma de la detección de tipos de clases (grietas y hueco) en 30 imágenes, donde

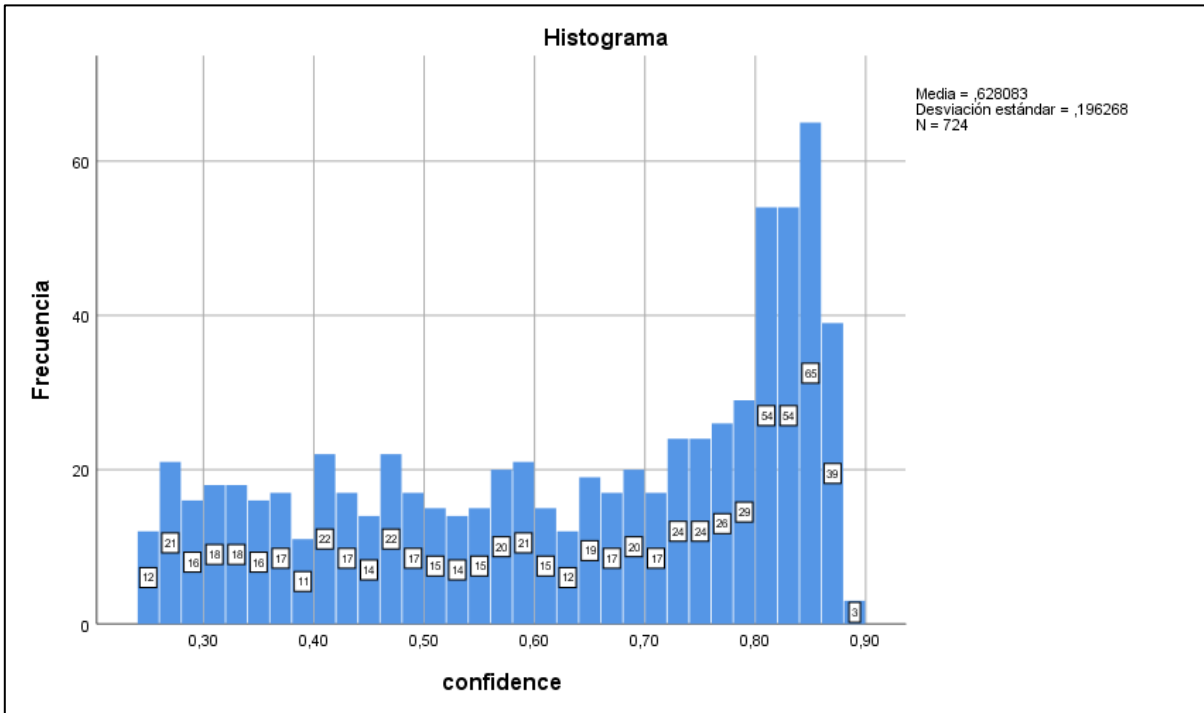


Figura 35. Histograma sobre la confianza obtenida de la validación de 30 imágenes, donde la media supera el 50% siendo el indicador de 0.62, mientras que la desviación alcanza a 0.19 en un total de 724 iteraciones.

Tabla 4. Resumen del resultado de las métricas.

Tipo métrica	Resultado
Accuracy	0.867
ROC AUC Macro Promedio	0.943
ROC AUC Micro Promedio	0.946
F1-Score Macro Promedio	0.881
F1-Score Micro Promedio	0.867
ROC AUC Grieta	0.920
ROC AUC Hueco	0.910
Promedio Precisión Grieta	0.933
Promedio Precisión Hueco	0.775
F1-Score Grieta	0.867
F1-Score Hueco	0.778

Fuente: Elaboración propia

Del análisis del resultado del test realizado se obtuvo las métricas correspondientes como el promedio de la precisión de grietas en un 0.93% y un 0.77% para huecos, mientras que la sensibilidad en grietas alcanza a 0.92% y el 0.91% en huecos, por último, tenemos el puntaje obtenido para grietas que alcanza a 0.86% y en huecos alcanza el 0.77%

4.2.2. Matriz de confusión del test

La matriz de confusión aplicado en la técnica del aprendizaje profundo nos permitirá visualizar de forma gráfica sobre el rendimiento del algoritmo YOLOv5, el cual estará dividida en filas y columnas donde cada columna de la matriz representa el número de predicciones de cada clase y en lo que corresponde a las filas estas representaran las instancias de cada clase el cual no permitirá mostrar los tipos de aciertos que este se genere en el proceso del modelo.

Bajo ese concepto el número de muestras que se aplicaron para el test fueron 30 imágenes, conformado de la siguiente manera.

- **VP (Verdaderos positivos)**, pavimento con hueco-grieta mientras que el modelo lo clasifica como esos términos dando un signo de (+).
- **VN (Verdaderos negativos)**, pavimento que no tiene grieta-hueco, mientras que el modelo lo clasifico como si estos tuvieran fallas dando el signo de (-)
- **FN (Falsos negativos)**, pavimento con hueco-grieta mientras que el modelo lo clasifica con fallas sobre los pavimentos dando un signo de (-), el cual sería un error por el signo aritmético.
- **FP (Falsos positivos)**, pavimento que no tiene grieta-hueco, mientras que el modelo lo clasifico como si estos tuvieran fallas dando el signo de (+), el cual sería un error en el cálculo.

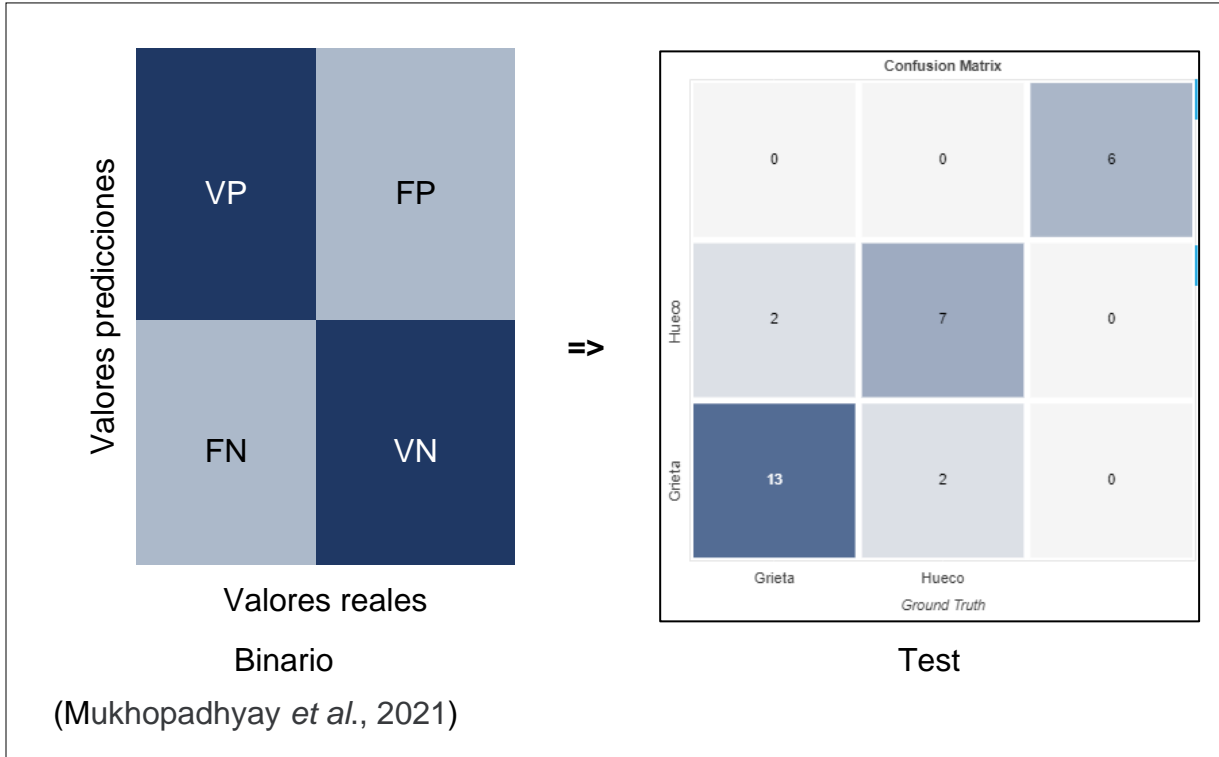


Figura 36. Matriz de confusión

4.2.3. Cuadro de ROC por indicador y el total

Dentro de este punto se detalla sobre los indicadores de la sensibilidad gracias a la curva de ROC, asimismo se encuentra la intervención de la precisión que es fundamental para predecir si existe fallas como hueco o grieta o ambos en una estructura de pavimento, bajo ese concepto esta figura proporciona las técnicas para discriminar así como para evaluar los posibles umbrales de decisión, donde los pares representan las sensibilidad y especificidad para el rango del eje “Y”, siendo la formula:

$$Precisión = \frac{VP}{VP + FN}$$

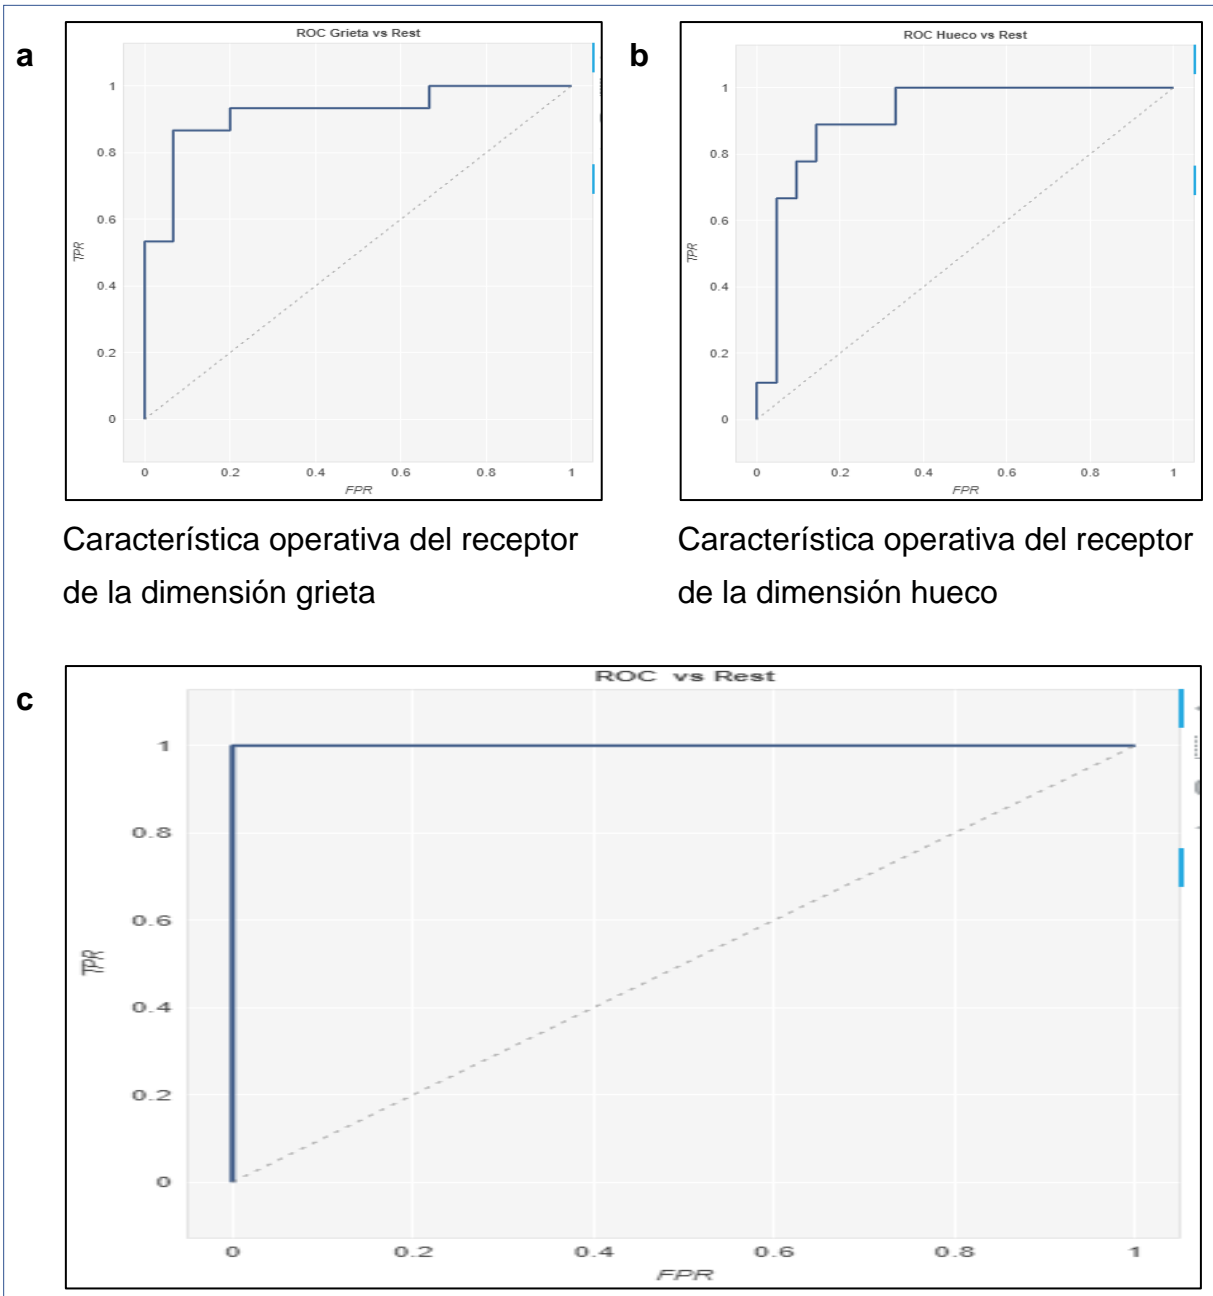


Figura 37. Característica Operativa del Recepto (ROC) general de las dimensiones grietas y huecos.

Donde:

- a) Represente la curva de ROC de la dimensión de la grieta siendo sus valores predictoriales (TPR) que está compuesto por verdadero positivo con un indicador

que se encuentra en su pico más alto de la última curva alcanzando a 0.8, mientras que en el eje de la “X” sus valores reales (FPR) representan los falsos positivos alcanzando a un indicado del 0.7.

- b) En la gráfica se aprecia los valores obtenidos de la predicción (TPR) alcanzando a 0.7 mientras que en el eje “X” alcanza a un indicador del 0.3 aproximadamente.
- c) Se visualiza el ROC general entre ambas dimensiones el cual alcanza a un indicador del 1 como punto máximo el cual garantiza la precisión del resultado del test.

4.2.4. Indicador: Precisión

Se realizó la prueba sobre el indicador el mismo donde se analizó los indicadores correspondientes de la curva de ROC de las grietas y huecos.

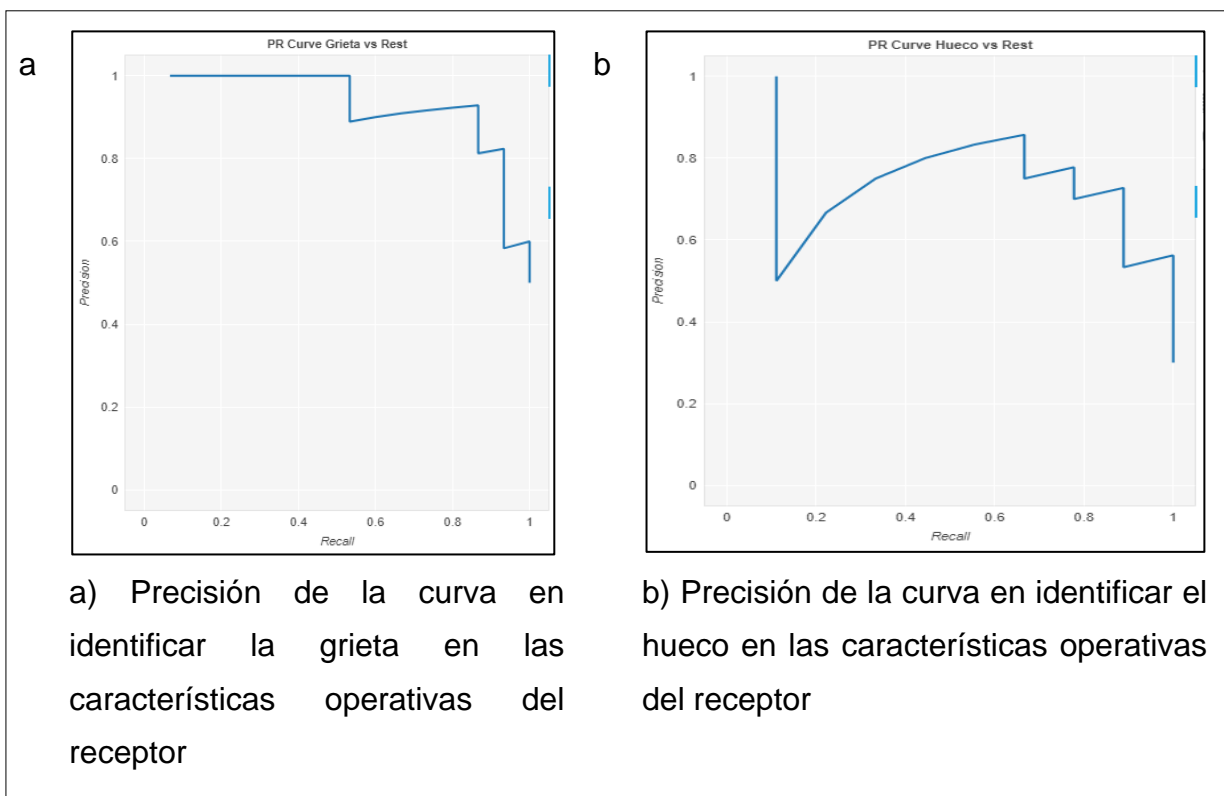


Figura 38. Curva de ROC de las dimensiones de grieta y hueco.

Como se ha descrito en el numeral 4.2.3, la precisión alcanza a indicadores que superan el 50% tal es así que se encuentra dentro del rango del nivel de confianza que es su pico más alto 0.95.

4.2.5. Indicador: Recall

En la métrica del recall nos referimos a la capacidad que tendrá el muestreo para discriminar los casos detectados como positivos de los negativos, también conocido como la tasa de los verdaderos positivos, siendo la siguiente formula:

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

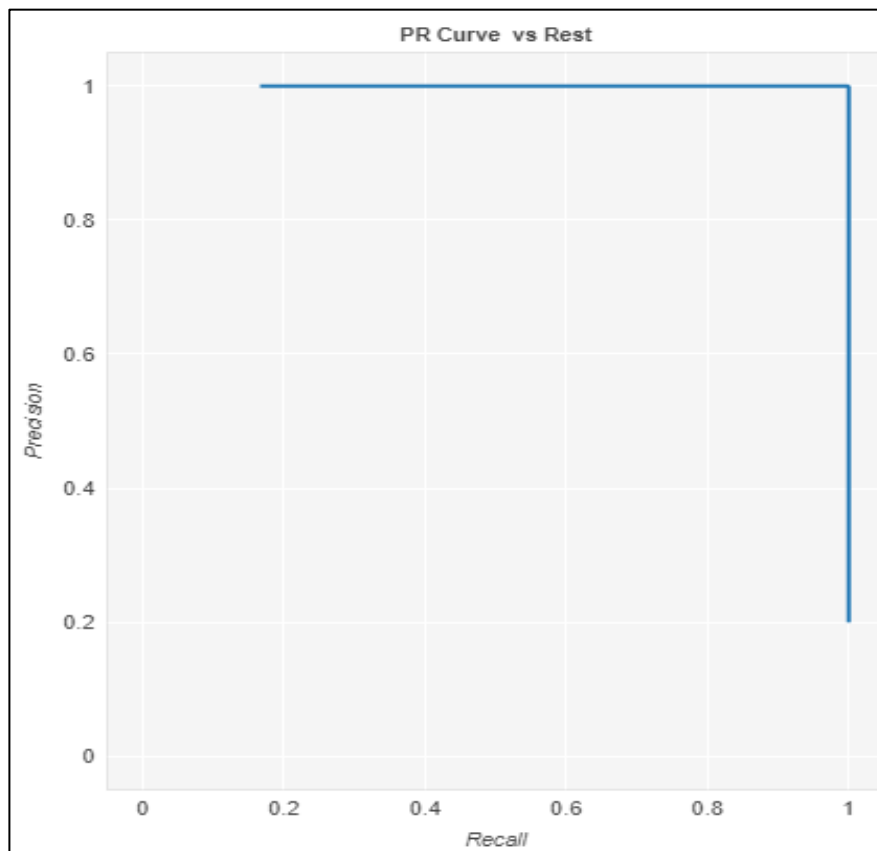


Figura 39. Precisión de la curva del ROC bajo la sensibilidad o recall.

En la figura se aprecia que los indicadores se encuentran enlazados bajo el número 1, el cual representa un porcentaje considerable apto para su sensibilidad.

4.2.6. Indicador: F1

Para calcular el indicador del valor puntaje se obtiene a través de la siguiente formula:

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

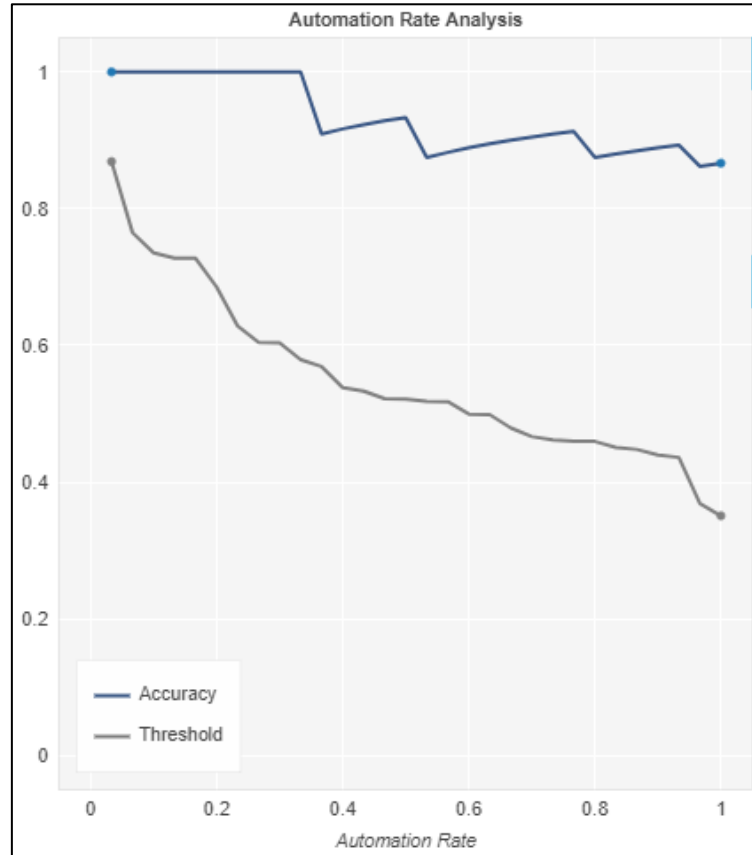


Figura 40. Indicador del Accuracy

Registro del análisis de la tasa de automatización sobre el comportamiento del puntaje obtenido, como se visualiza en la gráfica se aprecia la línea de color azul donde al puntaje alcanza entre el intervalo del $[0.8 \geq 1]$, el cual resultado favorable para la detección de las dimensiones de grietas y huecos durante el testeo de imágenes capturadas a través de teléfono inteligente.

4.2.7. Registro de imágenes del testeo




Figura 41. Matriz de imágenes capturas, donde se evidencia las dimensiones de grietas y huecos sobre los pavimentos de asfaltado y concreto.

4.3. Desarrollo del aplicativo

4.3.1. Diseño

Obtenida el nuevo modelo de la dataset listo para implementar en el sistema inteligente se procedió a concluir con el desarrollo y diseño del aplicativo bajo el lenguaje de programación de Python donde se usaron una serie de librerías detallados en el marco teórico del presente trabajo de investigación a fin de codificar las características así como las funciones para el uso del sistema, aplicando técnicas y metodologías bajo ese contexto para mayor detalle se muestra las imágenes en la sección de anexos del 17-34.

En consecuencia, mediante las fórmulas establecidas en los indicadores se obtuvieron las dimensiones establecidas en la matriz de operacionalización, siendo los resultados en la detección de grietas y huecos sobre estructuras viales como concreto y asfaltado halladas en la zona de estudio.

V. DISCUSIÓN

Los resultados obtenidos fueron óptimos en la detección de grietas y huecos sobre pavimentos en estructuras viales como asfaltado o concreto de la zona de estudio, principalmente en áreas dañadas, para ello se realizó una serie de procesos aplicando técnicas del aprendizaje profundo y herramientas tecnológicas, asimismo podemos apreciar que algunos métodos tienden a investigar la detección de las grietas mediante la captura de imágenes estáticas siendo los resultados que obtuvo Fan et al. (2020), donde la precisión alcanza entre 0.19 al 0.92, en el recall alcanza de 0.67 a 0.93 mientras que en el F1 alcanza de 0.28 a 0.92 en imágenes de con resoluciones de 768x512 y 991x462 y 311x462 pixeles. Mientras que los indicadores obtenidos en la tesis alcanzan dentro del rango de la confiabilidad que alcanzan a indicadores entre el 0.32 a 0.85 con imágenes de resolución de 1920x1080 pixeles.

En el trabajo planteado por Fan *et al.*, utilizó la técnica de preparación de data set que consistió en la limpieza de las imágenes que contenían características de grietas y huecos entre otros tipos de fallas que se puedan presentar sobre las superficies de estructuras viales aplicando técnicas de automatización con operaciones convolucionales basados en el tratamiento de información de los pixeles que obran en las imágenes los cuales son esenciales para el aprendizaje profundo, esta forma de trabajo tiene similitudes en las técnicas aplicadas para la detección de grietas y huecos sobre las estructuras viales (Opara et al. 2020), técnicas que fueron aplicadas en el desarrollo de la presente tesis.

Se determino mediante el aprendizaje profundo la detección de grietas y huecos con técnicas aplicadas para la recolección de datos a través de la captura de imagen desde un teléfono inteligente que fue implementada por Maeda et al., (2018) donde obtuvo resultados positivos en la detección de grietas y huecos sobre estas vías de tránsito, los cuales fueron aplicados en la presente investigación el cual se obtuvo los objetivos trazados.

VI. CONCLUSIONES

Se logró con el objetivo de la tesis en detectar grietas y huecos sobre estructuras de pavimentos viales que estén compuestos por cemento o asfaltado a través de técnicas del aprendizaje profundo en las principales calles de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo, asimismo se determinó mediante un sistema desarrollado bajo las arquitecturas de la redes neuronales mostrar fallas que obren sobre las estructuras viales, gracias a las capturas de imágenes recogidas a través del teléfono inteligente los cuales fueron analizados bajo una metodología sistémica sobre la existencia de grietas y huecos.

Asimismo, el cálculo de la sensibilidad y la determinación del puntaje de huecos se determinó mediante las técnicas del aprendizaje profundo basado en un modelo e implementado en un sistema inteligente que tiene la capacidad de detecta la precisión mediante el uso de la cámara. Asimismo, en lo que corresponde al segundo indicador sobre la precisión de grietas, así como la sensibilidad y puntaje se determinó a través de las fórmulas aplicadas en el aprendizaje profundo, el mismo que se visualiza en el capítulo de resultados.

También, el presente estudio utilizó el algoritmo de YOLOv5 siendo una de las técnicas más optimizadas que se aplica para detectar grietas y huecos en pavimentos, además se aplicó el modelo adquirido del entrenamiento de las redes neuronales siendo los resultados con puntajes altos en la precisión, el cual puede ser aplicado para casos futuros para analizar los distintos tipos de grietas que puedan existir de la captura de imagen o a través de la visión en video.

VII. RECOMENDACIONES

Finalizada la elaboración de la presente tesis se recomienda hacer uso de herramientas tecnológicas basadas en inteligencia artificial toda vez que permiten realizar una serie de actividades bajo la visión computacional como predecir, detectar, identificar, clasificar analizar información en grandes cantidades y en poco tiempo gracias a las técnicas del aprendizaje profundo que permiten identificar una serie de objetos los cuales son implementados en diversos proyectos para optimizar procesos, dar soluciones a los problemas que se presenta en la sociedad.

Se recomienda utilizar arquitecturas de redes neuronales convolucionales para determinar características de los objetos y clases que sean tomado en el estudio bajo algoritmos altamente sofisticados y precisos en detectar objetos o múltiples objetos como YOLOv5 siendo una de sus características principales la velocidad de procesamiento de información en corto tiempo, así como se pueden aplicar múltiples capas.

Asimismo, se recomienda realizar un adecuado tratamiento de datos de la recolección de imágenes que pueden ser capturadas a través de diferentes herramientas como cámara fotográfica, teléfonos inteligentes, dispositivos de vuelo que tengan la capacidad de realizar capturas de imágenes con resoluciones altamente nítidas y esenciales para los procesos del aprendizaje profundo y estas puedan ser implementadas con otras tecnologías de alto nivel, el cual hace más robusto a los proyectos que se desarrollen en el ámbito tecnológico.

REFERENCIAS

- ADEL, R., HARB, H. and ELSHENAWY, A., 2022. A Risk Management Framework for Large Scale Scrum using Metadata Outer Request Management Methodology. *International Journal of Advanced Computer Science and Applications* [en línea], vol. 13, no. 3, pp. 99–109. DOI 10.14569/IJACSA.2022.0130315. Disponible en: www.ijacsa.thesai.org.
- AIZAM, N., YUSOF, M., KHUSAIRI OSMAN, M., AHMAD, F., IDRIS, M., IBRAHIM, A., TAHIR, N. and YUSOF, N.M., 2021. CrackLabel: A Thresholding-Based Crack Labeling Tool for Asphalt Pavement Images. *Civil Engineering and Architecture* [en línea], vol. 9, no. 5A, pp. 58–67. DOI 10.13189/cea.2021.091307. Disponible en: <http://www.hrpub.org>.
- ARELLANO, S., 2020. Estas son las entidades con peores calles y avenidas. *Mexico Social* [en línea]. [Consulta: 9 septiembre 2021]. Disponible en: <https://www.mexicosocial.org/las-entidades-con-peores-calles-y-avenidas/>.
- ARIAS ODÓN, F.G., 2012. *El Proyecto de Investigación 6a Edición*. Caracas - República Bolivariana de Venezuela: EDITORIAL EPISTEME, C.A.
- AZIMJONOVA, J. y ÖZMEN, A., A real-time vehicle detection and a novel vehicle tracking systems for estimating and monitoring traffic flow on highways. [en línea], 2021. vol. 50, pp. 101393. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1474034621001452>.
- ABELIUK, A. y GUTIÉRREZ, C., Historia y evolución de la inteligencia artificial. [en línea], 2021. vol. 21, pp. 14–21. Disponible en: https://scholar.google.com/scholar?hl=es&as_sdt=0%2C5&q=Historia+y+evolu+ci%C3%B3n+de+la+inteligencia+artificial&btnG=.

- ALMEIDA, T.; SANTOS, V.; MOZOS, O.M. y LOURENÇO, B., Comparative Analysis of Deep Neural Networks for the Detection and Decoding of Data Matrix Landmarks in Cluttered Indoor Environments. *Journal of Intelligent & Robotic Systems* 2021 103:1 [en línea], 2021. vol. 103, no. 1, pp. 1–14. Disponible en: <https://link.springer.com/article/10.1007/s10846-021-01442-x>.
- ARBAOUI, A., OUAHABI, A., JACQUES, S. y HAMIANE, M., Concrete Cracks Detection and Monitoring Using Deep Learning-Based Multiresolution Analysis. *Electronics* 2021, Vol. 10, Page 1772 [en línea], 2021. vol. 10, no. 15, pp. 1772. Disponible en: <https://www.mdpi.com/2079-9292/10/15/1772/htm>.
- BALI, E., CAGLAR, O. y BIYANI, G., 2010. Cursos en línea. *UDEMY* [en línea]. [Consulta: 24 noviembre 2021]. Disponible en: <https://www.udemy.com/>.
- BOUGUEZZI, S.; FREDJ, H.B.; BELABED, T.; VALDERRAMA, C.; FAIEDH, H. y SOUANI, C., An Efficient FPGA-Based Convolutional Neural Network for Classification: *Ad-MobileNet*. [en línea], 2021. vol. 10, no. 18, pp. 2272. Disponible en: <https://www.mdpi.com/2079-9292/10/18/2272>.
- BIENVENIDO, MARÍN, D.; SÁNCHEZ, D.; FERNÁNDEZ, D. y MOYANO, J., Prediction of the maintenance performance cost in dwellings and building sites located in Spain using multilayer perceptrons. *Dyna (Spain)* [en línea], 2019. vol. 94, no. 5, pp. 530–538. Disponible en: <http://dx.doi.org/10.6036/9061>.
- CASS, S., 2021. Top Programming Languages: Our Eighth Annual Probe into What's Hot and Not. *IEEE Spectrum* [en línea], vol. 58, no. 10, pp. 17. DOI 10.1109/MSPEC.2021.9563957. Disponible en: <https://ieeexplore.ieee.org/document/9563957/keywords#keywords>.
- COLUCCIA, A.; FASCISTA, A.; SCHUMANN, A.; SOMMER, L.; DIMOU, A.; ZARPALAS, D.; MÉNDEZ, M.; IGLESIA, D. de la, GONZÁLEZ, I.; MERCIER, J.-P.; GAGNÉ, G.; MITRA, A. y RAJASHEKAR, S., Drone vs. Bird Detection:

Deep Learning Algorithms and Results from a Grand Challenge. *Sensors* 2021, Vol. 21, Page 2824 [en línea], 2021. vol. 21, no. 8, pp. 2824. Disponible en: <https://www.mdpi.com/1424-8220/21/8/2824>.

CHENG, Y.-T.; PATEL, A.; WEN, C.; BULLOCK, D. y HABIB, A., Intensity Thresholding and Deep Learning Based Lane Marking Extraction and Lane Width Estimation from Mobile Light Detection and Ranging (LiDAR) Point Clouds. *Remote Sensing* 2020 [en línea], 2020. vol. 12, no. 9, pp. 1379. Disponible en: <https://www.mdpi.com/2072-4292/12/9/1379>.

CHAUVET, P. y ALBERTONE, B., *Facilitación del Transporte y el Comercio en América Latina y el Caribe*. S.I.: Boletín FAL. 2018. Disponible en: https://repositorio.cepal.org/bitstream/handle/11362/44440/1/S1801184_es.pdf

CHAGAS, E.T.D.O., Deep learning y sus aplicaciones hoy. *Revista Científica Multidisciplinar Núcleo do Conhecimento* [en línea], 2019. vol. 4, no. 2448–0959, pp. 05–26. Disponible en: <https://www.nucleodoconhecimento.com.br/administracion-de-empresas/deep-learning-3>.

DANGERMOND, J., 1969. Esri. Esri.com [en línea]. [Consulta: 15 October 2021]. Disponible en: <https://www.esri.com/en-us/home>.

DE RYCK, T.; LANTHALER, S. y MISHRA, S., On the approximation of functions by tanh neural networks. *Neural Networks* [en línea], 2021. vol. 143, pp. 732–750. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0893608021003208?via%3Dihub>.

DE SALUD, M. y DEL TRIUNFO, M. de V.M., ANÁLISIS DE SITUACIÓN DE SALUD DEL DISTRITO VILLA MARÍA DEL TRIUNFO. [en línea]. S.I.: 2019. Disponible en: <https://www.dge.gob.pe/portal/docs/asis-lima->

2019/CD_MINSA/DOCUMENTOS_ASIS/ASIS_DISTRITO%20VILLA%20MARI
A%20EL%20TRIUNFO%202019.pdf.

ENZO, R.A.; CASSANDRA, C.R.; FELIPE, A.N. y PABLO, M.Q., *Artificial Intelligence: Development of classification and segmentation algorithms in chest radiography* [en línea]. S.l.: Revista chilena de radiología. 2021. Disponible en: <http://dx.doi.org/10.4067/S0717-93082021000100008>.

ERECH, O.R., *DEEP LEARNING PARA LA VISIÓN ARTIFICIAL E IDENTIFICACIÓN DEL PERSONAL ADMINISTRATIVO Y DOCENTE DE LA UNIVERSIDAD NACIONAL MICAELA BASTIDAS DE APURÍMAC 2018* [en línea]. 2020. PUNO: UNIVERSIDAD NACIONAL DEL ALTIPLANO. Disponible en: <http://repositorio.unap.edu.pe/handle/UNAP/13523>.

ESLAMI, E. y YUN, H.B., 2021. Attention-Based Multi-Scale Convolutional Neural Network (A+MCNN) for Multi-Class Classification in Road Images. *Sensors 2021, Vol. 21, Page 5137* [en línea], vol. 21, no. 15, pp. 5137. DOI 10.3390/S21155137. Disponible en: <https://www.mdpi.com/1424-8220/21/15/5137>.

FAN, Z.; LI, C.; CHEN, Y.; WEI, J.; LOPRENCIPE, G.; CHEN, X. y MASCIO, P.D., Automatic Crack Detection on Road Pavements Using Encoder-Decoder Architecture. *Materials 2020, Vol. 13, Page 2960* [en línea], 2020. vol. 13, no. 13, pp. 2960. Disponible en: <https://www.mdpi.com/1996-1944/13/13/2960>.

FAN, Z., LI, C., CHEN, Y., DI MASCIO, P., CHEN, X., ZHU, G. and LOPRENCIPE, G., 2020. Ensemble of deep convolutional neural networks for automatic pavement crack detection and measurement. *Coatings* [en línea], vol. 10, no. 2, pp. 14. DOI 10.3390/COATINGS10020152. Disponible en: <http://dx.doi.org/10.3390/COATINGS10020152>.

FU, H.; MENG, D.; LI, W. y WANG, Y., Bridge Crack Semantic Segmentation Based on Improved Deeplabv3+. *Journal of Marine Science and Engineering 2021*,

Vol. 9, Page 671 [en línea], 2021. vol. 9, no. 6, pp. 671. Disponible en:
<https://www.mdpi.com/2077-1312/9/6/671>.

FERREIRA, C., PALMEIRA, A., SOUSA, E., AMORIM, C.G., ARAÚJO, A.N. and MONTENEGRO, M.C., 2021. Supramolecular Atropine Potentiometric Sensor. *Sensors* 2021, Vol. 21, Page 5879 [en línea], vol. 21, no. 17, pp. 5879. DOI 10.3390/S21175879. Disponible en: <http://dx.doi.org/10.3390/S21175879>.

FLINT, C., 1911. IBM SPSS Statistics. www.ibm.com [en línea]. [Consulta: 15 March 2022]. Disponible en: <https://www.ibm.com/pe-es/products/spss-statistics>.

GESCHKE, C. and WARNOCK, J., 1982. Adobe Creative Cloud. [Adobe.com](http://adobe.com) [en línea]. [Consulta: 20 September 2021]. Disponible en: <https://www.adobe.com/la/>.

HERNÁNDEZ, R.; FERNÁNDEZ, C.; BATISTA, P. Metodología de la investigación sexta edición (sexta edición). 2014. Disponible en: <https://www.esup.edu.pe/wp-content/uploads/2020/12/2.%20Hernandez,%20Fernandez%20y%20Baptista-Metodolog%C3%ADa%20Investigacion%20Cientifica%206ta%20ed.pdf>

INSTITUTO NACIONAL DE ESTADÍSTICA E INFORMÁTICA, Resultados Definitivos de los Censos Nacionales 2017 Provincia de Lima. [en línea]. S.I.: 2017. Disponible en: https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitaless/Est/Lib1583/.

INSTITUTO NACIONAL DE ESTADÍSTICA E INFORMÁTICA, 2022. Indicador de la Actividad Productiva Departamental - Cuarto Trimestre 2021. [en línea]. S.I.: Disponible en: <https://m.inei.gob.pe/biblioteca-virtual/boletines/produccion-nacional-departamental-9836/1/#lista>.

- INSTITUTO NACIONAL DE ESTADÍSTICA E INFORMÁTICA, 2020. Planos Estratificados del Lima Metropolitana a Nivel de Manzanas 2020. [en línea]. S.l.: Disponible en: https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib1744/libro.pdf.
- JAAFARI, J.; DOUZI, S.; DOUZI, K. y HSSINA, B., Towards more efficient CNN-based surgical tools classification using transfer learning. *Journal of Big Data* 2021 8:1 [en línea], 2021. vol. 8, no. 1, pp. 1–15. Disponible en: <http://dx.doi.org/10.1186/S40537-021-00509-8>.
- JANSEN, P., 2000. TIOBE - The Software Quality Company. tiobe.com [en línea]. [Consulta: 9 October 2021]. Disponible en: <https://www.tiobe.com/tiobe-index/>
- KUMAR, P.; BATCHU, S.; SWAMY S., N. y KOTA, S.R., Real-time concrete damage detection using deep learning for high rise structures. *IEEE Access* [en línea], 2021. vol. 9, pp. 112312–112331. Disponible en: <http://dx.doi.org/10.1109/ACCESS.2021.3102647>.
- KIENBAUM, L.; CORREA ABONDANO, M.; BLAS, R. y SCHMID, K., DeepCob: precise and high-throughput analysis of maize cob geometry using deep learning with an application in genebank phenomics. *Plant Methods* 2021 17:1 [en línea], 2021. vol. 17, no. 1, pp. 1–19. Disponible en: <https://plantmethods.biomedcentral.com/articles/10.1186/s13007-021-00787-6>.
- LEE, J., KIM, H.S., KIM, N., RYU, E.M. and KANG, J.W., 2019. Learning to detect cracks on damaged concrete surfaces using two-branched convolutional neural network. *Sensors (Switzerland)* [en línea], vol. 19, no. 21. DOI 10.3390/S19214796. Disponible en: <http://dx.doi.org/10.3390/S19214796>.
- MAEDA, H., SEKIMOTO, Y., SETO, T., KASHIYAMA, T. and OMATA, H., 2018. Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone. University of Tokyo, pp. 14.

MAXIAOHE; KANGKAIZHANG; ZHURUI SHENG; WUHONGZHI y ZHOUKUN, Free-form scanning of non-planar appearance with neural trace photography. *ACM Transactions on Graphics (TOG)* [en línea], 2021. vol. 40, no. 4. Disponible en: <https://dl.acm.org/doi/abs/10.1145/3450626.3459679>.

MORALES, T.; SARABAKHA, A. y KAYACAN, E., *Image Generation for Efficient Neural Network Training in Autonomous Drone Racing* [en línea]. S.l.: Proceedings of the International Joint Conference on Neural Networks. 2020. Disponible en: https://www.researchgate.net/publication/343499034_Image_Generation_for_Efficient_Neural_Network_Training_in_Autonomous_Drone_Racing.

MORIYOSHII, A.; SHIBATA, E.; NATSUHARA, M.; SAKAI, K.; KONDO, T. y KASAHARA, A., Deterioration of modern concrete structures and asphalt pavements by respiratory action and trace quantities of organic matter. *PLOS ONE* [en línea], 2021. vol. 16, no. 5, pp. Disponible en: <http://dx.doi.org/10.1371/JOURNAL.PONE.0249761>.

MUNICIPALIDAD DE VILLA MARIA DEL TRIUNFO, Plan Estratégico Institucional 2017-2019, Informe de Evaluación 2019, 2020. <http://munivmt.gob.pe/pdf/transparencia/documentos/PEI2017-2019-EVALUACION.pdf>

MUKHOPADHYAY, S., CENNAMO, N., DEEN, M.J., LEE, J., FABIO, T.S., CHEN, C., CHANDRA, S., HAN, Y. and SEO, H., 2021. Deep Learning-Based Thermal Image Analysis for Pavement Defect Detection and Classification Considering Complex Pavement Conditions. *Remote Sensing* 2022, Vol. 14, Page 106 [en línea], vol. 14, no. 1, pp. 106. DOI 10.3390/RS14010106. Disponible en: <https://www.mdpi.com/2072-4292/14/1/106>.

OPARA, J.N.; THEIN, A.B.B.; IZUMI, S.; YASUHARA, H. y CHUN, P.-J., Defect Detection on Asphalt Pavement By Deep Learning. *International Journal of GEOMATE* [en línea], 2021. vol. 21, no. 83, pp. 87–94. Disponible en: <http://dx.doi.org/10.21660/2021.83.6153>.

PAULY, L., PEEL, H., LUO, S., HOGG, D. and FUENTES, R., 2017. Deeper Networks for Pavement Crack Detection. 34 th International Symposium on Automation and Robotics in Construction (ISARC 2017) [en línea], pp. 479–485. DOI 10.22260/ISARC2017/0066. Disponible en: http://www.iaarc.org/publications/2017_proceedings_of_the_34rd_isarc/deeper_networks_for_pavement_crack_detection.html.

PERUANO, E., 2014. Ley N° 30220 - Ley Universitaria. [en línea]. Lima: *Diario El Peruano*. Disponible en: <https://www.gob.pe/institucion/minedu/normas-legales/118482-30220>.

PALMA, M.J.T, y MORALES, R.M., 2008. Inteligencia Artificial. Técnicas, métodos y aplicaciones. España: McGRAW-HILL/INTERAMERICANA DE ESPAÑA, S. A. U.

PROKOPENKO, T., LAVDANSKA, O., POVOLOTSKYI, Y., OBODOVSKYI, B. y TARASENKO, Y., 2021. Devising an integrated method for evaluating the efficiency of scrum-based projects in the field of information technology. *Eastern-European Journal of Enterprise Technologies* [en línea], vol. 5, no. 3 (113), pp. 46–53. Disponible en: <http://dx.doi.org/10.15587/1729-4061.2021.242744>.

QIAO, W.; LIU, Q.; WU, X.; MA, B. y LI, G., Automatic Pixel-Level Pavement Crack Recognition Using a Deep Feature Aggregation Segmentation Network with a scSE Attention Mechanism Module. *Sensors 2021, Vol. 21, Page 2902* [en línea], 2021. vol. 21, no. 9, pp. 2902. Disponible en: <https://www.mdpi.com/1424-8220/21/9/2902>.

- RAVINDRAN, P.; OWENS, F.C.; WADE, A.C.; VEGA, P.; MONTENEGRO, R.; SHMULSKY, R. y WIEDENHOEFT, A.C., Field-Deployable Computer Vision Wood Identification of Peruvian Timbers. *Frontiers in Plant Science* [en línea], 2021. vol. 0, pp. 940. Disponible en: <https://www.frontiersin.org/articles/10.3389/fpls.2021.647515/full>.
- RAMALINGAM, B., HAYAT, A.A., ELARA, M.R., GÓMEZ, B.F., YI, L., PATHMAKUMAR, T., RAYGURU, M.M. and SUBRAMANIAN, S., 2021. Deep Learning Based Pavement Inspection Using Self-Reconfigurable Robot. *Sensors* 2021, Vol. 21, Page 2595 [en línea], vol. 21, no. 8, pp. 2595. DOI 10.3390/S21082595. Disponible en: <https://www.mdpi.com/1424-8220/21/8/2595/htm>.
- SARMIENTO, J.L., Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. *Revista UIS Ingenierías* [en línea], 2020. vol. 19, no. 4, pp. 1–18. Disponible en: <http://dx.doi.org/10.18273/REVUIN.V19N4-2020001>.
- SABINO, C., 1992. *El Proceso de Investigación*. Panapo, Caracas: Ed. Panamericana, Bogotá, y Ed. Lumen, Buenos Aires.
- SHATNAWI, N., Automatic Pavement Cracks Detection using Image Processing Techniques and Neural Network. *International Journal of Advanced Computer Science and Applications* [en línea], 2018. vol. 9, no. 9, pp. 399–402. Disponible en: www.ijacsa.thesai.org.
- SHAHZAD, B., NAEEM AWAN, W., ABRO, A., SHOAIB, M., ALYAHYA, S. and AUTHOR, C., 2022. Framework for Effective Utilization of Distributed Scrum in Software Projects. *Computer Systems Science and Engineering* [en línea], vol. 44, no. 1, pp. 407. DOI 10.32604/CSSE.2023.022601. Disponible en: <https://www.techscience.com/csse/v44n1/48025>.
- SHIM, S.; KIM, J.; CHO, G.C. y LEE, S.W., Multiscale and adversarial learning-based semi-supervised semantic segmentation approach for crack detection in

- concrete structures. *IEEE Access* [en línea], 2020. vol. 8, pp. 170939–170950. Disponible en: <https://ieeexplore.ieee.org/document/9193940>.
- SKALSKI, P., 2022. Make Alpha Sense. *Make Alpha Sense.ai* [en línea]. [Consulta: 2 June 2022]. Disponible en: <https://www.makesense.ai/>.
- SOMMERVILLE, I., 2011. *Ingeniería de Software*, 9a edición. México: Pearson Education Inc.
- SOUKAINA, M., BADR, E., ABDELAZIZ, M. and NAWAL, S., 2021. Towards a New Metamodel Approach of Scrum, XP and Ignite Methods. *International Journal of Advanced Computer Science and Applications* [en línea], vol. 12, no. 12, pp. 192–202. DOI 10.14569/IJACSA.2021.0121225. Disponible en: www.ijacsa.thesai.org.
- SUN, Y.; YANG, Y.; YAO, G.; WEI, F. y WONG, M., Autonomous Crack and Bughole Detection for Concrete Surface Image Based on Deep Learning. *IEEE Access* [en línea], 2021. vol. 9, pp. 85709–85720. Disponible en: <http://dx.doi.org/10.1109/ACCESS.2021.3088292>.
- TORRI, G., GIACOMETTI, R. and PATERLINI, S., 2019. Sparse precision matrices for minimum variance portfolios. *Computational Management Science 2019* 16:3 [en línea], vol. 16, no. 3, pp. 375–400. DOI 10.1007/S10287-019-00344-6. Disponible en: <http://dx.doi.org/10.1007/S10287-019-00344-6>.
- TURAY, T. and VLADIMIROVA, T., 2022a. Toward Performing Image Classification and Object Detection with Convolutional Neural Networks in Autonomous Driving Systems: A Survey. *IEEE Access* [en línea], vol. 10, pp. 14076–14119. DOI 10.1109/ACCESS.2022.3147495. Disponible en: <http://dx.doi.org/10.1109/ACCESS.2022.3147495>.
- UNIVERSIDAD CÉSAR VALLEJO, 2020. Código de Ética en Investigación de la Universidad César Vallejo. *UCV* [en línea]. [Consulta: 5 octubre 2021].

Disponible en: <https://www.ucv.edu.pe/wp-content/uploads/2020/11/RCUN%C2%B00262-2020-UCV-Aprueba-Actualizaci%C3%B3n-del-C%C3%B3digo-%C3%89tica-en-Investigaci%C3%B3n-1-1.pdf>

VAN ROSSUM, G., 2001. Python. python.org [en línea]. [Consulta: 10 September 2021]. Disponible en: <https://www.python.org/>.

VIZCARRA, G.; BERMEJO, D.; MAURICIO, A.; ZARATE GOMEZ, R. y DIANDERAS, E., The Peruvian Amazon forestry dataset: A leaf image classification corpus. *Ecological Informatics* [en línea], 2021. vol. 62, pp. 101268. Disponible en: <http://dx.doi.org/10.1016/J.ECOINF.2021.101268>.

YINSHAN, L.; LINLIN, L.; TIANYU, L.; RUYONG, G. y CHUNYING, W., Study on simulation mechanics and fatigue performance of steel bridge deck rigid flexible composite pavement. *E3S Web of Conferences* [en línea], 2021. vol. 272, pp. 5. Disponible en: <http://dx.doi.org/10.1051/E3SCONF/202127202025>.

YUSOF, N.A.M.; OSMAN, M.K.; AHMAD, F.; IDRIS, M.; IBRAHIM, A.; TAHIR, N. y YUSOF, N.M., CrackLabel: A Thresholding-Based Crack Labeling Tool for Asphalt Pavement Images. *Civil Engineering and Architecture* [en línea], 2021. vol. 9, no. 5A, pp. 58–67. DOI 10.13189/CEA.2021.091307. Disponible en: <http://www.hrpub.org>.

ZHANG, M.; LIU, Y.; LUO, S. y GAO, S., Research on Baidu Street View Road Crack Information Extraction Based on Deep Learning Method. *Journal of Physics: Conference Series* [en línea], 2020. vol. 1616, no. 1, pp. 012086. Disponible en: <https://iopscience.iop.org/article/10.1088/1742-6596/1616/1/012086>.

ZHANG, L., Hand-drawn sketch recognition with a double-channel convolutional neural network. *EURASIP Journal on Advances in Signal Processing 2021 2021:1* [en línea], 2021. vol. 2021, no. 1, pp. 1–12. Disponible en: <https://asp-erasipjournals.springeropen.com/articles/10.1186/s13634-021-00752-4>.

ANEXOS

ANEXO N° 1. Matriz de Consistencia

Problema de investigación	Objetivos	Hipótesis	Variable	Dimensiones	Indicadores	Escala	Método
<p>General: ¿De qué manera Deep Learning permite la Detección de Fallas en Pavimentos de una Zona del Distrito de Villa María del Triunfo 2022?</p> <p>PE1: ¿De qué manera se medirá las grietas y huecos en las superficies de estructuras viales de las calles principales de la zona de José</p>	<p>Determinar la detección de Deep Learning para las fallas en pavimentos de las principales calles de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo.</p> <p>OE1: Determinar grietas en las superficies de estructuras de pavimentos.</p>	<p>Hipótesis General: Deep Learning permite detectar fallas en pavimentos de una zona del distrito de Villa María del Triunfo en el 2022.</p> <p>HI1: Deep Learning permite detectar huecos en las principales calles pavimentadas de una zona de José Carlos Mariátegui del distrito de Villa María del Triunfo en el 2022</p>	<p>Evaluar la variable dependiente (grietas o huecos), mediante la ejecución del aprendizaje profundo.</p>	<p>Reconocimiento de huecos en el pavimento indicadores:</p> <p>Precisión de huecos.</p>	<p>Sensibilidad de huecos y puntaje de huecos.</p> <p>Fórmula para determinar la sensibilidad de grietas</p> $\text{Recall} = \frac{TP}{TP + FN}$	<p>Cuantitativa</p>	<p>Tipo de estudio: Aplicada.</p> <p>Diseño de investigación: Pre-experimental.</p> <p>Población: Las principales calles de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo, que abarca un total de 9.14 kilómetros.</p> <p>Técnica e Instrumento: Ficha de</p>

<p>Carlos Mariátegui del distrito de Villa María del Triunfo usando el Deep Learning en el 2022?;</p> <p>PE2: ¿De qué manera se obtendrá con la detección de grietas y huecos aplicando las redes neuronales multicapas en las principales calles de la zona de José Carlos Mariátegui del distrito de Villa María del Triunfo en el 2022 ?.</p>	<p>OE2: Determinar huecos en las superficies de estructuras de los pavimentos.</p>	<p>HI2: Deep Learning permite detecta grietas en las principales calles pavimentadas de una zona de José Carlos Mariátegui del distrito de Villa María del Triunfo en el 2022.</p>		<p>Reconocimiento de grietas en el pavimento. (Eslami y Yun, 2021).</p>	<p>Opara et al. (2021)</p> <p>Precisión de grietas, sensibilidad de grietas y puntaje de grietas</p> <p>Fórmula para determinar el puntaje de grietas</p> $F1 = \frac{2(\frac{TP}{TP + FN} * \text{precisión})}{\frac{TP}{TP + FN} + \text{precisión}}$ <p>Recall= Sensibilidad de grietas</p> <p>TP = Verdadero positivo Fn = Falso negativo Precisión = Precisión</p> <p>F1 = Puntaje obtenido de la combinación de Sensibilidad y Precisión de grietas.</p> <p>Opara et al. (2021)</p>	<p>instrumento y registro.</p>
---	---	---	--	---	---	--------------------------------

ANEXO N° 2. Operacionalización de Variables

Variable	Definición Conceptual	Definición Operacional	Dimensión	Indicador	Instrumento	Escala
Independiente Sistema inteligente con Deep Learning	Según Jaafari <i>et al.</i> (2021), define que el campo del <i>Deep Learning</i> fue testigo del gran avance de la ciencia que ha sido capaz de llegar al punto de que las máquinas tengan la capacidad de poder entender y manipular datos para tomar decisiones, procesarlas e interactuar con el hombre. Bajo esa definición se considera que un sistema basado en algoritmos de redes neuronales permitirá la automatización e interoperabilidad con las personas a través del aprendizaje profundo supervisado, generativas o híbridas.	Las Redes neuronales (RNN), está formada por una capa de entrada, donde pueden existir una a más capas ocultas y una capa de salida, para el procesamiento de imágenes que permita clasificar (Bienvenido <i>et al.</i> , 2019), así como pueden asignar a las variables independientes a fin de emitir resultados, a partir de la validación y medición de sus variables, usando la arquitectura Encoder-Decoder, y el modelo DeepLabv3+ (Zhang <i>et al.</i> , 2020) para el procesamiento de las imágenes.	Algoritmos de redes neuronales, para el aprendizaje automático.	Múltiples capas		Cuantitativo

Dependiente Fallas en Pavimentos	<p>Según Opara <i>et al.</i> (2021), menciona sobre la importancia de infraestructura vial que impacta en el desarrollo económico de una población, asimismo señala que un buen mantenimiento garantiza el propósito vial, así como la seguridad en el tránsito de las personas (Qiao <i>et al.</i> 2021), no obstante, es importante monitorear constantemente su estado a través de sistemas inteligentes que estandarice su clasificación de las estructuras que se encuentren con daños, grietas o fallas</p>	<p>Según Fan <i>et al.</i> (2020), agrupa una serie de características para determinar las estructuras defectuosas, como: agrietamiento de múltiples tamaños en los hormigones de cemento o asfáltico, esto se debe a diferentes causas como el exceso de transporte de cargas pesadas, efectos climáticos, estos tipos se pueden clasificar a través de la red neuronal convolucional recurrente (Eslami y Yun, 2021).</p>	<p>Reconocimiento de huecos en el pavimento (Eslami y Yun, 2021).</p>	<p>Sensibilidad y puntaje de huecos</p> <p>Fórmula para calcular la sensibilidad de grietas</p> $\text{Recall} = \frac{TP}{TP + FN}$ <p>(Opara <i>et al.</i> (2021))</p>	<p>Ficha de registro de datos</p> <p>(Técnica: Ficha de registro)</p>	<p>Cuantitativo</p>
			<p>Reconocimiento de grietas en el pavimento (Eslami y Yun, 2021).</p>	<p>Precisión de grietas, sensibilidad y puntaje de grietas</p> <p>Fórmula para determinar el puntaje de grietas</p> $F1 = \frac{2(\frac{TP}{TP + FN} * \text{precisión})}{\frac{TP}{TP + FN} + \text{precisión}}$ <p>Recall= Sensibilidad de grietas TP = Verdadero positivo Fn = Falso negativo Precisión = Precisión F1 = Puntaje de grietas</p> <p>(Opara <i>et al.</i> (2021))</p>		<p>Cuantitativo</p>

ANEXO N° 3.
MATRIZ DE OPERACIONALIZACIÓN DE LAS VARIABLES
Variable: Fallas en pavimentos.

Variable	Definición conceptual	Definición operacional	Dimensión	Indicadores	Instrumento	Escala de Medición
Fallas en pavimentos, Según Opara et al. (2021).	Según Opara <i>et al.</i> (2021), menciona sobre la importancia de infraestructura vial que impacta en el desarrollo económico de una población, asimismo señala que un buen mantenimiento garantiza el propósito vial, así como la seguridad en el tránsito de las personas (Qiao <i>et al.</i> 2021), no obstante, es importante monitorear constantemente su estado a través de sistemas inteligentes que estandarice su clasificación de las estructuras que se encuentren con daños, grietas o fallas	Según Fan <i>et al.</i> (2020), agrupa una serie de características para determinar las estructuras defectuosas, como: agrietamiento de múltiples tamaños en los hormigones de cemento o asfáltico, esto se debe a diferentes causas como el exceso de transporte de cargas pesadas, efectos climáticos.	Reconocimiento de grietas en el pavimento (Eslami y Yun, 2021).	Calcular la precisión de grietas $\text{Precisión} = \frac{TP}{TP + FP}$	Ficha de registro de datos (Técnica: Ficha de registro)	Cuantitativa
				Determinar el puntaje de grietas $F1 = \frac{2(\frac{TP}{TP + FN} * \text{precisión})}{\frac{TP}{TP + FN} + \text{precisión}}$ Recall = Sensibilidad de grietas TP = Verdadero positivo Fn = Falso negativo Precisión = Precisión F1 = Puntaje grietas (Opara et al. (2021))		Cuantitativa

ANEXO N° 4.
CERTIFICADO DE VALIDEZ DE CONTENIDO DEL INSTRUMENTO QUE MIDE:

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	$F1 = \frac{2\left(\frac{TP}{TP + FN} * \text{precisión}\right)}{\frac{TP}{TP + FN} + \text{precisión}}$	X		X		X		

Observaciones (precisar si hay suficiencia): _____

Opinión de aplicabilidad: **Aplicable [X]** **Aplicable después de corregir []** **No aplicable []**

Apellidos y nombres del juez validador: Alarcón Cajas Yohan Roy **DNI:** 46189705

Especialidad del validador: Magíster en Ingeniería de Sistemas

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

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

28 de noviembre del 2021



Firma del Experto Informante.

ANEXO N° 5.
VALIDACIÓN DE LA METODOLOGÍA DE DESARROLLO
Apellidos y Nombres del Experto:

YOHAN ROY ALARCON CAJAS

Título y/o Grado Académico:

ING. DE SISTEMAS

Doctor () Magister (X) Ingeniero () Licenciado () Otro ()
Fecha:

28/11/2021

Título de Investigación: Deep Learning Para la Detección de Fallas en Pavimentos de una Zona del Distrito de Villa María del Triunfo 2022.

Autores:

- Zúñiga Guisado, Yenmy

MUY MAL (1) MALO (2) REGULAR (3) BUENO (4) EXCELENTE (5)

ÍTEM	PREGUNTAS	METODOLOGÍA		
		XP	Common KADS	RUP
1	¿Qué metodología es la más adecuada para este tipo de investigación?	3	5	3
2	¿Qué metodología es factible para el desarrollo de un sistema y comprensión?	4	4	4
3	¿Qué metodología de desarrollo impulsa a comentar el código para una mayor comprensión?	3	5	4
4	¿Qué metodología analiza los procesos que intervienen en la empresa?	4	4	3
5	¿Qué metodología requiere menos costo?	3	5	4
6	¿Qué metodología permite la retroalimentación?	3	4	4
7	¿Qué metodología permitirá un mejor resultado para la empresa?	3	5	3
PUNTUACIÓN				

SUGERENCIAS

FIRMA DEL EXPERTO

ANEXO N° 6: Cuadro comparativo de metodologías de desarrollo

METODOLOGÍA		
XP	SCRUM	CommonKADS
Conjunto de práctica y reglas empleadas para desarrollar software.	Conjunto de buenas prácticas para trabajar colaborativamente, en equipo, y obtener el mejor resultado posible de un proyecto. Es un ciclo completo	Conjunto de buenas prácticas que permite trabajar a través de niveles y modelos contextuales, conceptuales y de diseño.
<ul style="list-style-type: none"> -Comunicación. -Realimentación -Alta calidad mínimo de tiempo -Disminuye traza de errores -Coraje (Satisfacción de los programadores) 	<ul style="list-style-type: none"> -Conocimiento necesario para lograr un objetivo. -Involucra desde un principio y se da un rol a todos. -Entregables en tiempo y forma 	<ul style="list-style-type: none"> -Conocimiento necesario para lograr un objetivo. -Involucra la intercomunicación entre todos los procesos desde un principio -El artefacto final está compuesto por una serie de actividades sistémicas que permite un adecuado desarrollo en el proyecto.
<ul style="list-style-type: none"> -Dificultad para determinar el coto del proyecto. -Se usa principalmente en proyectos pequeños. 	<ul style="list-style-type: none"> -Los miembros del equipo se saltan pasos importantes en el camino para llegar al Sprint final. -Demasiadas reuniones para poco avance. 	<ul style="list-style-type: none"> -Los integrantes del proyecto interactúa constantemente en los diferentes niveles.
<ul style="list-style-type: none"> -Programador -Encargado de pruebas -Encargado de seguimiento -Consultor 	<ul style="list-style-type: none"> -Trabajo realizado por el equipo de especialistas. -Visible, transparente por el equipo de especialista. -Responsabilidad. 	<ul style="list-style-type: none"> -El proyecto puede ser desarrollado por un conjunto de especialistas que tengan conocimiento en el diseño, prototipado y el desarrollo de la documentación de ayuda
<ul style="list-style-type: none"> -Prueba Unitarias. Se basa en pruebas de las fallas que pudiera ocurrir. -Metodología basada en prueba y error. -Fundamentada en valores y practica 	<ul style="list-style-type: none"> -Fundamentada en principios. -Reduce el costo del cambio en todas las etapas -Equipo con formación elevada 	<ul style="list-style-type: none"> -Fundamentada en principios. -Reduce la transición del cambio en todas las etapas -Equipo con formación elevada

VALIDACIÓN DEL INSTRUMENTO DE EXPERTOS: CALCULAR LA PRECISIÓN
I. DATOS GENERALES

Apellidos y Nombres del Experto: ALARCON CAJAS, YOHAN ROY
 Título y/o Grado Académico: ING. DE SISTEMAS

Doctor () Magister (x) Ingeniero () Licenciado () Otro ().....

Universidad que labora: Universidad César Vallejo
 Fecha: 28/11/2021

Título de Investigación: Deep Learning Para la Detección de Fallas en Pavimentos de una Zona del Distrito de Villa María del Triunfo 2022.

Autores:

- Zuñiga Guisado, Yenmy

Deficiente (0-20%) Regular(21-50%) Bueno(51-70%) Muy Bueno(71-80%) Excelente(81-100%)

II. ASPECTOS DE VALIDACIÓN

INDICADOR	CRITERIO	VALORACIÓN				
		0-20%	21-50%	51-70%	71-80%	81-100%
CLARIDAD	Es formulado con lenguaje apropiado.				80%	
OBJETIVIDAD	Está expresado en conducta observable.				80%	
ACTUALIDAD	Es adecuado el avance, la ciencia y tecnología.				80%	
ORGANIZACIÓN	Existe una organización lógica.				80%	
SUFICIENCIA	Comprende los aspectos de cantidad y calidad.				80%	
INTENCIONALIDAD	Adecuado para valorar los aspectos del sistema metodológico y científico.				80%	
CONSISTENCIA	Está basado en aspectos teóricos y científicos.				80%	
COHERENCIA	En los datos respecto al indicador.				80%	
METODOLOGÍA	Responde al propósito de investigación.				80%	
PERTENENCIA	El instrumento es adecuado al tipo de investigación.				80%	
TOTAL					80%	

III. PROMEDIO DE VALIDACIÓN

--

IV. OPCIÓN DE APLICABILIDAD

- () El instrumento puede ser aplicado, tal como está elaborado
 () El instrumento debe ser mejorado antes de ser aplicado


 FIRMA DEL EXPERTO

ANEXO N° 8
TABLA DE VALIDACIÓN DEL INSTRUMENTO DE EXPERTOS: DETERMINAR EL PUNTAJE
I. DATOS GENERALES

Apellidos y Nombres del Experto: **ALARCON CAJAS, YOHAN ROY**
 Título y/o Grado Académico: **ING. DE SISTEMAS**

Doctor () Magister (x) Ingeniero () Licenciado () Otro ().....

Universidad que labora: **Universidad César Vallejo**
 Fecha: **28/11/2021**

Título de Investigación: Deep Learning Para la Detección de Fallas en Pavimentos de una Zona del Distrito de Villa María del Triunfo 2022.

Autores:

- Zuñiga Guisado, Yenmy

Deficiente (0-20%) Regular(21-50%) Bueno(51-70%) Muy Bueno(71-80%) Excelente(81-100%)


II. ASPECTOS DE VALIDACIÓN

INDICADOR	CRITERIO	VALORACIÓN				
		0-20%	21-50%	51-70%	71-80%	81-100%
CLARIDAD	Es formulado con lenguaje apropiado.				80%	
OBJETIVIDAD	Esta expresado en conducta observable.				80%	
ACTUALIDAD	Es adecuado el avance, la ciencia y tecnología.				80%	
ORGANIZACIÓN	Existe una organización lógica.				80%	
SUFICIENCIA	Comprende los aspectos de cantidad y calidad.				80%	
INTENCIONALIDAD	Adecuado para valorar los aspectos del sistema metodológico y científico.				80%	
CONSISTENCIA	Está basado en aspectos teóricos y científicos.				80%	
COHERENCIA	En los datos respecto al indicador.				80%	
METODOLOGÍA	Responde al propósito de investigación.				80%	
PERTENENCIA	El instrumento es adecuado al tipo de investigación.				80%	
TOTAL					80%	

III. PROMEDIO DE VALIDACIÓN**IV. OPCIÓN DE APLICABILIDAD**

- () El instrumento puede ser aplicado, tal como está elaborado
- () El instrumento debe ser mejorado antes de ser aplicado

FIRMA DEL EXPERTO





ANEXO N° 9

Ficha de registro del indicador – Calcular Precisión

Autor: Zúñiga Guisado, Yenmy

Indicador:
$$\text{Precisión} = \frac{TP}{TP + FP}$$

Objetivo: Determinar la precisión del reconocimiento de imagen

Periodo: En un periodo 30 días

Fecha de aprobación: 28/11/2021

N°	Nombre archivo	Dimensiones	Pavimento		Hueco	Grieta
1	test_1	1920x1080	Asfaltado		1	
2	test_2	1920x1080	Asfaltado		1	
3	test_3	1920x1080	Asfaltado		1	
4	test_4	1920x1080	Asfaltado		1	
5	test_5	1920x1080	Asfaltado			1
6	test_6	1920x1080	Asfaltado			1
7	test_7	1920x1080	Asfaltado			1
8	test_8	1920x1080	Asfaltado			1
9	test_9	1920x1080	Asfaltado			1
10	test_10	1920x1080	Asfaltado		1	
11	test_11	1920x1080	Asfaltado		1	
12	test_12	1920x1080	Asfaltado		1	
13	test_13	1920x1080	Asfaltado		1	
14	test_14	1920x1080	Asfaltado		1	
15	test_15	1920x1080		Concreto	1	
16	test_16	1920x1080		Concreto	1	
17	test_17	1920x1080		Concreto	1	
18	test_18	1920x1080		Concreto	1	
19	test_19	1920x1080		Concreto	1	
20	test_20	1920x1080		Concreto	1	
21	test_21	1920x1080		Concreto		1
22	test_22	1920x1080		Concreto		1
23	test_23	1920x1080		Concreto		1
24	test_24	1920x1080		Concreto		1
25	test_25	1920x1080		Concreto		1
26	test_26	1920x1080		Concreto	1	
27	test_27	1920x1080		Concreto	1	
28	test_28	1920x1080		Concreto	1	
29	test_29	1920x1080		Concreto	1	
30	test_30	1920x1080		Concreto	1	



ANEXO N° 10

Ficha de registro del indicador – Determinar el Puntaje

Autores: Zúñiga Guisado, Yenmy

Indicador:
$$F1 = \frac{2(\frac{TP}{TP + FN} * \text{precisión})}{\frac{TP}{TP + FN} + \text{precisión}}$$


Objetivo: Incrementar el porcentaje del nivel de servicio

Periodo: En un periodo de 30 días

Fecha de aprobación: 28/11/2021

N°	Nombre archivo	Dimensiones	Pavimento		Hueco	Grieta
1	test_1	1920x1080	Asfaltado		1	
2	test_2	1920x1080	Asfaltado		1	
3	test_3	1920x1080	Asfaltado		1	
4	test_4	1920x1080	Asfaltado		1	
5	test_5	1920x1080	Asfaltado			1
6	test_6	1920x1080	Asfaltado			1
7	test_7	1920x1080	Asfaltado			1
8	test_8	1920x1080	Asfaltado			1
9	test_9	1920x1080	Asfaltado			1
10	test_10	1920x1080	Asfaltado		1	
11	test_11	1920x1080	Asfaltado		1	
12	test_12	1920x1080	Asfaltado		1	
13	test_13	1920x1080	Asfaltado		1	
14	test_14	1920x1080	Asfaltado		1	
15	test_15	1920x1080		Concreto	1	
16	test_16	1920x1080		Concreto	1	
17	test_17	1920x1080		Concreto	1	
18	test_18	1920x1080		Concreto	1	
19	test_19	1920x1080		Concreto	1	
20	test_20	1920x1080		Concreto	1	
21	test_21	1920x1080		Concreto		1
22	test_22	1920x1080		Concreto		1
23	test_23	1920x1080		Concreto		1
24	test_24	1920x1080		Concreto		1
25	test_25	1920x1080		Concreto		1
26	test_26	1920x1080		Concreto	1	
27	test_27	1920x1080		Concreto	1	
28	test_28	1920x1080		Concreto	1	
29	test_29	1920x1080		Concreto	1	
30	test_30	1920x1080		Concreto	1	

ANEXO N° 11.



Zona de estudio de captura de imágenes a través del teléfono inteligente.

Fuente: Elaboración propia.

ANEXO N° 12.




Diagrama de flujo para la captura de imagen


ANEXO N° 13.



Características del teléfono inteligente MOTOROLA MOTO E6 PLUS:

- Tamaño de la pantalla: 6.1 pulgadas
- Resolución: 720 x 1560 px
- Sistema operativo: Android 9.0
- Cámara posterior: Dual, 13 MP
- Cámara frontal: 8 MP, 1080p, HDR
- Memoria interna: 32GB
- Memoria RAM: 2GB
- Tipo de batería: Li-Po
- Redes 4G: LTE
- SIM: SIM dual híbrido
- USB: microUSB 2.0
- Alto: 155.6 mm
- Ancho: 73.1 mm
- Profundidad: 8.6 mm
- Peso: 150 g

Captura de imágenes

ANEXO N° 14.


Registro estadístico de imágenes de pavimentos

Tabla. Ficha de registro de las características de la clase grieta y hueco

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	Telefono inteligente	jpg	4160	3120	1920	1080	121	292
		Asfaltado	Telefono inteligente	jpg	4160	3120	1920	1080	12	
	Grieta longitudinal	Cemento	Telefono inteligente	jpg	4160	3120	1920	1080	84	
		Asfaltado	Telefono inteligente	jpg	4160	3120	1920	1080	8	
Hueco	Grieta de cocodrilo	Cemento	Telefono inteligente	jpg	4160	3120	1920	1080	33	128
		Asfaltado	Telefono inteligente	jpg	4160	3120	1920	1080	34	
	Cubierta de pozo	Cemento	Telefono inteligente	jpg	4160	3120	1920	1080	50	
		Asfaltado	Telefono inteligente	jpg	4160	3120	1920	1080	78	

Fuente. Elaboración propia


ANEXO N° 15.

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	


Asignar nombre a las imágenes capturadas

ANEXO N° 16.

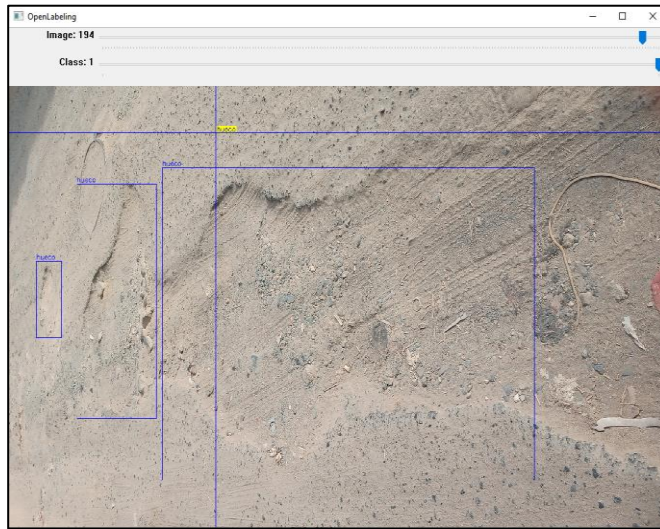
A) Vott



B) MakeAlphaSense



C) OpenLabeling



D) Labelme




Figura. Herramientas de etiquetado

ANEXO N° 17.




Figura. Diagrama de flujo para el diseño del aplicativo denominado ÑawiBionic

ANEXO N° 18.

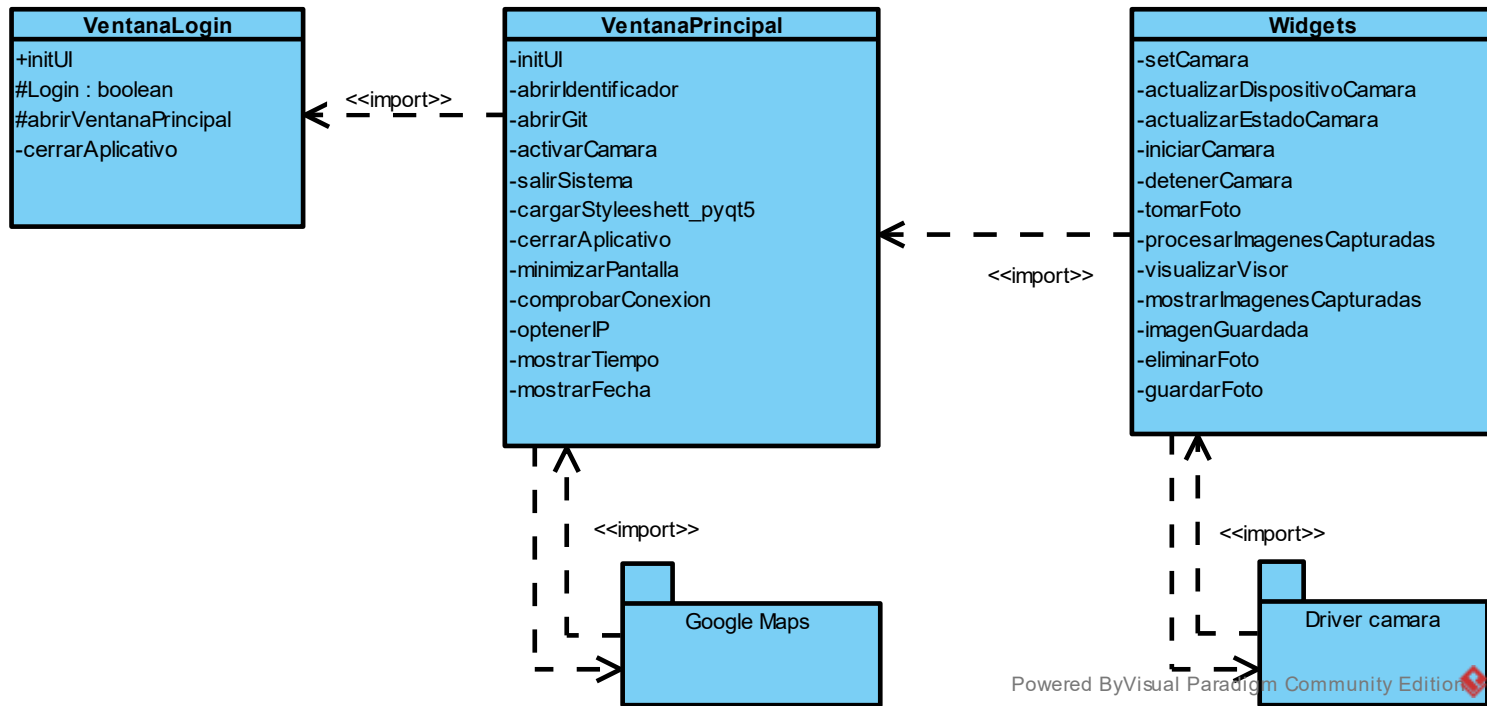


Figura. Diagrama de clases, representa la visualización de las funciones y clases implementadas en el aplicativo

ANEXO N° 19.

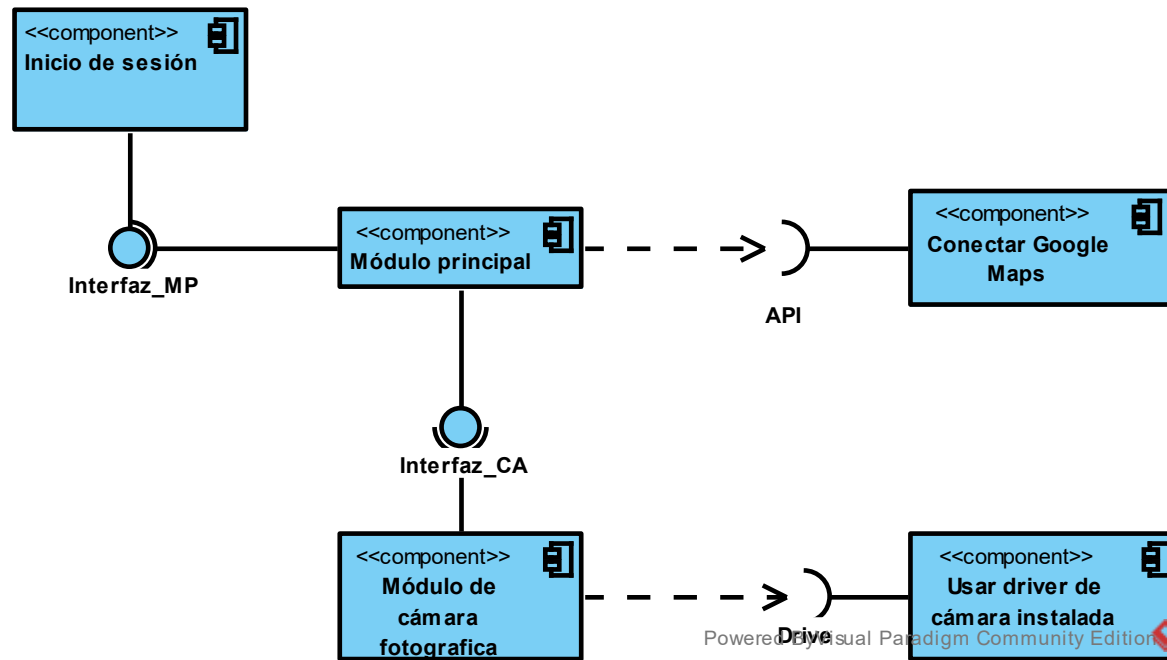


Figura. Diagrama de componentes

ANEXO N° 20.




Figura. Diagrama de paquetes

ANEXO N° 21.


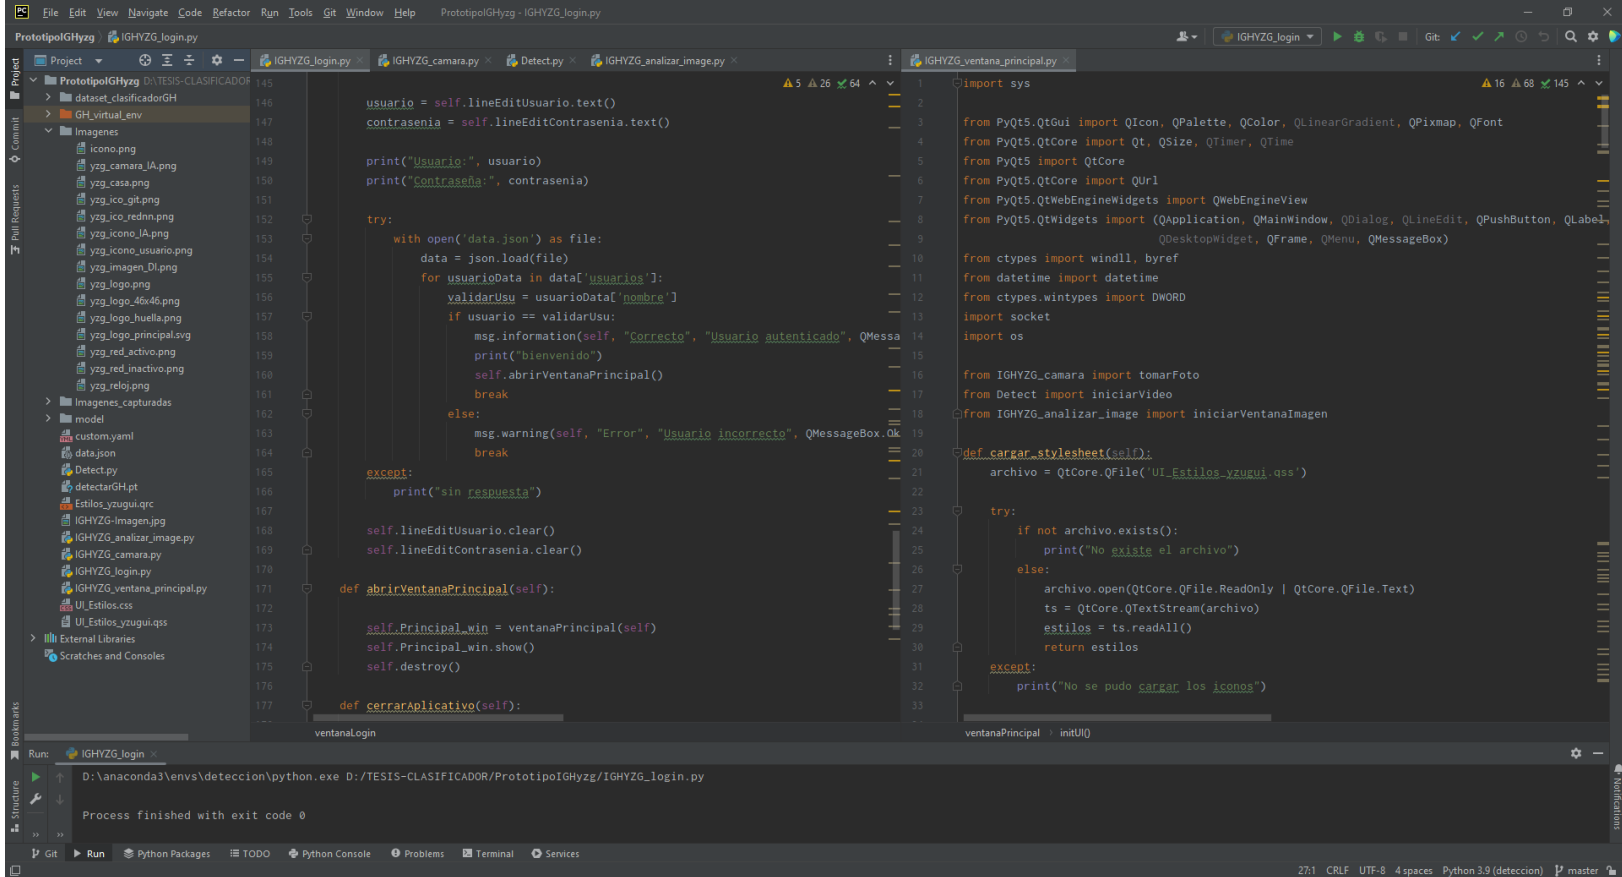


Figura. Arquitectura para el desarrollo del sistema inteligente NawiBionic

ANEXO N° 22.



```

145
146
147
148
149
150
151
152
153
154
155
156
157
158
159
160
161
162
163
164
165
166
167
168
169
170
171
172
173
174
175
176
177
...
usuario = self.lineEditUsuario.text()
contrasenia = self.lineEditContrasenia.text()

print("Usuario:", usuario)
print("Contrasena:", contrasenia)

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")

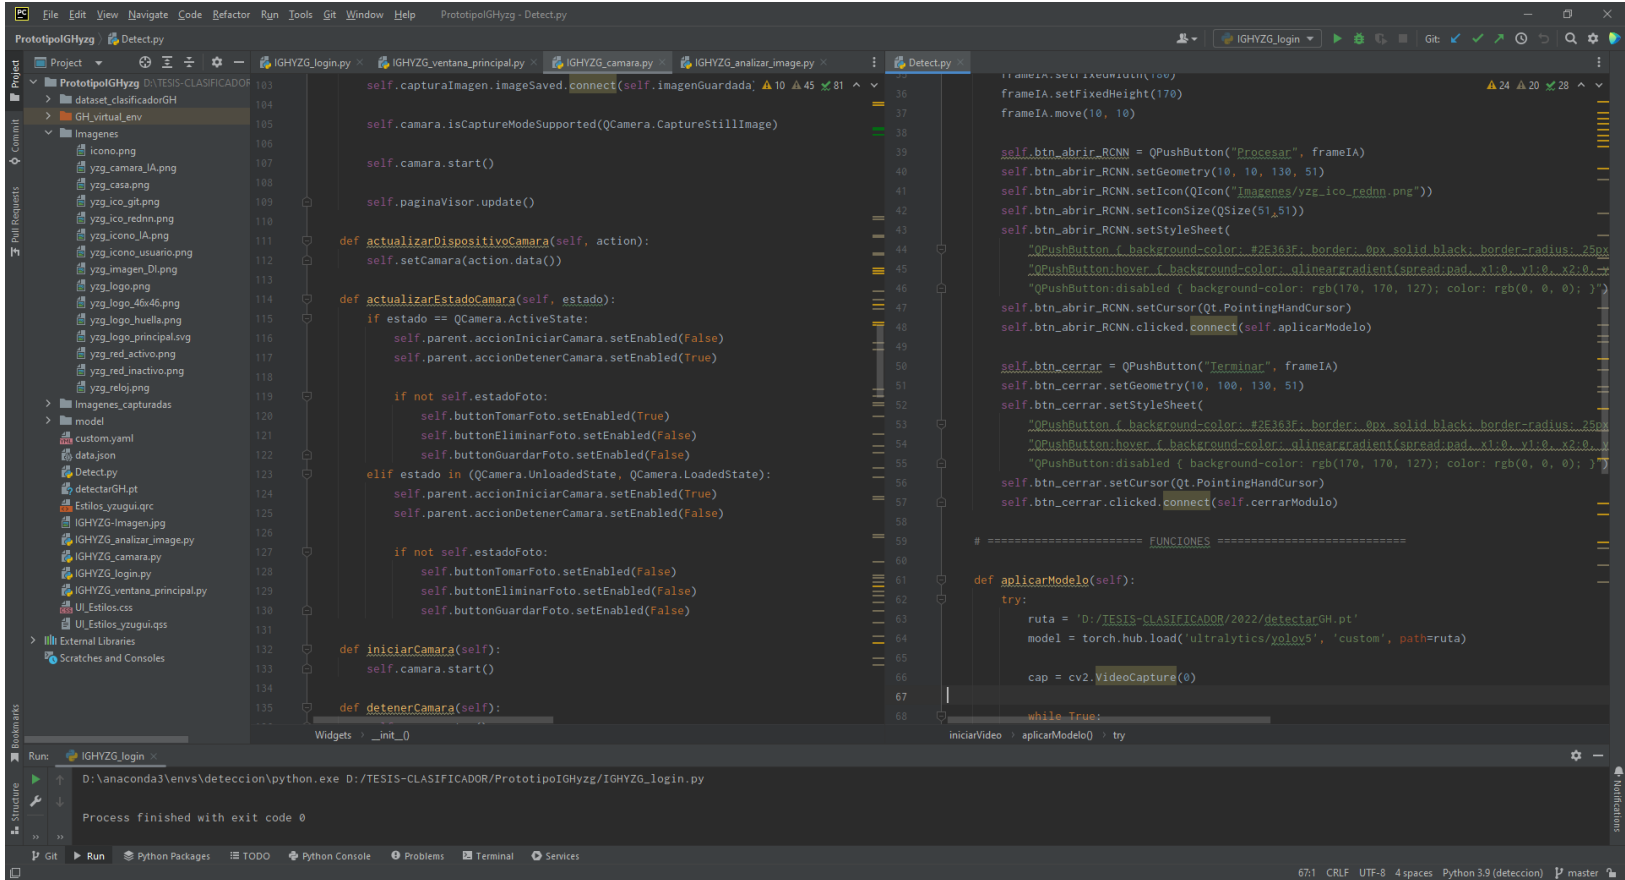
self.lineEditUsuario.clear()
self.lineEditContrasenia.clear()

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

def cerrarAplicativo(self):
    ventanaLogin
    ventanaPrincipal > initUI()
    
```

Figura. Escritura de código de los módulos denominados IGHYZG_login.py, IGHYZG_ventana_principal.py

ANEXO N° 23.

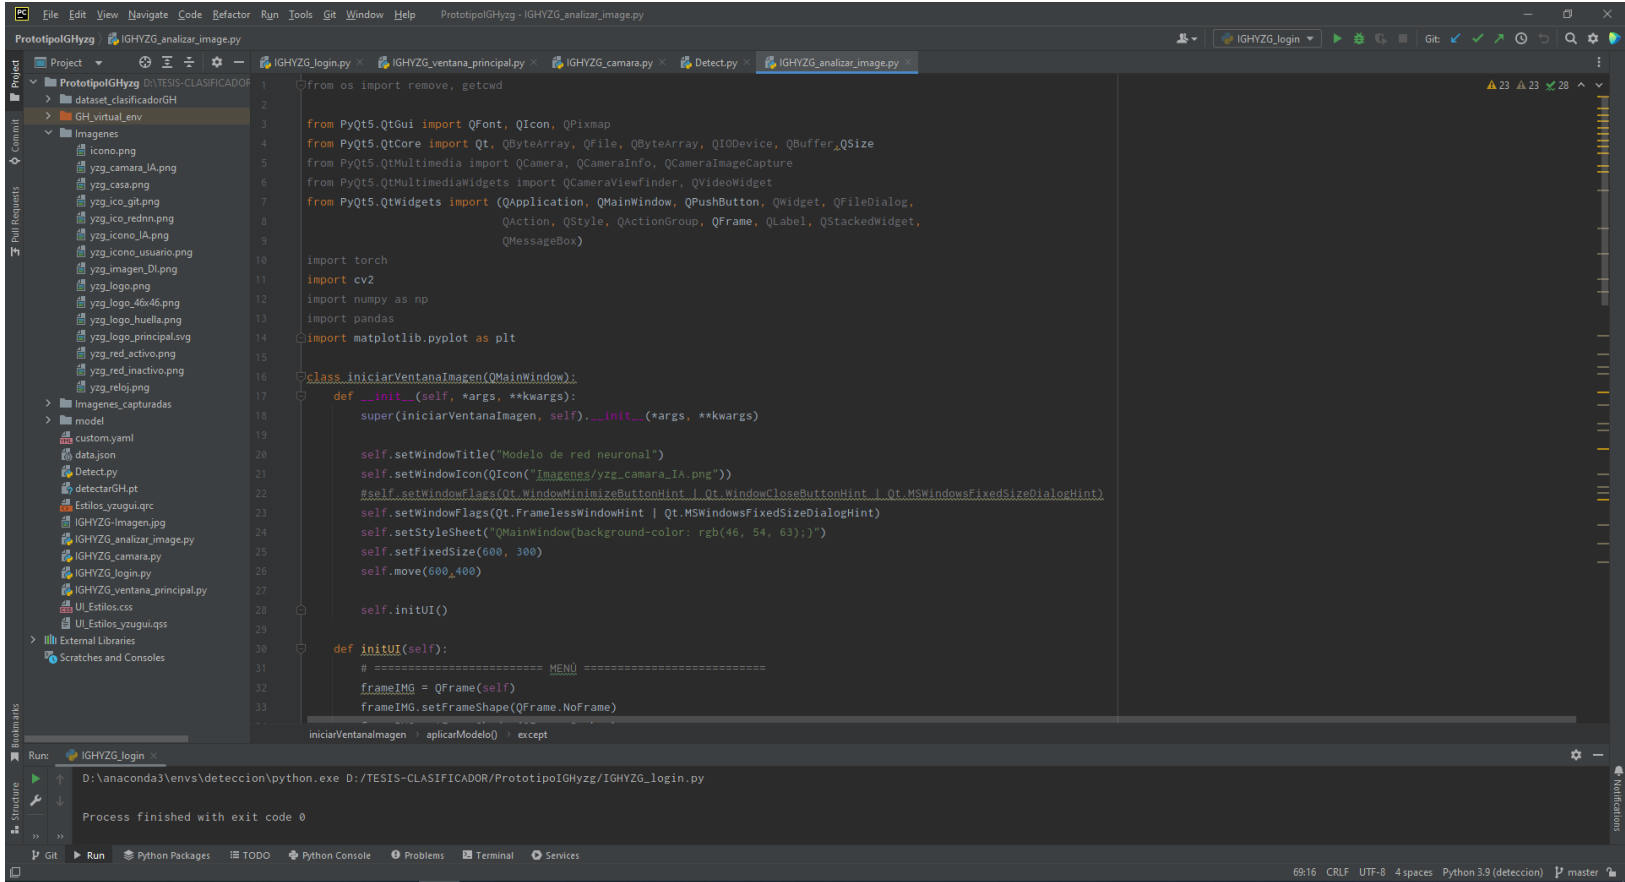


```

103 self.capturaImagen.imageSaved.connect(self.imagenGuardada)
104
105 self.camara.isCaptureModeSupported(QCamera.CaptureStillImage)
106
107 self.camara.start()
108
109 self.paginaVisor.update()
110
111 def actualizarDispositivoCamara(self, action):
112     self.setCamara(action.data())
113
114 def actualizarEstadoCamara(self, estado):
115     if estado == QCamera.ActiveState:
116         self.parent.accionIniciarCamara.setEnabled(False)
117         self.parent.accionDetenerCamara.setEnabled(True)
118
119         if not self.estadoFoto:
120             self.buttonTomarFoto.setEnabled(True)
121             self.buttonEliminarFoto.setEnabled(False)
122             self.buttonGuardarFoto.setEnabled(False)
123
124         elif estado in (QCamera.UnloadedState, QCamera.LoadedState):
125             self.parent.accionIniciarCamara.setEnabled(True)
126             self.parent.accionDetenerCamara.setEnabled(False)
127
128             if not self.estadoFoto:
129                 self.buttonTomarFoto.setEnabled(False)
130                 self.buttonEliminarFoto.setEnabled(False)
131                 self.buttonGuardarFoto.setEnabled(False)
132
133     def iniciarCamara(self):
134         self.camara.start()
135
136     def detenerCamara(self):
137
36 frameIA.setFixedWidth(170)
37 frameIA.setFixedHeight(170)
38 frameIA.move(10, 10)
39
40 self.btn_abrir_RCNN = QPushButton("Procesar", frameIA)
41 self.btn_abrir_RCNN.setGeometry(10, 10, 130, 51)
42 self.btn_abrir_RCNN.setIcon(QIcon("Imagenes/yzg_ico_redon.png"))
43 self.btn_abrir_RCNN.setIconSize(QSize(51,51))
44 self.btn_abrir_RCNN.setStyleSheet(
45     """QPushButton { background-color: #2E363F; border: 0px solid black; border-radius: 25px;
46     """QPushButton:hover { background-color: qlineargradient(spread:pad, x1:0, y1:0, x2:0,
47     """QPushButton:disabled { background-color: rgb(170, 170, 127); color: rgb(0, 0, 0); }
48 self.btn_abrir_RCNN.setCursor(Qt.PointingHandCursor)
49 self.btn_abrir_RCNN.clicked.connect(self.aplicarModelo)
50
51 self.btn_cerrar = QPushButton("Terminar", frameIA)
52 self.btn_cerrar.setGeometry(10, 100, 130, 51)
53 self.btn_cerrar.setStyleSheet(
54     """QPushButton { background-color: #2E363F; border: 0px solid black; border-radius: 25px;
55     """QPushButton:hover { background-color: qlineargradient(spread:pad, x1:0, y1:0, x2:0,
56     """QPushButton:disabled { background-color: rgb(170, 170, 127); color: rgb(0, 0, 0); }
57 self.btn_cerrar.setCursor(Qt.PointingHandCursor)
58 self.btn_cerrar.clicked.connect(self.cerrarModulo)
59
60 # ===== FUNCIONES =====
61
62 def aplicarModelo(self):
63     try:
64         ruta = 'D:/TESIS-CLASIFICADOR/2022/detectarGH.pt'
65         model = torch.hub.load('ultralytics/yolov5', 'custom', path=ruta)
66         cap = cv2.VideoCapture(0)
67
68         while True:
    
```

Figura. Escritura de código de los módulos denominados IGHYZG_camara.py, Detect.py


ANEXO N° 24.



```
1 from os import remove, getcwd
2
3 from PyQt5.QtGui import QFont, QIcon, QPixmap
4 from PyQt5.QtCore import Qt, QByteArray, QFile, QByteArray, QIODevice, QBuffer, QSize
5 from PyQt5.QtMultimedia import QCamera, QCameraInfo, QCameraImageCapture
6 from PyQt5.QtMultimediaWidgets import QCameraViewFinder, QVideoWidget
7 from PyQt5.QtWidgets import (QApplication, QMainWindow, QPushButton, QWidget, QFileDialog,
8                             QAction, QStyle, QActionGroup, QFrame, QLabel, QStackedWidget,
9                             QMessageBox)
10
11 import torch
12 import cv2
13 import numpy as np
14 import pandas
15 import matplotlib.pyplot as plt
16
17 class iniciarVentanaImagen(QMainWindow):
18     def __init__(self, *args, **kwargs):
19         super(iniciarVentanaImagen, self).__init__(*args, **kwargs)
20
21         self.setWindowTitle("Modelo de red neuronal")
22         self.setWindowIcon(QIcon("imagenes/yzg_camara_IA.png"))
23         #self.setWindowFlags(Qt.WindowMinimizeButtonHint | Qt.WindowCloseButtonHint | Qt.MSWindowsFixedSizeDialogHint)
24         self.setWindowFlags(Qt.FramelessWindowHint | Qt.MSWindowsFixedSizeDialogHint)
25         self.setStyleSheet("QMainWindow{background-color: rgb(46, 54, 63);}")
26         self.setFixedSize(600, 300)
27         self.move(600, 400)
28
29         self.initUI()
30
31     def initUI(self):
32         # ===== MENU =====
33         frameIMG = QFrame(self)
34         frameIMG.setFrameShape(QFrame.NoFrame)
35         iniciarVentanaImagen.aplicarModelo() except
```

Figura. Escritura de código de los módulos denominados IGHYZG_analizar_image.py

ANEXO N° 25.



ANEXO N° 26.




Figura. Listado de librerías instaladas para el funcionamiento del aplicativo

ANEXO N° 27.

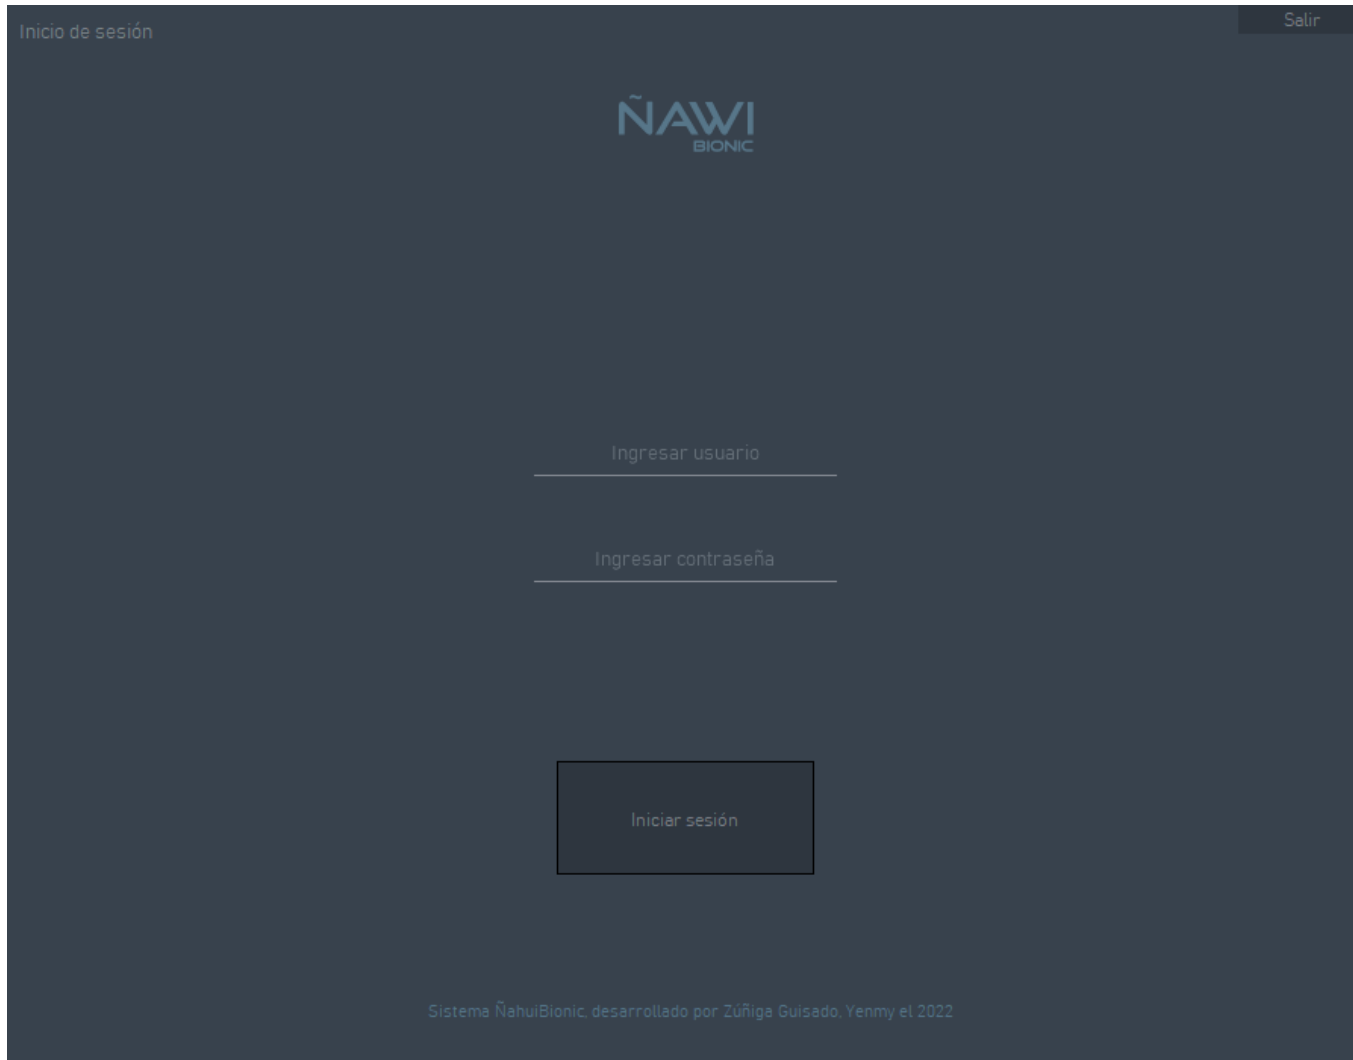


Figura. Interfaz de validación de usuario

ANEXO N° 28.




Figura. Módulo principal

ANEXO N° 29.

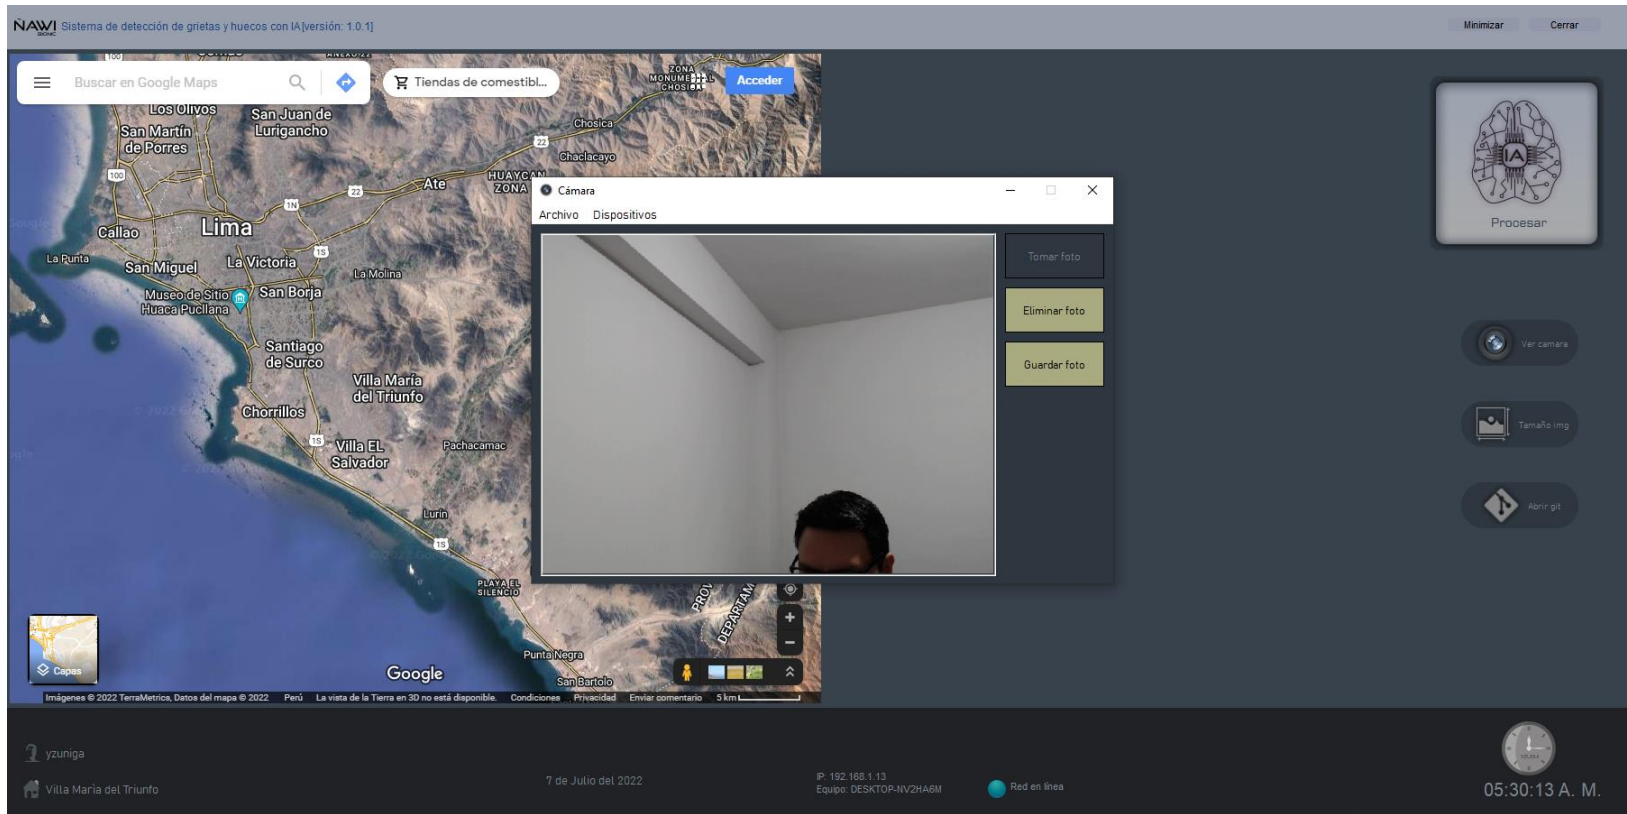


Figura. Módulo de cámara fotográfica

ANEXO N° 30.

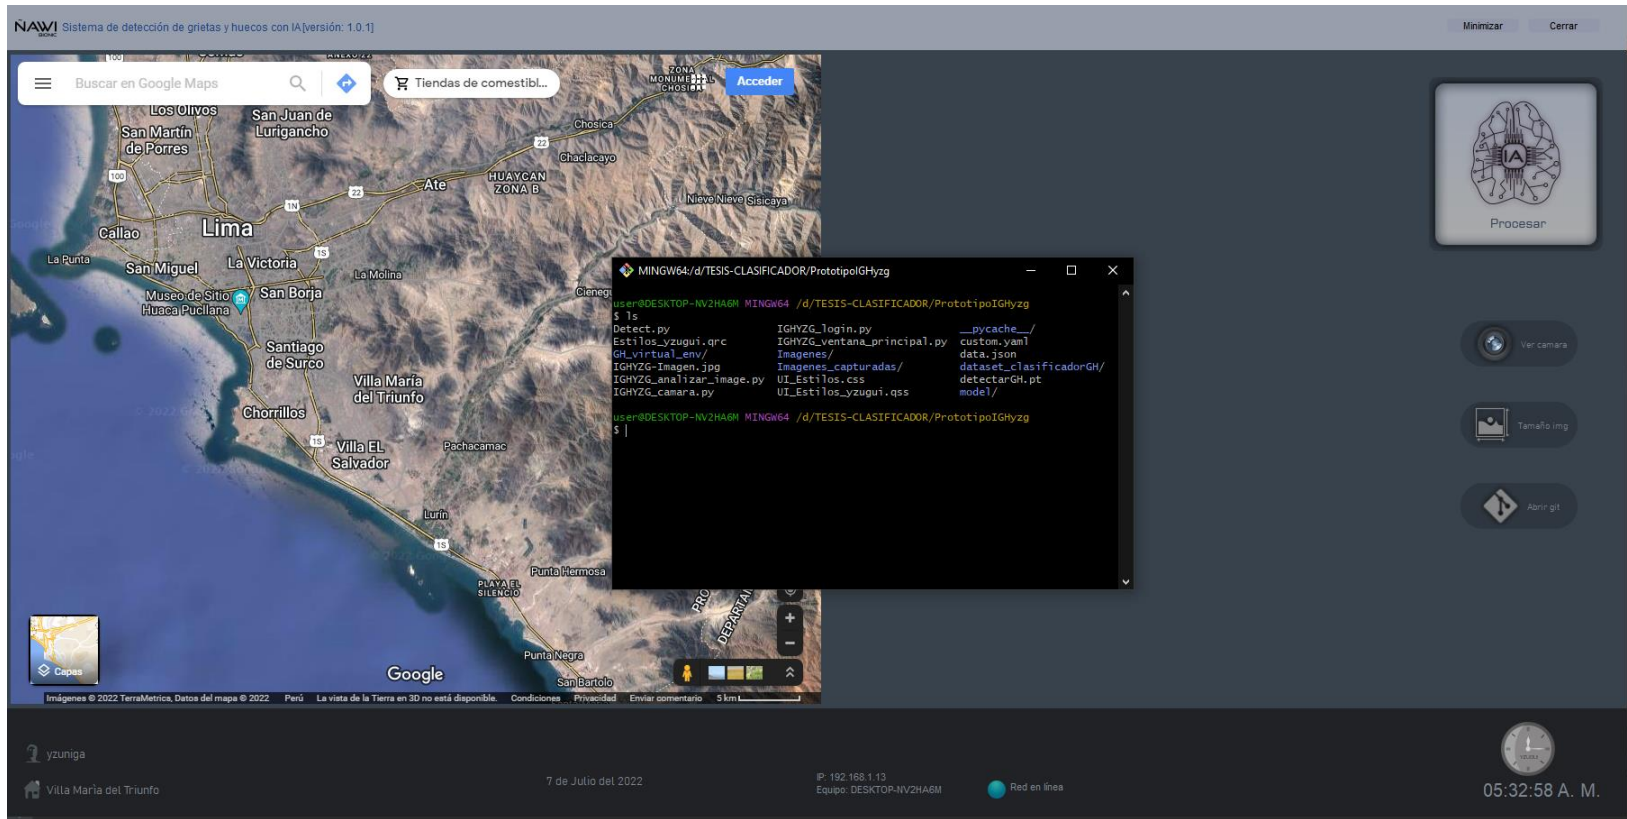


Figura. Módulo incorporado con git, para listar, configurar archivos del sistema.

ANEXO N° 31.

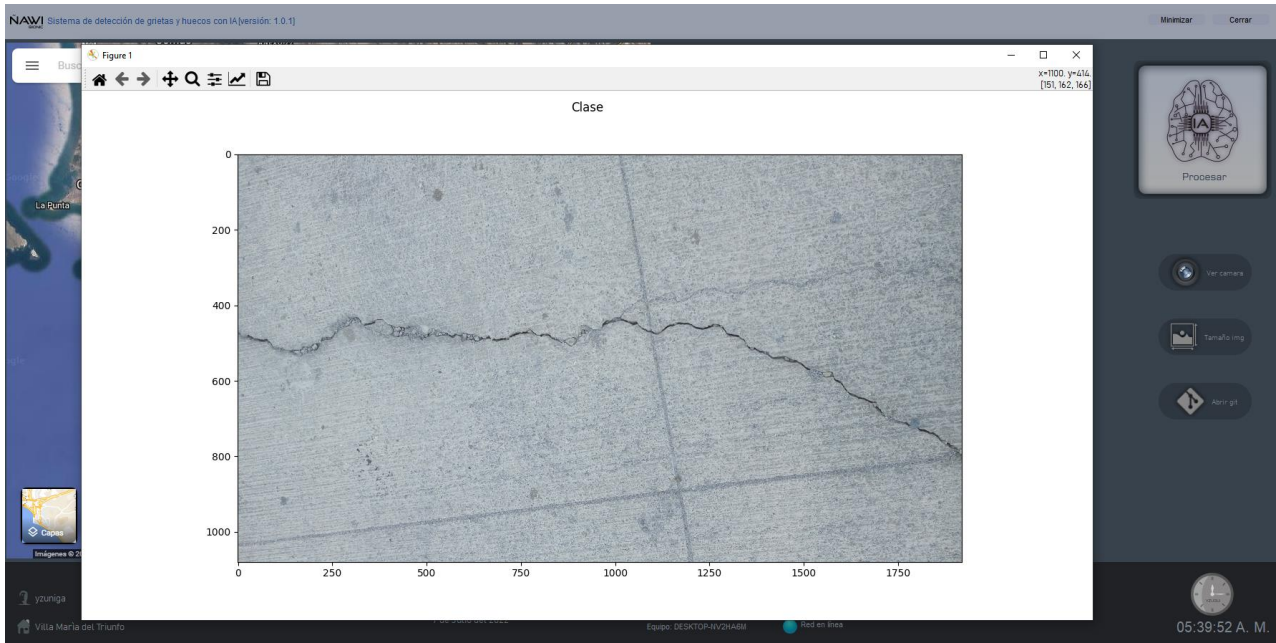
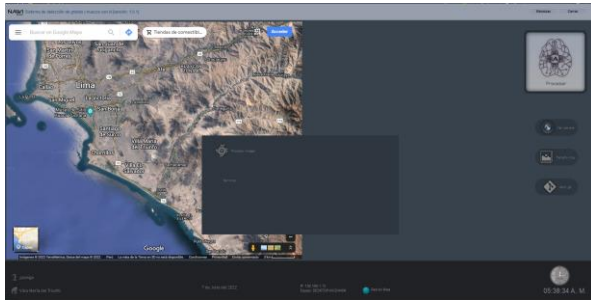


Figura. Visualizador de dimensiones de imágenes

ANEXO N° 32.

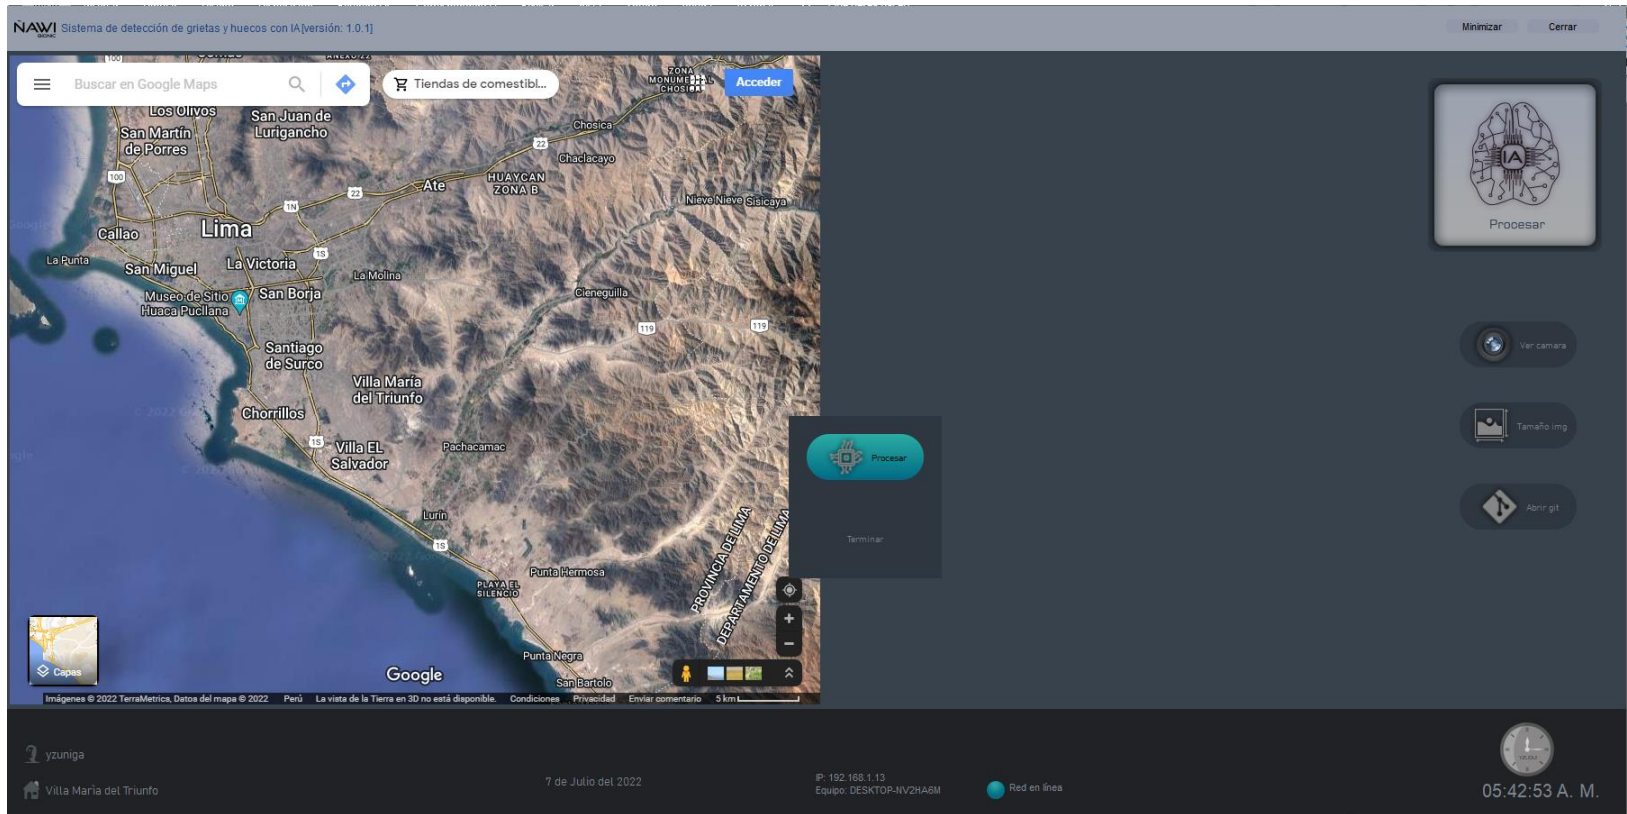


Figura. Módulo de activación IA para detectar grieta y huecos

ANEXO N° 33.




Figura. Módulo de activación IA detectando grieta con una precisión de 0.86.

ANEXO N° 34.

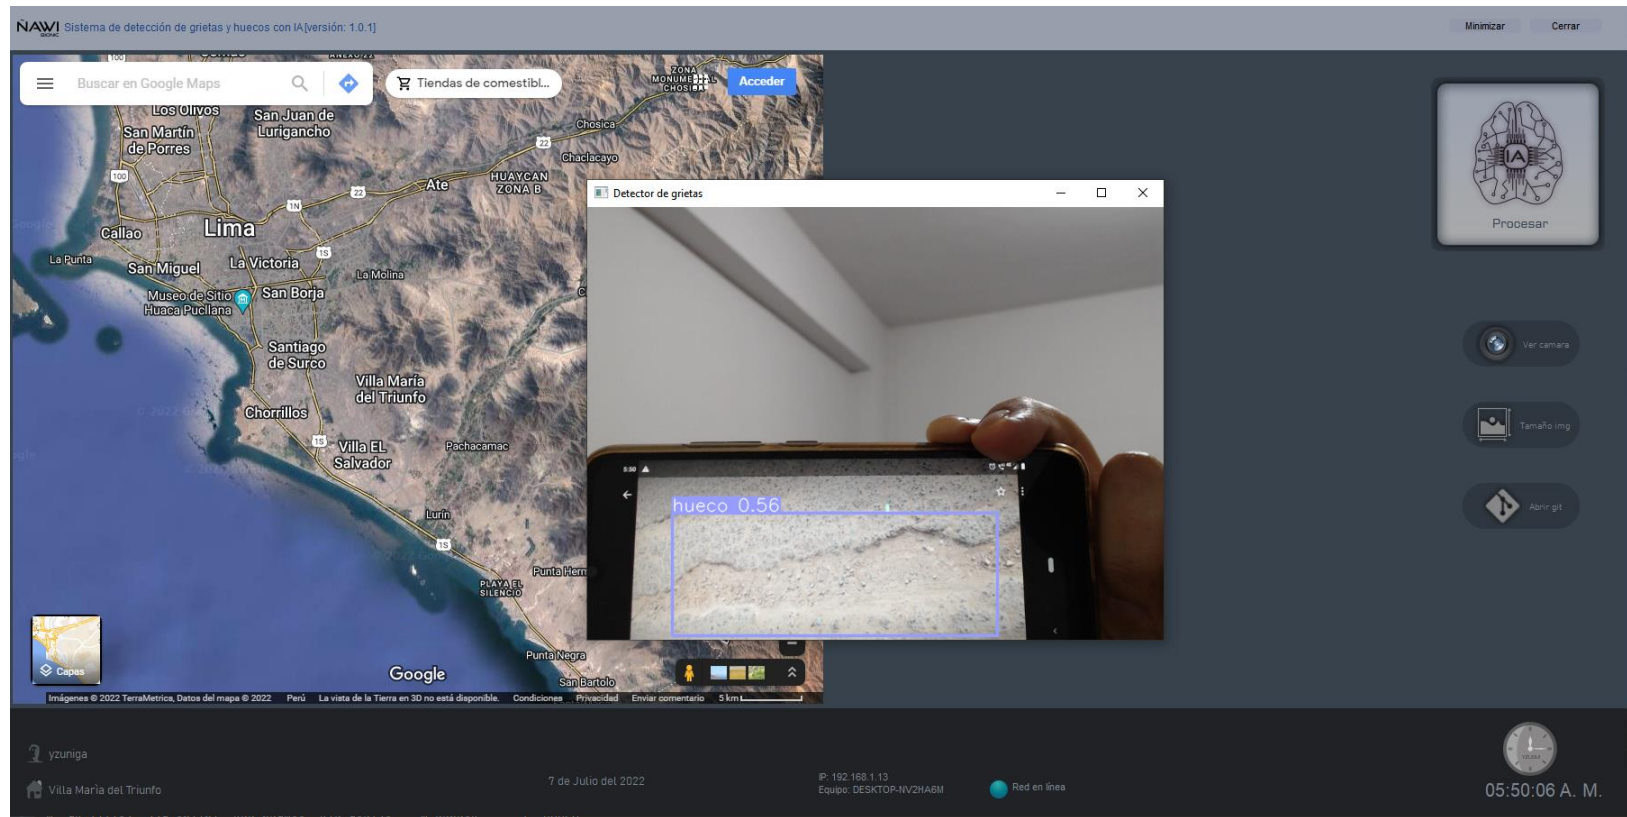


Figura. Módulo de activación IA detectando hueco con una precisión de 0.56.



UNIVERSIDAD CÉSAR VALLEJO

FACULTAD DE INGENIERÍA Y ARQUITECTURA

ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

ACTA DE SUSTENTACION DE TESIS

Siendo las 19:30 horas del 24/07/2022, el jurado evaluador se reunió para presenciar el acto de sustentación de Tesis titulada: "Deep Learning Para la Detección de Fallas en Pavimentos de una Zona del Distrito de Villa María del Triunfo 2022", presentado por el autor ZUÑIGA GUIADO YENMY estudiante de la escuela profesional de INGENIERÍA DE SISTEMAS.

Concluido el acto de exposición y defensa de Tesis, el jurado luego de la deliberación sobre la sustentación, dictaminó:

Autor	Dictamen
YENMY ZUÑIGA GUIADO	Excelencia

Firmado digitalmente por: EVALLEJOS el
02 Ago 2022 17:43:16

Firmado digitalmente por:
RUDYCHAPONAN el 02 Ago 2022
18:56:26

EDUARDO VALLEJOS SALAZAR
PRESIDENTE

RUDY CHAPOÑAN CAMARENA
SECRETARIO

Firmado digitalmente por: YALARCONCA el
02 Ago 2022 18:15:14

YOHAN ROY ALARCON CAJAS
VOCAL

Código documento Trilce: TRI - 0348821



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

Autorización de Publicación en Repositorio Institucional

Yo, ZUÑIGA GUIADO YENMY identificado con DNI N° 43575414, (respectivamente) estudiante de la FACULTAD DE INGENIERÍA Y ARQUITECTURA y de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, autorizo (X), no autorizo () la divulgación y comunicación pública de mi Tesis: "Deep Learning Para la Detección de Fallas en Pavimentos de una Zona del Distrito de Villa María del Triunfo 2022".

En el Repositorio Institucional de la Universidad César Vallejo, según esta estipulado en el Decreto Legislativo 822, Ley sobre Derecho de Autor, Art. 23 y Art. 33.

Fundamentación en caso de NO autorización:

--

LIMA, 22 de Julio del 2022

Apellidos y Nombres del Autor	Firma
ZUÑIGA GUIADO YENMY DNI: 43575414 ORCID 0000-0002-0185-912X	Firmado digitalmente por: YZUNIGAG el 22-07-2022 21:52:36

Código documento Trilce: INV - 0773703



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

Declaratoria de Autenticidad del Asesor

Yo, ALARCON CAJAS YOHAN ROY, docente de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, asesor de Tesis titulada: "Deep Learning Para la Detección de Fallas en Pavimentos de una Zona del Distrito de Villa María del Triunfo 2022", cuyo autor es ZUÑIGA GUIADO YENMY, constato que la investigación cumple con el índice de similitud establecido, y 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, 16 de Julio del 2022

Apellidos y Nombres del Asesor:	Firma
ALARCON CAJAS YOHAN ROY DNI: 46189705 ORCID 0000-0001-5382-3754	Firmado digitalmente por: YALARCONCA el 23-07- 2022 16:27:25

Código documento Trilce: TRI - 0348823



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

Declaratoria de Originalidad del Autor

Yo, ZUÑIGA GUIADO YENMY estudiante de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, declaro bajo juramento que todos los datos e información que acompañan la Tesis titulada: "Deep Learning Para la Detección de Fallas en Pavimentos de una Zona del Distrito de Villa María del Triunfo 2022", es de mi autoría, por lo tanto, declaro que la Tesis:

1. No ha sido plagiada ni total, ni parcialmente.
2. He 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 asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de la información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

Nombres y Apellidos	Firma
ZUÑIGA GUIADO YENMY DNI: 43575414 ORCID 0000-0002-0185-912X	Firmado digitalmente por: YZUNIGAG el 22-07-2022 21:52:44

Código documento Trilce: INV - 0773705