



**UNIVERSIDAD CÉSAR VALLEJO**

**FACULTAD DE INGENIERÍA Y ARQUITECTURA**

**ESCUELA PROFESIONAL DE INGENIERÍA CIVIL**

**Inspección automatizada de la superficie de pavimento  
flexible con el uso de redes neuronales convolucionales,  
Juliaca 2023**

**TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:  
Ingeniero Civil**

**AUTOR:**

Mamani Coasaca, Rosmeri Glenda (orcid.org/0009-0002-6425-4707)

**ASESOR:**

Mgtr. Quesada Llanto, Julio Christian (orcid.org/0000-0003-4366-4926)

**LÍNEA DE INVESTIGACIÓN:**

Diseño de Infraestructura Vial

**LINEA DE INVESTIGACION SOCIAL UNIVERSITARIA:**

Desarrollo económico, empleo y emprendimiento

**CALLAO – PERÚ**

**2024**



**UNIVERSIDAD CÉSAR VALLEJO**

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

### **Declaratoria de Autenticidad del Asesor**

Yo, QUESADA LLANTO JULIO CHRISTIAN, docente de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA CIVIL de la UNIVERSIDAD CÉSAR VALLEJO SAC - CALLAO, asesor de Tesis titulada: "Inspección Automatizada De La Superficie De Pavimento Flexible Con El Uso De Redes Neuronales Convolucionales, Juliaca 2023", cuyo autor es MAMANI COASACA ROSMERI GLENDA, constato que la investigación tiene un índice de similitud de 14%, 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, 19 de Abril del 2024

<b>Apellidos y Nombres del Asesor:</b>	<b>Firma</b>
QUESADA LLANTO JULIO CHRISTIAN DNI: 42831273 ORCID: 0000-0003-4366-4928	Firmado electrónicamente por: JQUESADA el 19-04- 2024 15:44:13

Código documento Trilce: TRI - 0743128



**UNIVERSIDAD CÉSAR VALLEJO**

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

**Declaratoria de Originalidad del Autor**

Yo, MAMANI COASACA ROSMERI GLENDA estudiante de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA CIVIL de la UNIVERSIDAD CÉSAR VALLEJO SAC - CALLAO, declaro bajo juramento que todos los datos e información que acompañan la Tesis titulada: "Inspección Automatizada De La Superficie De Pavimento Flexible Con El Uso De Redes Neuronales Convolucionales, Juliaca 2023", 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
ROSMERI GLENDA MAMANI COASACA DNI: 76196044 ORCID: 0009-0002-8425-4707	Firmado electrónicamente por: RGMAMANI el 19-04- 2024 15:14:29

Código documento Trilce: TRI - 0743127

## **DEDICATORIA**

Este trabajo se lo dedico especialmente a Dios quien me ayuda a seguir adelante día a día, por sus bendiciones; a mis padres que por ellos soy lo que soy hoy en día; a mi mami Nelida Coasaca por inculcarme desde niña la importancia de los valores y el estudio, por su apoyo constante, amor incondicional y palabras de aliento ante cualquier adversidad; a mi papi Wilber Mamani por ser mi cable a tierra, por los valores inculcados, palabras de aliento y por siempre confiar en mí.

## **AGRADECIMIENTO**

Mi agradecimiento a la Universidad César Vallejo por abrirme sus puertas para lograr mi superación en esta carrera.

Al ingeniero Julio Quesada Llanto por brindarme su apoyo y orientación como asesor para la elaboración de este trabajo de tesis.

Para culminar a todas aquellas personas que me brindaron su tiempo y apoyo para el logro de mis objetivos.

Muchas Gracias

## ÍNDICE DE CONTENIDO

Carátula.....	i
Declaratoria de autenticidad del asesor.....	ii
Declaratoria de autenticidad del autor.....	iii
Dedicatoria.....	IV
Agradecimiento.....	V
Indice de contenido.....	VI
Indice de tablas.....	X
Resumen.....	XI
Abstract.....	XII
I. INTRODUCCIÓN.....	1
II. METODOLOGIA.....	23
III. RESULTADOS.....	78
IV. DISCUSIÓN.....	87
V. CONCLUSIONES.....	91
VI. RECOMENDACIONES.....	92
REFERENCIAS.....	93
ANEXOS.....	98

## ÍNDICE DE FIGURAS Y GRAFICOS

<b>Figura 1</b> <i>Red Neuronal Artificial (RNA) de Tres Capas Interconectadas</i> .....	14
<b>Figura 2</b> <i>Red Neuronal Convolutacional</i> .....	15
<b>Figura 3</b> <i>Algoritmo ACSTM</i> .....	18
<b>Figura 4</b> <i>Partes de un Pavimento Flexible</i> .....	19
<b>Figura 5</b> <i>Ejemplos de Fallas en Pavimento Flexible</i> .....	21
<b>Figura 6</b> <i>Mantenimiento de una Vía</i> .....	22
<b>Figura 7</b> <i>Sistema Vial de la Ciudad de Juliaca</i> .....	28
<b>Figura 8</b> <i>Jirón mi Perú con la Av. héroes de la guerra del pacifico progresiva 0+584</i> .....	29
<b>Figura 9</b> <i>I.E. central Esquen con la av. Héroes de la Guerra del Pacifico progresiva</i> <i>4+250</i> .....	299
<b>Figura 10</b> <i>Red Neuronal Convolutacional con tres Diferentes Secciones de Extracción</i> <i>de Características</i> .....	31
<b>Figura 11</b> <i>Esquema de Proceso a Realizar</i> .....	33
<b>Figura 12</b> <i>Ubicación del Tramo Evaluado de la Ciudad de Juliaca, Iniciando en el</i> <i>Jirón Mi Perú y concluyendo en la escuelita Esquen</i> .....	35
<b>Figura 13</b> <i>Esquema de Captura de Imágenes del Pavimento Flexible</i> .....	36
<b>Figura 14</b> <i>Detalle de cámara de teléfono inteligente</i> .....	37
<b>Figura 15</b> <i>Recorrido de Cámara en la Toma de Imágenes para Posterior</i> <i>Procesamiento</i> .....	38
<b>Figura 16</b> <i>Etapas de la Obtención de Imágenes</i> .....	39
<b>Figura 17</b> <i>Esquema de Toma y Clasificación de Imágenes</i> .....	40

<b>Figura 18</b>	<i>Imágenes Obtenidas y Proceso de Obtención</i> .....	41
<b>Figura 19</b>	<i>Fotogramas Obtenidos con Herramienta VLC Media Player</i> .....	42
<b>Figura 20</b>	<i>Registro del total de Imágenes Obtenidas Luego del Proceso de Selección</i> .....	43
<b>Figura 21</b>	<i>Detallado de Imágenes Correspondientes a Entrenamiento y Validación</i> .....	44
<b>Figura 22</b>	<i>Creación de Estructura de Datos</i> .....	<b>¡Error! Marcador no definido.</b>
<b>Figura 23</b>	<i>Carga de Datos</i> .....	46
<b>Figura 24</b>	<i>Proceso de Etiquetado con Herramienta Roboflow</i> .....	48
<b>Figura 25</b>	<i>Dataset Obtenido</i> .....	49
<b>Figura 26</b>	<i>Desarrollador y Lenguaje de Programación utilizados como son JupyterLab y Python respectivamente</i> .....	52
<b>Figura 27</b>	<i>Arquitectura de Tipo Convolutiva CNN</i> .....	53
<b>Figura 28</b>	<i>Obtención de un Mapa de Detección de Características</i> .....	56
<b>Figura 29</b>	<i>Capa Convolutiva</i> .....	57
<b>Figura 30</b>	<i>Arquitectura de Red de Neuronas / Capas de Convoluciones</i> .....	58
<b>Figura 31</b>	<i>Proceso de Convolución</i> .....	59
<b>Figura 32</b>	<i>Procedimiento para el Entrenamiento de Red Neuronal Convolutiva</i>	60
<b>Figura 33</b>	<i>Descarga desarrollador Anaconda Navigator</i> .....	61
<b>Figura 34</b>	<i>Creación de Entorno en Anaconda Navigator</i> .....	62
<b>Figura 35</b>	<i>Proceso de Descarga de Librerías</i> .....	63
<b>Figura 36</b>	<i>Desarrollador Anaconda- Entorno Listo</i> .....	63
<b>Figura 37</b>	<i>Ejecución de Python 3 dentro de JupyterLab</i> .....	65
<b>Figura 38</b>	<i>Versión de Algoritmo</i> .....	67
<b>Figura 39</b>	<i>Obtención de la Ejecución de Algoritmo para Carga de Datos</i> .....	69



<b>Figura 40</b>	<i>Histograma Obtenido</i> .....	71
<b>Figura 41</b>	<i>Imágenes de Entrenamiento y Validación</i> .....	72
<b>Figura 42</b>	<i>Modelo de Red Neuronal</i> .....	73
<b>Figura 43</b>	<i>Perdida y Precisión del Modelo</i> .....	75
<b>Figura 44</b>	<i>Tramo Recorrido de la Avenida Héroes de la Guerra del Pacífico</i> .....	79
<b>Figura 46</b>	<i>Proceso de Selección de Imagenes</i> .....	81
<b>Figura 47</b>	<i>Conjunto de Imágenes que Representa el Dataset</i> .....	82
<b>Figura 48</b>	<i>Validación y Entrenamiento</i> .....	84
<b>Figura 49</b>	<i>Precisión del Modelo</i> .....	84
<b>Figura 50</b>	<i>Matriz de Confusión</i> .....	86
<b>Figura 51</b>	<i>Confiabilidad</i> .....	90

## ÍNDICE DE TABLAS

<b>Tabla 1</b> <i>Similitud de los Modelos de Inteligencia Artificial</i> .....	15
<b>Tabla 2</b> <i>Cantidad de Kilómetros Asfaltados por Zona</i> .....	26
<b>Tabla 3</b> <i>Medidas de las principales vías de la Ciudad de Juliaca</i> .....	27
<b>Tabla 4</b> <i>Algoritmos de de Grietas Según su Nivel de Eficacia</i> .....	50
<b>Tabla 5</b> <i>Principales Librerías Utilizadas</i> .....	54
<b>Tabla 6</b> <i>Cantidad de Imágenes Obtenidas</i> .....	82

## RESUMEN

Este proyecto se encargó de la evaluación superficial del pavimento flexible en la ciudad de Juliaca haciendo uso de sistemas computacionales, teniendo como principal objetivo el diseño de una red neuronal convolucional, para así realizar la detección de fallas, esta investigación es de tipo aplicada orientada a la solución de problemas prácticos y un enfoque de investigación de tipo cuantitativo; se consideró una población total de 180 Km de pavimento asfáltico y un muestreo no probabilístico por juicio eligiéndose la avenida Héroes de la Guerra del Pacífico que forma parte de la red vial nacional PE-34A con una extensión de 10Km, el tramo a evaluar comprende entre la progresiva 0+584 y 4+250 respectivamente; haciendo uso del desarrollador denominado Python ; para este estudio se contó con un total de 14769 fotogramas de los cuales se trabajó con un universo total de 646 imágenes de las cuales se destinaron el 80% al proceso de entrenamiento y el 20% al proceso de validación; alcanzando un total de 85% en confiabilidad del modelo; logrando de esta manera proporcionar una técnica la cual es fiable en la automatización como es en este caso la detección de fallas en la superficie del pavimento flexible.

Palabras clave: Red neuronal, convolucional, fallas en pavimento, automatización.

## **ABSTRACT**

This project was in charge of the surface evaluation of the flexible pavement in the city of Juliaca using computer systems, with the main objective being the design of a convolutional neural network, in order to detect faults. This research is of an applied type aimed at the solution of practical problems and a quantitative research approach; A total population of 180 km of asphalt pavement was considered and a non-probabilistic sampling was carried out by trial, choosing Héroes de la Guerra del Pacifico avenue, which is part of the national road network PE-34A with an extension of 10 km, the section to be evaluated includes between the progressive 0+584 and 4+250 respectively; using the developer called Python ; For this study, there was a total of 14,769 frames of which we worked with a total universe of 646 images, of which 80% were allocated to the training process and 20% to the validation process; reaching a total of 85% in model reliability; thus providing a technique which is reliable in automation, such as in this case the detection of faults on the surface of the flexible pavement.

Keywords: Neural network, convolutional, pavement failures, automation.

## I. INTRODUCCIÓN

En el mundo se puede observar una creciente extensión de carreteras , día con día las cuales vienen presentando fallas debido al incremento de diversos medios de transporte terrestre siendo el más popular el vehículo de motor y las altas velocidades con las que estos son manejadas influyendo así en un deterioro prematuro de sus carreteras además de los diferentes climas extremos que se puede llegar a tener en las diferentes partes del mundo, para poder tener una comunicación fluida y tranquila se requiere que sus carreteras se encuentren en un adecuado estado. En el Perú se pueden observar muchas carreteras con el problema de las fallas a lo largo de su recorrido, las cuales tienden a debilitarse muy rápido y requerir de un mantenimiento sin cumplir con el periodo mínimo estimado para la realización de estos y también debido a las evaluaciones previas de su situación las cuales suelen tomar mucho tiempo, esto se debe a problemas en el debido proceso constructivo o problemas con las proyecciones en el índice medio diario (IMD) de vehículos que transitan por determinadas vías no aptas para el tipo de vehículo de motor causando así la aparición de fallas en su superficie o estructura, la aparición de fallas en del pavimento flexible no solo puede causar daños estructurales sino también daños funcionales siendo como resultado de la variedad de clima y la calidad de material. En la región Puno se observa que los pavimentos con el pasar de los años van perdiendo su confort y con esto el nivel de servicio que brinda al área usuaria, los pavimentos se encuentran deteriorados de diferente nivel y proporción debido a diversos factores que influyen en la aparición de estos tanto a nivel superficial como estructural, debemos de reconocerlos desde un inicio para así poder dar una solución rápida y sin mucho costo. Actualmente tenemos muchos métodos para el análisis y el

diagnóstico de estas fallas superficiales que se presentan en el pavimento, las cuales se realizan mediante el trabajo de campo utilizando métodos visuales, las cuales requieren tiempo y posteriormente también opiniones imparciales de inspectores generando un poco de incertidumbre y la inversión de tiempo y mucho dinero ; es por eso que se plantea la utilización de Inteligencia Artificial para poder realizar estos trabajos de manera automatizada y precisa en menor costo y tiempo ,haciendo uso de algoritmos de inteligencia artificial , ayudándonos también de aplicativos y programas mediante el uso de técnicas para lograr el buen reconocimiento de fallas viales a lo largo de una carretera. Para este trabajo de tesis se tiene como **problema general**: ¿Cómo realizar una inspección automatizada de la superficie de pavimento flexible con el uso de redes neuronales convolucionales, Juliaca 2023 ?, seguidamente tenemos el **problema específico 1**: ¿de qué manera se realizará la detección de las fallas de la superficie del pavimento flexible haciendo uso de redes neuronales convolucionales, Juliaca 2023? ; **problema específico 2**:¿Cómo realizar una buena elección de la red neuronales convolucional para realizar la inspección de las fallas en la superficie del pavimento flexible , Juliaca 2023?; **problema específico 3**: ¿Cómo mejorar la inspección de las fallas en pavimentos flexibles haciendo uso de las redes neuronales convolucionales, Juliaca 2023?.La inteligencia artificial es una innovación tecnológica que cada vez está más presente en nuestra vida diaria siendo cada vez más accesible tanto para nuestra vida personal como a nuestro entorno, simplificando cada vez más algunos procedimientos de cierta complejidad. El trabajo que puede realizar una computadora es realmente impresionante tomando más en cuenta la precisión de los resultados que nos puedan brindar de acuerdo a una buena programación , el uso de algoritmos para poder conocer , predecir las fallas en un pavimento flexible nos ayuda a realizar evaluaciones a menor costo y en menor

tiempo ya que hasta el día de hoy se realizan las evaluaciones de la superficie de pavimento con trabajos de campo y gabinete , la inspección automatizada nos ayudara de gran manera a realizar los trabajos de inspección superficial o estructural al pavimento flexible ahorrándonos dinero y tiempo , ayudándonos a dar solución en menor tiempo y así realizar los mantenimientos de manera efectiva. Para este proyecto de tesis se tiene como **justificación practica** el modo en el que el proyecto de investigación cambiara la realidad del ámbito de estudio .Ya que en la actualidad nos encontramos en medio del avance de la tecnología en todos los ámbitos de manera acelerada , los cuales nos ayudan a simplificar y acelerar procesos ,,dentro dela ingeniería civil esto nos ayudaría a revolucionar los diferentes procesos tanto en laboratorio y los diferentes métodos dándonos de esta manera resultados más exactos, confiables y en menor tiempo y costo; dentro de este apartado tenemos también lo que vendría a ser la **justificación teórica** se refiere a explicar las diferentes reseñas de conocimiento. Para poder cumplir con esta justificación teórica se realizó el análisis de diferentes artículos y tesis dentro de las cuales tenemos: “Detección de objetos basados en Deep learning y aplicad a vehículos autónomos”, “sistema automático pata la detección y clasificación de grietas en pavimentos”, “Caracterización del uso de modelos de deterioro para optimizar la gestión del mantenimiento de carreteras , Cajamarca 2020”, “Identificación automática de las grietas en las pistas de asfalto utilizando procesamiento digital de imágenes” , entre otras ; donde se obtuvieron niveles de confiabilidad aceptables; por ultimo tenemos lo que es la **justificación metodológica** Sera cuantitativo ya que se realizarán pruebas para probar una hipótesis. De igual manera según Shim (2020) indica que la técnica de análisis de datos radica en analizar rendimientos, asimismo Opara (2021) detalla que muchos métodos de instrucción profunda fueron hechos para estudiar e identificar

elementos usando variedades de algoritmos. Para esta investigación se tiene como **objetivo general** : Diseñar una red neuronal convolucional para realizar una inspección automatizada de la superficie de pavimento flexible haciendo uso de redes neuronales convolucionales , Juliaca 2023 ; teniendo como **objetivo específico 1:** Determinar las fallas que se encuentran en la superficie del pavimento flexible haciendo uso de las redes neuronales convolucionales , Juliaca 2023; **objetivo específico 2:** Analizar las fallas que se encuentran en la superficie del pavimento flexible con el uso de las redes neuronales convolucionales , Juliaca 2023 ; **objetivo específico 3:** Evaluar los resultados obtenidos de la inspección realizada a la superficie del pavimento flexible usando las redes neuronales convolucionales , Juliaca 2023. La situación actual de la superficie del pavimento flexible se encuentra afectada debido a la presencia de diversas patologías por a un mal diseño o que se haya sobrepasado su vida útil, la variación de climas y el aumento del sector transporte lo cual muchas veces dificulta el procedimiento manual que se hace en su mayoría para la detección de fallas , podríamos automatizar estos procesos con el uso de las redes neuronales convolucionales , para este proyecto de investigación se tiene como **hipótesis general** : Es posible realizar una inspección automatizada de la superficie del pavimento flexible con el uso de redes neuronales convolucionales, Juliaca 2023; se tiene también las siguiente **hipótesis específica 1:** La utilización de redes neuronales convolucionales permite la detección de las diferentes fallas de la superficie del pavimento flexible , Juliaca 2023; **hipótesis específica 2:** Realizar una adecuada inspección de las fallas encontradas en la superficie del pavimento flexible con el uso de las redes neuronales convolucionales, Juliaca 2023; **hipótesis específica 3:** las redes neuronales convolucionales realizan una adecuada validación de datos para poder proceder con un mantenimiento adecuado , Juliaca 2023. Para



esta investigación se examinaron una serie de proyectos de investigación nacionales como internacionales de varias universidades, y los aspectos más destacados los enumeraremos a continuación como son los **antecedentes internacionales:** Arriola(2018) , “Detección de objetos basada en Deep Learning y aplicada a vehículos autónomos” , tuvo como objetivo general analizar, ejecutar y valorar redes neuronales artificiales para la exploración de elementos encontrados en carretera, siendo una investigación experimental , tuvo como conclusión más relevante que la ubicación precisa de los agujeros en el pavimento es un desafío debido a algunos errores de el ground-truth , es así que , el índice de Jaccard se reduce a  $IoU=0,4$  para su evaluación,Entonces , el faster- RCNN Resnet 101 logro un valor de mAP del 82% mientras que Faster-RCNN Inception v2 logro un valor de mAP del 75% con un bajo costo de procesamiento, mostrando así una excelente productividad de detección en grupos de datos mas grandes.Orellana(2022), “Categorización de daños georreferenciados de los ejes viales de la ciudad de Quito-Ecuador , usando algoritmos de inteligencia artificial y Python”, tuvo como objetivo general determinar una categorización de daños georreferenciados en las arterias viales de la ciudad de Quito(Ecuador) usando el algoritmo de inteligencia artificial desarrollada en Python , llegando a la conclusión de que la fiabilidad promedio de la categorización del algoritmo de daños en las carreteras de la ciudad de Quito, utilizando mapas de distribución espacial de las categorías de daños identificados fue de 0.834116667 , siendo esta medida más inmediata de la condición de los clasificadores , como esta en un entre los valores de 0 y 1 y siempre que sea más alto , mejor, se le puede considerar adecuada ; en términos generales se pudo determinar que la ejecución de algoritmos de inteligencia artificial para la detección y evaluación de daños en las carreteras de la ciudad de Quito por parte de la EMOP-Q convertirá esta actividad en

un proceso proactivo , lo que disminuirá los tiempos de respuesta de la EMOP-Q ya que el personal de la organización dejara de depender de las llamadas de los usuarios de las vías y podrá planificar de mejor manera ,tanto su tiempo de acción, como la determinación más eficiente de los presupuestos asignados al mantenimiento de las vías del distrito metropolitano. Madroñero y Valencia(2019),“Metodología para la identificación automática del deterioro en pavimento flexible, por medio de fotografías aéreas tomadas desde vehículos no tripulados”, tuvo como principal objetivo poner en funcionamiento una técnica para seleccionar de manera automatizada las diferentes patologías que se observan en la superficie del pavimento flexible de Cali, usando imágenes obtenidas de vehículos aéreos no tripulados, fue una investigación de tipo básica , llegando a la conclusión más relevante que el algoritmo que demostró una mejor productividad para la selección de las fallas que se encuentran en el pavimento flexible fue una RNA perceptrón multicapa con (10 6 3) de conformación ,entrenada operando el método levenberg marquardt. En el periodo de comprobación de resultados se logró una precisión del 97.63% en lo que son baches y 99.13% en lo que serían grietas. También se obtuvo un porcentaje de acierto del 98.3%. Algunos resultados se vieron afectados por la alta prevalencia de sombreados y áreas húmedas en el asfalto ya que estos inconvenientes producían falsos positivos, resultados en bajos porcentajes de valor predictivo positivo (28.07% y 35.12% en baches y grietas); luego también se analizó la susceptibilidad que demuestra la exactitud de selección del deterioro en el tipo correcto; siendo así 82%para baches y un 70%para grietas. Rodríguez(2020),“Sistema automático para la detección y clasificación de grietas en pavimentos”, tuvo como objetivo general el establecimiento de un sistema que permita la separación de particularidades de defectos en el pavimento haciendo uso del procesamiento de imágenes , por consiguiente se llegó

a la siguiente conclusión la cual se centró en la división de imágenes en grietas tipo malla, grietas, asimismo , en la distinción de las grietas transversales de las longitudinales , así como clasificar también cuando un pavimento se encuentra libre de fallas. Durante el proceso se realizó una disminución de propiedades de ingreso siendo más claras en resolución y ubicación, siendo más cómodo en interpretación a diferencia de otras imágenes. Es de esa manera que se ha logrado demostrar que realizando un ensamblaje de modelos y una simplificación de imágenes se realizan mejores interpretaciones que los individuales. Luego de realizar su investigación descubrió que su métrica de precisión tenía una variación mínima y máxima de 2.4% y 12.6%, y un 1% y 16.4% para la métrica de Recall. Tello, Aguirre ,Diaz y Hernández(2021), “Evaluación de daños en pavimento flexible usando fotogrametría terrestre y redes neuronales”, tuvo como objetivo general describir una técnica que utiliza redes neuronales y fotogrametría terrestre para evaluar los deterioros que se presentan en pavimentos flexibles, tuvo como conclusión más relevante que el desarrollo de esta técnica optimiza el rastreo de fallas en el pavimento flexible lo que ayuda a una mejor toma de decisiones en el mantenimiento vial, dentro de los clasificadores , la que obtuvo un mejor rendimiento para las fallas del pavimento fue una red neuronal perceptrón multicapa que utiliza el entrenamiento de retro propagación de Levenberg Marquardt y la configuración(12 12 3).Esta técnica tuvo 96% de coincidencia , un 93.3% de sensibilidad ,un 0.936 de índice kappa .La piel de cocodrilo y grietas tuvieron una precisión del 100% y un 80% para lo que serían baches.Badr , El gendy y El Refaey (2022), “Uso de redes neurales artificiales para predecir las molestias del pavimento flexible”, tuvo como objetivo general pronosticar las estimaciones del Pavement Condition Index que podían ocurrir posteriormente en el pavimento flexible , fue una investigación de tipo básica , teniendo como conclusión

más relevante que la inteligencia artificial a través del uso de las redes neuronales artificiales para pronosticar las estimaciones del Pavement Condition Index las RNA son capaces de administrar una gran variedad de información haciendo uso del programa denominado Matlab , se obtuvieron resultados del 83% para datos pronosticados en primera categoría y en segunda categoría el 90% de la información pronosticada .Y en un segundo método se obtiene un 91% para los datos pronosticados para el pavimento flexible , concluyendo que el modelo esta técnica logro una buena posibilidad para usarse en la planificación de mantenimientos viales. Seguido de estos antecedentes también se tienen algunos **antecedentes nacionales** que se detallan a continuación: Según León , Alvarado, Arevalo, Maldonado y Polonio (2020), “Detección y extracción de muestras falladas usando visión artificial y un brazo robótico”, tuvo como principal objetivo Sustituir la visión humana por una visión artificial ya que actualmente muchos rubros en el Perú que se desempeñan en lo que es producción de variados productos buscan optimizar sus procedimientos en menos tiempo, concluyéndose que para implementar un software que pueda manipular de manera inteligente un brazo robótico usando una visión artificial para poder hallar la imagen con falla, se aplicó el algoritmo CBIR , de esta manera se resolvió características resaltantes en las imágenes según su clasificación por lo cual se obtuvieron respuestas a favor dentro de los márgenes establecidos obteniendo así errores por niveles de 2.5%,3.59% , 4.65 semejantes a una productividad de 97.5%,96.41% y 95.35% ;de esta manera se demuestra que si se pudo desarrollar un software para poder realizar un control automatizado a partir del algoritmo CBR. Vila (2017),“Análisis del comportamiento lineal de la estructura del pavimento flexible mediante redes neuronales en la panamericana norte”, cuyo objetivo general fue establecer el comportamiento lineal de la conformación del pavimento flexible

haciendo uso de RNA a lo largo de la vía panamericana norte ruta PE1 NL que comprende 1003 km - 1017 km en el año 2010 , fue un estudio de tipo aplicada y de nivel descriptivo, tiene como conclusión más relevante que se elaboró una RNA es apto para realizar pronósticos de módulos de elasticidad para pavimento flexible de 3 a 4 capas con muy elevados rangos de exactitud y mínimo costo .El modelo de entrenamiento fue el reforzado ya que muestra ser más eficaz tanto en exactitud como en tiempo, se encuentra que los parámetros de ingreso a la RNA se detallan en sectores como: el sector 4 muestra datos por debajo del módulo elástico como vendrían a ser 16717.02 MPa y 17481.10 MPa adquirido por el programa MichBack y RNA ,los datos adquiridos para base granular en el sector 3 obtuvo las puntuaciones más altas de 602.62 y 597.19MPa adquirido por el programa MichBack y RNA , para base subbase granular se obtiene que en el sector 1 muestra las puntuaciones más altas de 80.76 MPa y 75.29 MPa adquiridos por el programa MichBack y RNA , para subrasante se obtiene que en el sector 5 las puntuaciones son 289.38 y 294.85MPa adquiridos por el programa MichBack y RNA ;todas las puntuaciones obtenidas tiene relación a las puntuaciones ya obtenidas por el plan CVS (231 MPa) ya que nos demuestra que la red neural es una alternativa muy verídica y exacta.Murrugarra y Ruiz (2020), “Caracterización del uso de modelos de deterioro para optimizar la gestión del mantenimiento de carreteras, Cajamarca 2020”, tuvo como objetivo general determinar el manejo de los tipos de fallas para mejorar la administración de la gestión de mantenimientos de carreteras de Cajamarca, siendo un estudio descriptivo y de diseño de tipo no experimental, donde su conclusión más relevante fue que se determinó el manejo de patrones de deterioro, por medio de la hoja de datos de recolección , donde se concluye que el más resaltante es el de Cadenas de Márkov, porque este tiene mayor eficacia de un 37.5 %en redes vecinales , aplicando

a pavimentos flexibles, rígidos y mixtos , donde también engloba una mayor distancia de vía (480Km) , haciendo uso de evaluación como son el PCI y el índice de rugosidad en todas las investigaciones por sus niveles de confiabilidad , se pueden efectuar valoraciones económicas ; este modelo alcanzo un puntaje de 63 tomando en cuenta las condiciones de las vías de Cajamarca. Ignacio (2022), "Identificación automática de las grietas en pistas de asfalto utilizando procesamiento digital de imágenes" , tuvo como objetivo general ejecutar la detección automatizada de fallas en carreteras de pavimento flexible haciendo uso de procesadores digitales de imágenes, fue una investigación cuantitativa de tipo cuasi experimental , en esta investigación se tuvo como conclusión más relevante que la elaboración de un brazo mecánico fue indispensable para la captación de imágenes con las fallas en las pistas de asfalto evaluadas realizando una buena focalización de imágenes para facilitar de esta manera la visualización de fallas en el pavimento , se desarrolló la investigación apoyándose en un tipo de programación como es Python, dicha programación viene ganando acogida en lo que es la evaluación de datos ;el uso de algoritmos de redes neuronales convolucionales demostró tener un buen funcionamiento en la detección de grietas logrando alcanzar en esta investigación con el uso de las redes neuronales convolucionales un 98% de confiabilidad en un tiempo de 84 segundos.

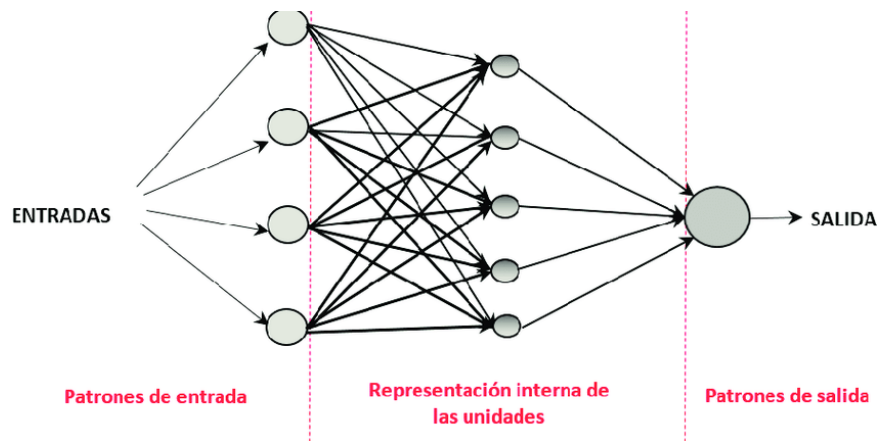
Paytán (2018), "Estimación del índice de regularidad internacional en pavimentos flexibles usando redes neuronales artificiales", tuvo como objetivo general Establecer de qué manera se diferencia la estimación del IRI de la carretera PE-1S evaluado través de un proyecto de RNA de un valor extraído a través del Perfilómetro Láser , su estudio fue de tipo aplicada de nivel descriptivo, cuya conclusión más relevante fue que después de realizar un estudio de parentesco entre cada uno de las fallas del pavimento y el IRI se llegó a la conclusión de usar información del modelo neuronal

donde los que presentaron mayor incidencia fueron un total de 10 , el modelo de entrenamiento usado para este modelo de entrenamiento fue Levenberg-Marquardt y el proceso de activación la sigmoide tangente hiperbólica; en el punto de entrenamiento (red 03-07)el cual se utilizó para evaluar los datos del IRI ,haciendo uso de información variada a la utilizada al inicio del entrenamiento ,al comparar los resultados con el perfilómetro laser , obtuvo  $R=0.365513$  en el coeficiente de correlación, evidenciando así una nula coherencia entre los datos , lo que refleja que las RNA no mantuvieron un buen comportamiento , llegando de esta manera a la conclusión de rechazar la hipótesis y aceptar una hipótesis nula. Zúñiga (2022), “Deep Learning para la detección de fallas en pavimento de la zona del distrito de Villa María del Triunfo 2022” , tuvo como objetivo primordial Establecer a través del uso del Deep Learning la exploración de patologías que se encuentran en las vías asfaltadas de José Carlos Mariátegui del distrito de Villa María del Triunfo, fue un estudio de tipo aplicada con un enfoque cuantitativo, llegando a la conclusión más relevante de que los datos hallados fueron adecuados para la exploración de fallas en pavimentos Fan (2020) , se alcanzó una exactitud de 0.19-0.92, alcanzando en recall 0.67-0.93 entre tanto que F1 llega a 0.28-0.92 en fotografías de 768x512 , 991x462 ,311x462 px ;en este estudio se logró alcanzar niveles de 0.32-0.85 con fotografías de 1920x1080px haciendo uso de YOLOv5 ya que es un mejor modelo en el estudio de fallas en pavimentos , se usó también de una red neuronal con elevado entrenamiento para de esa manera tener una mejor confiabilidad . Ortega(2021), “Software para la evaluación superficial de pavimentos flexibles basado en la metodología Pavement Condition Index”, tuvo como objetivo general crear un programa de escritorio que gira en torno a la evaluación por método PCI para el estudio superficial de pavimento flexible en carreteras dentro de la ciudad, fue un estudio de tipo aplicada con enfoque

cuantitativo , llegando a la conclusión más relevante de que al ejecutar un procedimiento de administración de pavimentos urbanos, el programa nos da como solución las estimaciones del PCI ya evaluados en campo , se alcanzó una validación de las soluciones dadas por el programa ,dando como resultado 0.9991 de correlación de Pearson(r) en un primer inicio y 0.998 en un segundo inicio ,estos datos son apreciados como una concordancia positiva de muy alto nivel según la teoría ; de igual manera utilizando los coeficientes de determinación se concluyó que el 99.8% fue el porcentaje asignado a la variabilidad de la primera sección y de 99.5% el porcentaje de la segunda sección, evidenciando de esta manera que el programa PAVDO es novedoso y beneficioso en todo el mundo de la ingeniería civil. Primero, antes de iniciar con lo que son las redes neuronales convolucionales, debemos de iniciar con lo que vendría a ser la **Inteligencia artificial**, según Llopis (2020) Aunque no existe una definición clara de este concepto, podemos decir que la IA es la mezcla de algoritmos (una secuencia de pasos ordenados para realizar una tarea) con el objetivo de crear algunas máquinas con las iguales o mejores competencias que los humanos. Además, encontró que el aprendizaje automatizado es una tecnología de IA fundamentada en algoritmos de aprendizaje que permite a las máquinas aprender a realizar acciones específicas para luego realizarlas de forma automática. De acuerdo a la manera en la que se efectúe el aprendizaje automático, podemos distinguir entre aprendizaje supervisado y aprendizaje no supervisado. En el primer caso, el usuario debe decirle a la máquina si lo que hace es bueno o malo, mientras que, en el segundo caso, la propia máquina debe aprender a detectar lo que hace bien y mal, en función del rendimiento de la máquina; dentro de este podemos mencionar primero a **Machine learning** o también llamado aprendizaje automático es lo que vendría a ser un modelo de inteligencia artificial que se basa el algoritmo de




aprendizaje que permite a una maquina instruirse a formular algunas acciones para después realizarlos de manera automática. Tenemos dos tipos como la instrucción supervisada y la no supervisada donde en la primera es el usuario quien le indica a la maquina si lo que se viene realizando está mal o bien, mientras tanto en el segundo es la maquina quien tiene que realizar los calificativos de acuerdo a las normas y segundo al **Deep learning** que es una inteligencia artificial profunda que se basa en redes neuronales que tiene como objetivo tratar altas cantidades de datos en un menor tiempo. Se dice que estas redes son de más profundidad ya que se encuentran compuestas por cantidad de capas de información , entonces de esta manera podemos concluir lo que son las **redes neuronales artificiales** Una RNA puede denominarse un método de instrucción automática que simula el cerebro humano y consta de múltiples neuronas artificiales. Cada neurona en una RNA recibe múltiples entradas y utiliza una función de activación a estas entradas, lo que da como resultado el nivel de aplicación de la neurona. Las redes neuronales son adaptativas; pueden inferir soluciones a partir de los datos que se les proporcionan, y a menudo capturan relaciones muy sutiles. Las redes neuronales artificiales pueden generalizar correctamente datos que son muy similares a los datos con los que fueron entrenadas originalmente. Además, pueden manejar datos imperfectos o incompletos, proporcionando tolerancia a fallos ( Badr , El gendy y El Refaey ,2022)



**Figura 1.** Red Neuronal Artificial (RNA) de Tres Capas Interconectadas

Fuente: Issasy y Galván, 2004

Ya teniendo en cuenta las bases teóricas antes mencionadas podemos deducir que una **Red neuronal convolucional** o CNN se usa para principalmente procesar imágenes para así poder categorizar, reconocer objetos. También son muy eficaces para la detección de datos de audio, señales y serie; está formado por una capa de entrada, otra de salida y varias capas de entradas en entre ellas, estas capas forman operaciones que causan variación en los datos con el fin de entender sus características particulares; Según Calvo( 2017) En el proceso de convolución se efectúan operaciones entre la capa de partida y los diversos filtros (o kernel) que origina un plano de particularidades. Las particularidades separadas pertenecen a cierta ubicación factible del filtro en la fotografía original, También indica que en la disminución se reduce un total de indicadores al permanecer con las cualidades más generales y finalmente en el término de las capas con volucionales se utilizaran capas totalmente conectadas en la que cada uno de los pixeles se llegaran a considerar como neurona separada, así como un perceptrón multicapa.



**Figura 2.** Red Neuronal Convolutacional

Fuente: Yangyan, 2015

**Tabla 1 .**Similitud de los Modelos de Inteligencia Artificial

TECNICA IA	VENTAJAS	DESVENTAJAS
Sistemas difusos (Abdullah y Nezhad 2014) (Lim et al., 2015)	<ul style="list-style-type: none"> <li>• Esto se hace mediante el manejo de esquemas de lenguaje original que simulan el habla humana y la normalización de modelos difusos los hace prácticos y sencillos de aplicar.</li> <li>• Uniformidad de clasificación de sistemas con enormes cambios como imágenes donde las categorías son limitadas.</li> </ul>	<ul style="list-style-type: none"> <li>• Los problemas son difíciles de definir con precisión utilizando etiquetas y atributos, a menudo definidos por las personas desde su propia perspectiva, lo que crea espacio para la subjetividad.</li> <li>• Debido a la función, no se recomienda su uso en sistemas de alta precisión, porque los resultados dependen de los valores de pertenencia de la función parametrizada en</li> </ul>

---

Red neuronal MLP  
(Cristea et al. 2016) (Jani  
et al., 2017)

- Rápida velocidad de aprendizaje y alta tasa de éxito.
- Las capacidades de procesamiento lo convierten en un método muy útil y de respuesta rápida.
- Las redes neuronales MLP son sencillas de incorporar en comparación con otras técnicas de inteligencia artificial e incluso con otro tipo de redes neuronales.

sistemas lingüísticos no numéricos.

- Deben recibir capacitación periódicamente para evitar la pérdida de precisión debido a los cambios normales del sistema a lo largo del tiempo.
- Cuanto mayor sea el rango, será más los datos representativos que se necesitarán para determinar las pendientes de separación.

Red neuronal convolucional  
(Galdámez et al., 2017)  
(Cao et al., 2017)

- La red está diseñada específicamente para el procesamiento de imágenes, ya que sus operaciones 2D permiten la extracción de características globales en una fotografía utilizando varias matrices de filtros.
- Fuerte conocimiento ante cambios de imagen ya que el

- Largos periodos de entrenamiento.
- La calidad del reconocimiento depende del tamaño de la biblioteca de ilustraciones usada para el entrenamiento.
- El sistema es computacionalmente costoso porque se utilizan convoluciones matriciales.

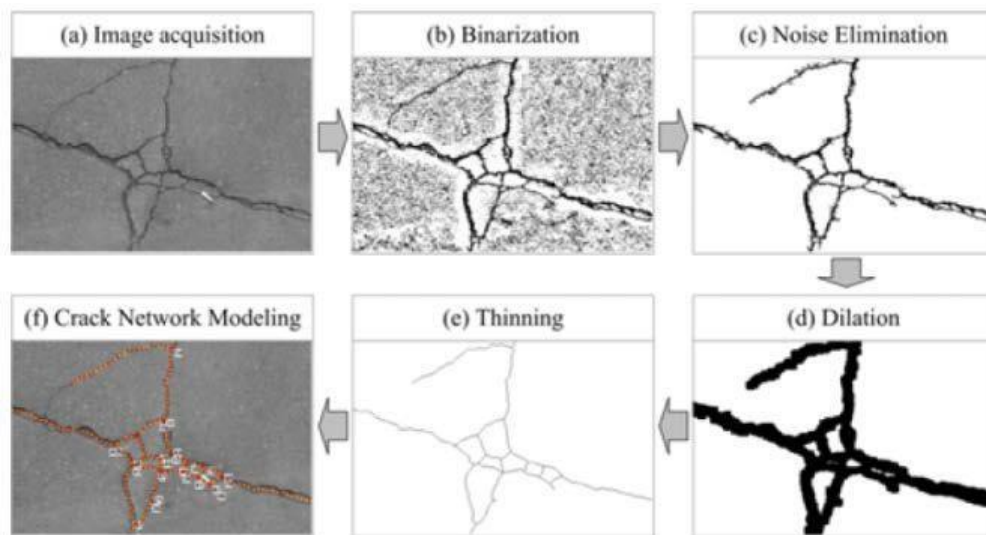
---

	desarrollo de algoritmos de Deep learning permite que la red aprenda varias categorías de presentación.	
Inteligencia de enjambre (Colonia de abejas) (Cui et al. 2017) (Banitalebi et al., 2015)	<ul style="list-style-type: none"> <li>• Soluciones de sistema integradas rápidas con alta flexibilidad.</li> <li>• Esta técnica usa mínimos parámetros de configuración.</li> </ul>	<ul style="list-style-type: none"> <li>• A veces hay una mejor solución entre las soluciones locales a las que converge el algoritmo, por lo que se debe usar uno de búsqueda global externo para encontrar la mejor solución.</li> </ul>
Sistema inmune artificial (Bayar et al., 2015) (Costa et al., 2017)	<ul style="list-style-type: none"> <li>• Gran capacidad para explorar soluciones para optimizar mejor las tareas.</li> <li>• En comparación con otros métodos de IA que no tienen capacidades de aprendizaje autónomo, tiene capacidades de autoaprendizaje estructuradas, profundas y simples.</li> </ul>	<ul style="list-style-type: none"> <li>• Necesita un amplio desarrollo de programación inicial para poder organizar sus operaciones y capas.</li> <li>• Su principal ventaja proviene de procesos estocásticos, lo que en principio reduce la robustez de la implementación.</li> </ul>

---

Fuente: Elaboración propia

Teniendo en cuenta los conceptos anteriores existe hoy en día diferentes aplicaciones de la inteligencia artificial en la elaboración digital de fotografías en pavimentos en tiempo y costo los procedimientos que se vienen realizando de manera manual por lo que su uso viene aumentando en el ámbito de la ingeniería Civil (Shafabakhsh ,2015). Se utiliza para realizar predicción en comportamiento de material, en pruebas de laboratorio minimizando tiempos de análisis obteniendo así altas tasas de éxito.




**Figura 3.** Algoritmo ACSTM

Fuente: Yoo y Kim, 2016

Como se detalla líneas atrás el uso de redes convolucionales tiene un gran aporte en lo que sería la detección de fallas en el pavimento donde un **pavimento** es una estructura constituida por capas superpuestas sobre un terreno ya preparado que tiene como principal función brindar confort al usuario; podemos mencionar los tipos de pavimento existentes en la actualidad los cuales son pavimento rígido , flexible y articulado ; en este proyecto de investigación pondremos un especial énfasis en lo que es el **pavimento flexible** ,el cual es un pavimento que se encuentra formado por

una carpeta asfáltica la cual debe distribuir las cargas de la superficie, estando conformado por una capa de rodadura, base y subbase .



**Figura 4.** Partes de un Pavimento Flexible


Fuente: La Librería del Ingeniero, 2023

A lo largo de las vías , el pavimento flexible ya sea por aumento en el tráfico vehicular , por la variación de climas y por quizá malos mantenimientos realizados durante su periodo de vida llegan a presentar anomalías o fallas las cuales causan dificultad en el buen transito de transporte y peatonal .Tenemos dos tipos de Fallas:fallas funcionales y fallas estructurales donde se podría decir que las **fallas funcionales** son las de menos intensidad, como cuando empieza a presentar algunas deficiencias en su buen funcionamiento ya que en algunos casos solo presenta deficiencias en la capa superficial de un pavimento; Siendo el caso de las **fallas estructurales** es donde se ven anomalías de mayor intensidad y compromete a más de una de las capas superpuestas del pavimento, afectando así en gran magnitud al pavimento; Entre las principales anomalías tenemos: deformaciones , agrietamiento, anomalías de superficie y anomalías de borde ; donde podemos visualizar que en una deformación se tiene lo que serían las **depresiones** que se forman por hundimientos del terreno o

por una mala construcción de las capas superiores de la calzada, creando un cierto desnivel que en ocasiones puede provocar deslizamientos cuando se encuentran profundos y llenos de agua(Corredor y Coros , 2010) , dentro de este también tenemos lo que son los **ahuellamientos** que se trata del desgaste por niveles de la capa de rodadura y se muestra como un hundimiento debajo de las bandas de tránsito; también tenemos a lo que serían los **desplazamientos y hundimientos** que son desplazamientos hacia la parte superior o inferior ya sea en gran o pequeña magnitud causando así variaciones en el pavimento. También tenemos lo que vendrían a ser los agrietamientos , dentro de estos tenemos a lo que denominamos **Piel de cocodrilo**, o agrietamiento por fatiga son un conjunto de fisuras interconectadas causada por la fatiga de la capa de rodadura del pavimento, carga o tráfico; también tenemos lo que son **Fisuras longitudinales**, son fisuras de cierta magnitud, predominante en el eje de la calzada que se manifiesta en una superficie de la estructura; **Fisuras transversales**, son las que atraviesan el pavimento en manera vertical a la línea central; **Fisuras en bloque**, mayormente nos indican que el asfalto se ha endurecido considerablemente, las fisuras en bloque generalmente pasan sobre un tramo largo de pavimento; Fisuras en diagonal ;Fisuras zigzagueantes . También encontramos lo que son defectos superficiales como es la **Exudación** que es una capa delgada de componente asfáltico que se expande en áreas determinadas del pavimento formando así una superficie brillante que a menudo se vuelve pegajosa; luego lo que es el **Desprendimiento** que se debe a la pérdida de material de la capa de rodadura de la superficie del pavimento y la descamación del asfalto del pavimento, afectando la calidad y el transporte ; también los **Baches** que son pequeños huecos en las superficies del pavimento; y por último dentro de estos tenemos a lo que es el **Parque** que es una determinada zona del perímetro de la



superficie de la superficie de rodadura del pavimento que se encuentra en mal estado y ha sido mejorada el cual causa una disminución en el nivel de servicio. Dentro de toda esta clasificación también tenemos los **defectos de borde** donde encontramos lo que sería **Rotura de borde** que son grietas paralelas que se ubican en el borde exterior del pavimento, aumentando por la excesiva carga de tráfico dañando de esa manera la estructura del pavimento; **Descenso**, son producidos por aumento del peso de tráfico.



**Figura 5.** Ejemplos de Fallas en Pavimento Flexible

Fuente: David Llopis, 2020

Los diferentes tipos de falla ya mencionados conlleva a realizar un adecuado estudio de estas para poder realizar los diferentes tipos de mantenimiento de acuerdo a la magnitud de las fallas, podemos decir que es un **mantenimiento del pavimento** se llama así al conjunto de acciones que se desarrollan para preservar en un estado aceptable la situación de una vía para de esa manera asegurar que el transporte pueda llevarse a cabo de manera cómoda y segura. Lo que se busca es que la

inversión pueda perdurar a través del tiempo dentro de los parámetros ya establecidos y evitar su deterioro prematuro .Los mantenimientos se clasifican por la constancia con la que se repiten , pueden ser clasificados en rutinarios y periódicos , donde los rutinarios vienen a ser los que se realizan de manera continua en variados tramos de carretera y las que son periódicas son las que se llevan a cabo en lapsos de tiempo más extensos como pueden ser de varios meses o años. (Ministerio de Transporte y Comunicaciones Republica del Perú, 2006)



**Figura 6.** *Mantenimiento de una Vía*

Fuente: Misión Venezuela Bella, 2020

## II. METODOLOGIA

**Tipo y diseño de investigación;** Desarrollando primero lo que es el Tipo de Investigación; Para este proyecto de investigación se propone una investigación de tipo aplicada ya que está orientada a la solución de problemas prácticos, dentro de nuestro proyecto de investigación se busca lograr la automatización y optimización de la realización de evaluación del pavimento flexible. “Una investigación aplicada es una solución eficiente y con fundamentos a un problema que se ha identificado” Ander-Egg( 2011).

**Diseño de Investigación ;** Se propone un diseño de investigación de tipo pre experimental, ya que tiene su fundamento en la gestión activa y control del sistema, debido a que estaremos de manera constante con la manipulación de imágenes y realizando un control de las capas convolucionales. Donde no elegiremos nuestra muestra al azar sino de acuerdo a ciertas cualidades definidas para de esa manera poder realizar una adecuada evaluación.

Se propone un **enfoque de investigación cuantitativa ;** ya que según Hernández, Fernández y Baptista (2006) indica que los métodos cuantitativos se dedican a la utilización de la recolección de información para comprobar unas hipótesis basándose en lo que son los diferentes cálculos y evaluaciones estadísticas para reconocer modelos de conductas y demostrar teorías; lo que queremos realizar es demostrar que se puede realizar evaluaciones de la superficie del pavimento flexible en menor tiempo y menor costo.

Para este proyecto de investigación se propone un **nivel de investigación** de tipo **descriptivo**, según Guillen Valle y otros (2020) una investigación de tipo descriptivo es una de las investigaciones más usadas ya que se encargan de mostrar, distinguir, reconocer acontecimientos, peculiaridades de determinados objetos de evaluación, logrando dar un diagnóstico o diseñando determinados prototipos o modelos; pero no se brinda explicación acerca de los acontecimientos o fenómenos. En este proyecto de investigación como es la inspección automatizada de la superficie del pavimento flexible con el uso de redes neuronales convolucionales, Juliaca 2023 se busca el diseño de una red neuronal capaz de realizar inspecciones de manera automática a través del entrenamiento de las redes neuronales a determinadas imágenes de las diferentes fallas encontradas.

**Variables y operacionalización;** Tendremos para este proyecto de investigación como **variable independiente** establecido las redes neuronales convolucionales CNN. **Definición conceptual;** Debido al aumento de costos en rehabilitaciones, mantenimientos y ejecución de vías, analizar las estructuras y superficie del pavimento para de esa manera precisar su propio comportamiento y sus particularidades propias es que la inteligencia artificial se ha vuelto un ámbito de mucha relevancia en la ingeniería civil, para el análisis de estas imágenes se vienen desarrollando herramientas que ayudan a la simplificación de estos trabajos y así poder automatizarlos en gran escala causando así mayor velocidad en entrega de resultados y menor costo. (Reyes, Mejía y Useche, 2019). **Definición operacional;** Una red neuronal convolucional consta de variables capas de filtros en o más dimensiones. Después de cada status, en su mayoría se inserta una función para de esa manera lograr un mapeo, en la red de clasificación primero se tendrá una fase de

extracción que tiene neuronas de convolución y neuronas de reducción de resolución. Finalmente encontraremos una neurona perceptrón simple que realiza la categorización final de las particularidades extraídas. Esta fase consta de capas alternas de convolución y neuronas de reducción de resolución. Mientras estos datos avanzan a través de esta fase, su dimensionalidad disminuye y las neuronas en capas distantes disminuyen su sensibilidad a las alteraciones en la información de entrada, pero de igual manera se activan por propiedades cada vez más profundas y complejas. **Dimensiones:** Algoritmo de red neuronal convolucional para el entrenamiento automatizado; Indicadores: instrucción automatizada, variedad de capas, datos (imágenes), modelos, efectos, efectos futuros, algoritmos. **Escala de medición,** en este proyecto de investigación se quiere lograr la correcta programación de acuerdo a las diferentes imágenes evaluadas, se considera que se tiene como escala de medición **ordinal** ya que lo que se quiere es categorizar.

Tendremos establecido como **variable dependiente** en este proyecto de investigación a el **pavimento flexible** ; **Definición conceptual;** Lo importante de las propiedades de la superficie del pavimento flexible radica sobre todo en su influencia en el correcto funcionamiento, conformando así las únicas propiedades de interés para el usuario, ya que debido a ellas dependen en gran parte la seguridad y el confort necesario para el área usuaria, de manera estética también hay un impacto en el entorno urbano afectando de esta manera a los peatones y también a los residentes (Menéndez, 2012, p. 271). **Definición operacional;** Las diferentes fallas a encontrar en la superficie del pavimento flexible se determinarán a través de su profundidad y longitud, estas fallas son causadas por el aumento de tráfico, condiciones climáticas, procesos constructivos o también malos mantenimientos anteriores. **Dimensión;** Se

tendrá como dimensiones a la identificación y selección de fallas en la superficie del pavimento flexible. **Indicadores:** Se tendrán indicadores como: tipo de daño, severidad, medidas. **Escala de medición,** Para este proyecto de investigación se propone una escala de medición **nominal** ya que se procederá a detectar y seleccionar las imágenes con las diferentes fallas encontradas de acuerdo a sus diferentes características.

**Población y muestra; Población ;** Según Tamayo (2015), “es el total de una investigación, comprende todas las unidades de estudio o casos de la población que tengan el mismo fenómeno”. De igual manera tendremos para nuestro proyecto de investigación como población las principales salidas de la ciudad de Juliaca. La ciudad de Juliaca actualmente cuenta con una cantidad total de 180km de pavimento asfáltico siendo conformando el 60% de la superficie vial de la ciudad.

**Tabla 2.** *Cantidad de Kilómetros Asfaltados por Zona*

<b>ZONA</b>	<b>CANTIDAD DE KM ASFALTADOS</b>
<b>URBANA</b>	120
<b>PERIFERICA</b>	60
<b>RURAL</b>	0

Fuente: Elaboración propia


**Criterio de Inclusión;** se refiere a la referencia en particular que debe de poseer nuestra muestra para así poder ser considerada como tal. **Criterio de Exclusión;** hace referencia a ciertas particularidades que no deberían de estar presente en nuestra muestra para de esa manera ser seleccionada.

**Muestra;** Según Vara (2015), la muestra es un grupo de hechos los cuales se extraen de la población haciendo uso de una técnica racional. Se tendrá para este proyecto de investigación como muestra las principales salidas de la ciudad de Juliaca ya que con el transcurrir del tiempo y el incremento de carga de tráfico vienen presentando una cantidad innumerable de fallas a lo largo de estas vías, como son, la Salida a Arequipa, salida a Puno, Salida Huancané, Salida Cusco, Salida a Lampa.

**Tabla 3 . Medidas de las principales vías de la Ciudad de Juliaca**

<b>EJE</b>	<b>VIA</b>	<b>LONGITUD</b>
<b>SALIDA A PUNO</b>	Jr. M. Núñez Butron	650.00 m
	Jr. Noriega	350.00 m
	Jr. M. Núñez Butron	400.00 m
	Av.4 de noviembre	5000.00 m
<b>SALIDA A CUSCO</b>	Jr. M. Núñez Butron	1050.00 m
	Av. Independencia	2000.00 m
<b>SALIDA A HUANCANE</b>	Jr. Lambayeque - E. Cáceres	1150.00 m
	Av. Huancané	2000.00 m
<b>SALIDA A AREQUIPA</b>	Jr. Sandia – Av. R. Palma	650.00m
	Av. José Olaya	500.00m
	Av. Héroes de la Guerra del Pacifico	1800.00m
<b>SALIDA A LAMPA</b>	<i>Av. Nueva Zelanda</i>	<i>1200.00m</i>
	<i>Av. Lampa</i>	<i>1250.00m</i>

Fuente: Municipalidad Provincial de San Román



**Figura 7.** Sistema Vial de la Ciudad de Juliaca

Fuente: Municipalidad Provincial de San Román

**Muestreo;** Tendremos el tipo de muestreo no probabilístico ya que elegiremos a nuestro criterio la avenida con mayores fallas superficiales en su trayecto, siendo esta la Salida a Arequipa donde tomaremos la Avenida Héroes de la Guerra del pacifico la cual también forma parte de la red vial nacional PE-34A contando con una longitud total de 10km, cuenta también con una sección transversal de 22 metros, con dos carriles por sentido de circulación. La calzada tiene un ancho de 7 metros por carril, y las bermas tienen un ancho de 2 metros. Se propone utilizar un muestreo por juicio ya que elegimos los tramos a evaluar de dicha avenida las cuales comprende de inicio el jirón mi Perú con la Avenida héroes de la guerra del pacifico progresiva 0+584 y finalizaremos en la institución educativa central Esquen con la avenida Héroes de la Guerra del Pacifico progresiva 4+250.





**Figura 8.** *Jirón mi Perú con la Av. héroes de la guerra del pacifico progresiva 0+584*

Fuente: Google maps




**Figura 9.** *I.E. central Esquen con la av. Héroes de la Guerra del Pacífico progresiva 4+250.*

Fuente: Google maps

**Unidad de Análisis;** Según Hernández (2012), Para poder indicar esto a algunos que usaran ciertos instrumentos de medición para así realizar el análisis de datos. Siendo en este caso la Unidad de análisis las fallas de la superficie del pavimento flexible.

**Técnicas e instrumentos de recolección de datos;** La técnica de investigación son los procedimientos que se realizaran para poder reunir la información o datos con un fin específico, para este proyecto de investigación se propone la observación de campo ya que realizaremos un determinado protocolo de observación , los instrumentos , estos vienen a ser las herramientas que nos ayudaran a una buena y organizada recolección de información brindando de esa manera confiabilidad en la información recolectada que seguidamente será procesada en un determinado sistema computacional , en este proyecto de investigación se propone utilizar como instrumentos un teléfono inteligente para la obtención de imágenes en muy buena resolución, así como también diferentes focos de iluminación para garantizar así la variedad y dificultad de las diferentes fallas en la superficie del pavimento para su posterior procesamiento. **Validez** , es el procedimiento en el cual un proceso de recopilación de datos realiza la medición de lo que tenga que medir a ese procedimiento se le denomina **validez** , el procedimiento de validación se realiza con el único fin de brindar objetividad a la investigación.**Confiabilidad**, viene a ser el procedimiento en el cual se tiene como objetivo la disminución de errores y sesgos de la investigación, ya que garantiza los resultados y mediciones precisas.

**Métodos para el Análisis de Datos;** La parte más importante de este proyecto de investigación sería la correcta toma de imágenes y para ello es necesario explicar el procesamiento de las imágenes a través de redes neuronales convolucionales es por eso que se seleccionaran las imágenes en un mismo tamaño para poder facilitar el proceso de selección , el proceso se tendrá que realizar en áreas exactas donde se encuentran las fallas o grietas en la superficie del pavimento , la recolección de imágenes se realizara mediante un teléfono inteligente con el cual primero tendremos que realizar grabaciones en diferentes tiempos como son en la mañana y al atardecer para poder captar imágenes con distintos tonos de luz ya que esto nos ayudara a realizar una mejor clasificación de nuestras imágenes y también un mejor procesamiento de estas con ayuda de la red neuronal convolucional.



**Figura 10.** Red Neuronal Convolucional con tres Diferentes Secciones de Extracción de Características

Fuente: López Saca, 2019

Para este proyecto de investigación se realizará: Primero realizaremos la identificación del tramo que tenga mayor cantidad de fallas o grietas en la superficie del pavimento flexible, luego se procederá con la utilización de un teléfono inteligente para poder realizar la toma de videos y realizar así la clasificación de imágenes y proceder así con el etiquetado y agrupamiento de las imágenes obtenidas por la diversidad de formas y tamaños de las fallas a encontrar en el trayecto de la salida Juliaca a Arequipa. Una vez realizado todo este proceso las imágenes serán cargadas al centro de procesamiento donde se procesarán las imágenes a través de técnicas de aprendizaje profundo, donde se procederá con el entrenamiento de manera secuencial y de esta manera poder llegar a detectar los tipos de grietas aplicando los modelos con las diferentes imágenes q se sumarán al sistema.




**Figura 11.** Esquema de Proceso a Realizar

Fuente: *Elaboración Propia*

Como se explica en la Figura N°11 se procedió con el desarrollo de un esquema sobre procedimiento a realizar dividido en tres etapas como son la obtención de imágenes, filtrado de imágenes y el entrenamiento de la red neuronal convolucional las cuales representan a los objetivos específicos propuestos para esta investigación y las cuales se procede a desarrollar a continuación:

**OBJETIVO ESPECIFICO 1: “Determinar las fallas que se encuentran en la superficie del pavimento flexible haciendo uso de redes neuronales convolucionales, Juliaca 2023”;** para el desarrollo de este objetivo se realizó la ejecución de dos puntos importantes como son la ubicación del tramo a evaluar, la toma del video y obtención de fotogramas los cuales detallamos a continuación:

**Ubicación del tramo a evaluar;** La ubicación de nuestro tramo a evaluar posee una extensión de 3670 metros , iniciándose en el Jirón Mi Perú con la Avenida héroes del pacifico progresiva 0+584 y concluyendo en la avenida Héroes del Pacifico progresiva 4+250 (I.E. Central Esquén) de la ciudad de Juliaca ubicada a 3824 m.s.n.m. ; la toma de videos se realizó en diferentes horarios del día para así poder captar imágenes con distintos tonos de luz ; Se realizó la toma de video de las diferentes fallas a encontrar a lo largo de la avenida Héroes de la Guerra del Pacifico , esta toma de vídeo para posterior obtención de fotogramas deberá realizarse de manera exacta en los diferentes lugares donde se encuentren las diferentes fallas a lo largo de todo el tramo pre seleccionado como se muestra en la Figura N°12 para la realización de este trabajo de investigación.




**Figura 12.** Ubicación del Tramo Evaluado de la Ciudad de Juliaca, Iniciando en el Jirón Mi Perú y concluyendo en la escuelita Esquen

Fuente: Elaboración Propia

**Toma de video y obtención de imágenes:** Se realizó la toma de imágenes con ayuda de un trípode que será utilizado como brazo, el cual consta de un banco para lograr estabilidad y así evitar se tengan muchas variaciones en la toma de video o muestra ya que el pavimento presenta innumerables fallas a lo largo de su trayecto y

así también evitar posibles caídas del celular inteligente también se utilizó un trípode para usarlo como soporte de nuestro teléfono celular a una altura de 1.60mts como se muestra en la Figura N°13 , se realizó todo el recorrido con una velocidad que estuvo variando de entre 25-30 km/h para de esa manera obtener un buen campo de visualización dentro de un área no controlada.



**Figura 13.** *Esquema de Captura de Imágenes del Pavimento Flexible*

Fuente: elaboración propia

Una vez realizado el ensamble de estos se procedió la toma del video de las diferentes fallas que se pusieran encontrar en la superficie del pavimento flexible de nuestra vía ya elegida, seguido de esto se realiza la colocación del celular inteligente para de esta manera proceder con la toma del video, para este fin se utilizó un celular inteligente de la marca Xiaomi C10 que cuenta con una cámara de video de 1080p y 30 fotogramas por segundo (fps) además de contar con GPS como se puede visualizar en la figura N°13 , el teléfono inteligente se ubicó haciendo uso de un trípode en la parte trasera de la camioneta para así realizar la toma de imágenes con seguridad y evitar cualquier tipo de incidente que pueda ocurrir a lo largo de la vía a evaluar .






**Figura 14.** *Detalle de cámara de teléfono inteligente*

Fuente: Elaboración Propia

Se utilizó también el aplicativo AutoGuard Dash Cam-Blackbox que es de descarga gratis en el App Store como se muestra en la Figura N°15 de fácil acceso y uso, se encuentra libre de descarga en la app Store el cual nos permitió realizar la toma de imágenes georreferenciadas y sin sonido ya que esto nos ayudara a obtener nuestros fotogramas en mejor calidad, la toma de videos se tomaron en diferentes horarios para de esa manera evitar tener alguna dificultad con la toma de imágenes ya sea por la variación de sombras o la diversidad de tonalidades con las que se pudieran

obtener , ya que las imágenes obtenidas tendrán que pasar por un proceso de clasificación para su posterior procesamiento .



**Figura 15.** Recorrido de Cámara en la Toma de Imágenes para Posterior Procesamiento

Fuente: Elaboración Propia

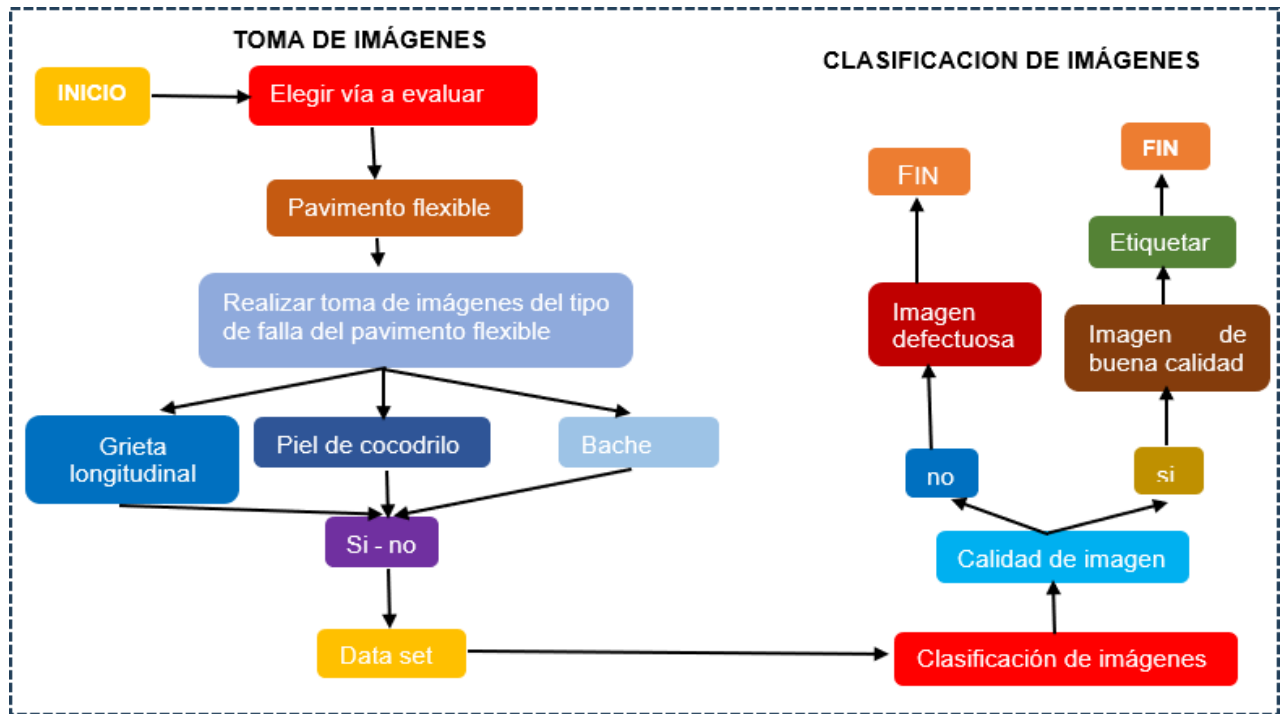
**OBJETIVO ESPECIFICO 2:** “Analizar las fallas que se encuentran en la superficie del pavimento flexible con el uso de las redes neuronales convolucionales, Juliaca 2023”; Para la realización de este objetivo se realizó una serie de pasos, como son el procesamiento, el filtrado y el etiquetado de las imágenes obtenidas como se muestra en la Figura N°16 , para posteriormente ser cargadas al centro de procesamiento donde se clasificarán las imágenes a través de diversas técnicas de aprendizaje profundo que vendría a ser nuestra red neuronal convolucional, donde se procederá a entrenar de manera secuencial de acuerdo a los diferentes tipos para de esa manera lograr realizar una clasificación correcta de los diferentes tipos de fallas aplicando los modelos con las diferentes imágenes que se cargaran al sistema.



**Figura 16.** *Etapas de la Obtención de Imágenes*

*Fuente:* Elaboración Propia


**Procesamiento de imágenes;** Se realizó la toma de video en diferentes horarios para evitar obtener imágenes con alguna deficiencia en sombras o mal enfocadas como detallamos en la Figura N°17.



**Figura 17.** Esquema de Toma y Clasificación de Imágenes

Fuente: Elaboración Propia


Como se visualiza en la figura 17 podemos apreciar la manera correcta del procesamiento de imágenes tanto para la toma de imágenes y su posterior clasificación con los diferentes pasos a ejecutar para de esa manera poder evitar defectos en nuestra red neuronal que estos pudiera ocasionar , para la obtención de estos fotogramas se utilizó el programa VLC media player como de muestra en la Figura N°18, seguido de esto realizamos una previa selección de manera manual para eliminar las imágenes que puedan presentar algún detalle o distorsión.



**Figura 18.** *Imágenes Obtenidas y Proceso de Obtención*

Fuente: Elaboración Propia

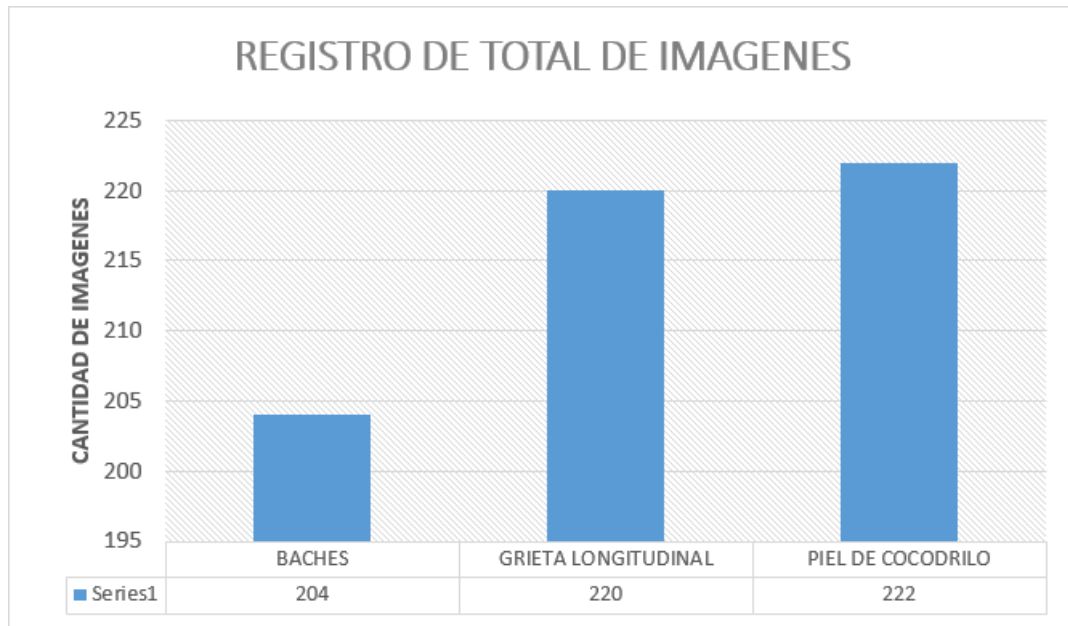
Como se muestra en la Figura N°18 se procedió con la toma del video para la obtención de nuestros fotogramas haciendo uso de la herramienta VLC media player como se puede observar en la figura N°19 de la toma del video se obtuvieron diferentes fotogramas de imágenes de las cuales se obtuvieron 14769 fotogramas de las cuales se realizó posteriormente la depuración y clasificación de las fallas como son para este proyecto de investigación las encontradas en la superficie del pavimento flexible con son grietas longitudinales, piel de cocodrilo y baches.



**Figura 19.** *Fotogramas Obtenidos con Herramienta VLC Media Player*

*Fuente:* Elaboración Propia

Seguido de esto se procede a otra selección para poder determinar las cantidades de imágenes con las cuales se trabajarán, seguido de un arduo proceso de selección manual y una clasificación de acuerdo al tipo de fallas al que pertenecen , de las cuales se obtuvieron un total de 646 imágenes entre baches, grietas longitudinales y piel de cocodrilo como se aprecia en la figura N°19 que son las que más predominan en este tramo que comprende de la avenida Héroes del Pacífico entre el jirón mi Perú y la I.E. Central Esquen la de la ciudad de Juliaca.



**Figura 20.** Registro del total de Imágenes Obtenidas Luego del Proceso de Selección

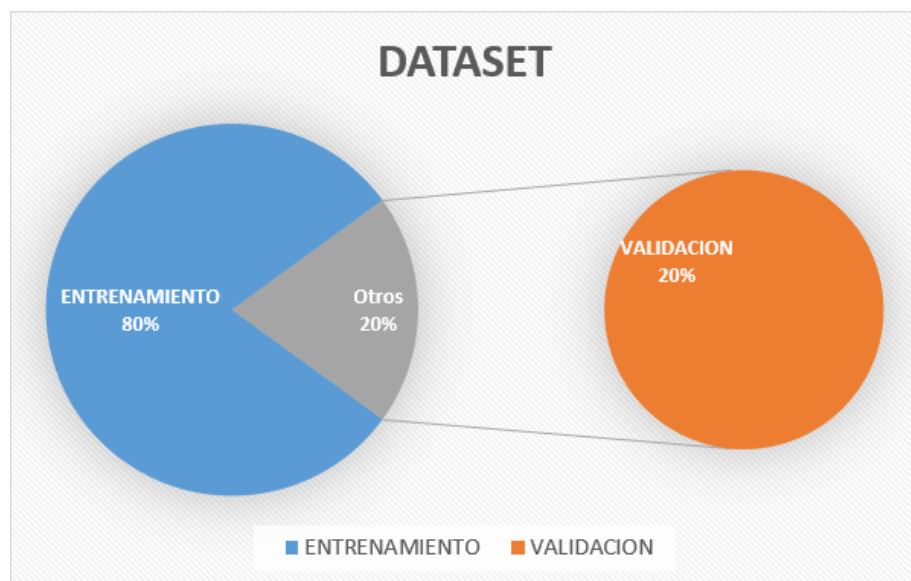
Fuente: Elaboración Propia

Como se puede visualizar en la figura N°20 se puede observar la cantidad seleccionada de imágenes con las cuales se trabajó para el entrenamiento del modelo de red neuronal convolucional como son en un numero de 204 en bache, 220 en lo que es grieta longitudinal y 222 correspondiente a piel de cocodrilo.

**Proceso de etiquetado de imágenes;** Para realizar este procedimiento de etiquetado de las imágenes se procede primero a realizar la selección y depuración de las imágenes deficientes ya realizado anteriormente para su correcta clasificación y etiquetado de las mismas.

El proceso de etiquetado se realizará conforme a la agrupación de las imágenes obtenidas, así como el tipo de falla y cantidad de estas, dentro de las cuales se

utilizarán el 80% para realizar el entrenamiento de nuestra red neuronal convolucional y el otro 20% será destinado para una correcta validación como se muestra en la Figura N°21 la cual será llevado a cabo una vez realizado el apto entrenamiento de nuestra red neuronal convolucional, este conjunto de imágenes serán llamadas en adelante como “dataset” que nos servirá para ejecutar el entrenamiento de nuestra red neuronal convolucional.



**Figura 21.** *Detallado de Imágenes Correspondientes a Entrenamiento y Validación*

Fuente: Elaboración Propia

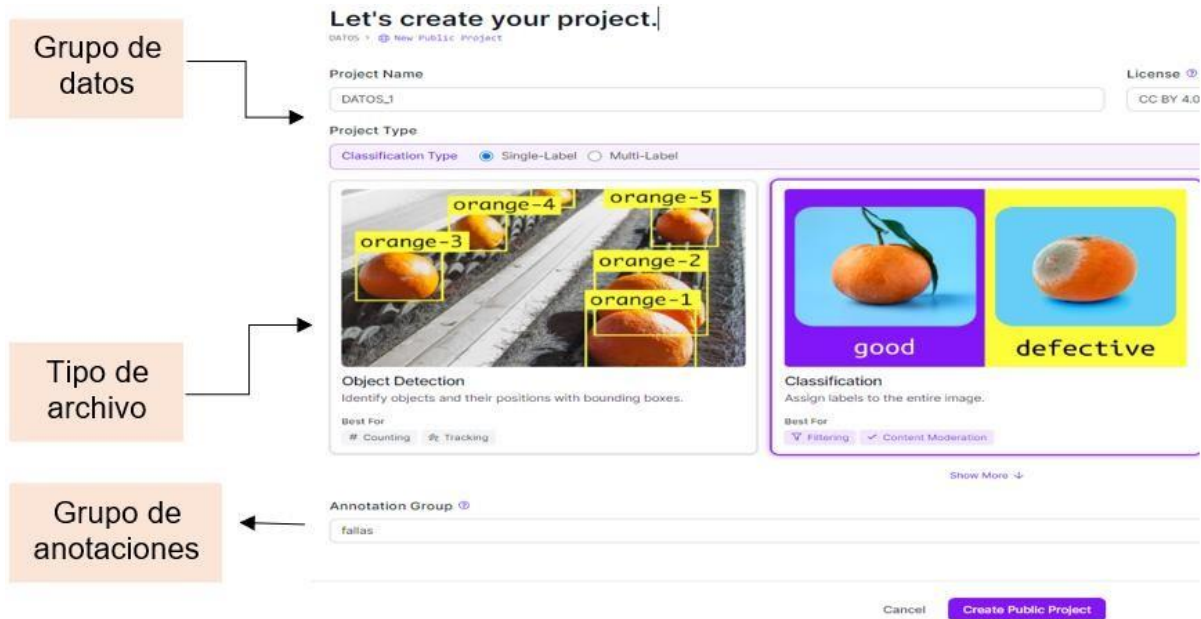
Dentro de este procedimiento se realizó el etiquetado de imágenes con ayuda de programas como es Roboflow que es un programa direccionado exclusivamente al etiquetado de imágenes y creación de datasets compatibles con Python las cuales para su utilización es necesario tener una cuenta en su plataforma GitHub para posteriormente ser usados en el entrenamiento de redes neuronales.



Este proceso tuvo cuatro fases, como son: la creación de una estructura de datos para el entrenamiento, la carga de datos para el entrenamiento, seguido tenemos el proceso de etiquetado de imágenes y por último se tendrá la generación del dataset o archivo que contendrá todos los datos ya procesados y en el formato requerido para de esa manera poder iniciar con el modelo de entrenamiento.

1. **Creación de una estructura de datos para el entrenamiento;** con ayuda de la herramienta Roboflow se estableció un dataset o archivo de datos con la información necesaria para la generación de nuestro archivo requerido como se muestra en la Figura N°22, para iniciar con nuestro entrenamiento para lo cual se ingresó la siguiente información:


- ✓ Project Name; el cual es el grupo de datos.
- ✓ Project Type; el cual viene a ser el tipo de archivo o el fin con el cual se quiere realizar el etiquetado, para este caso debemos de seleccionar la opción: Classification
- ✓ Annotation Group; Aquí se procede a realizar el etiquetado específico de nuestra imagen.



**Figura 22.** Creación de Estructura de Datos

Fuente: Elaboración Propia

- Carga de datos;** se cargarán el archivo de nuestras imágenes como se muestra en la Figura N°23, las cuales se procederán a etiquetar.

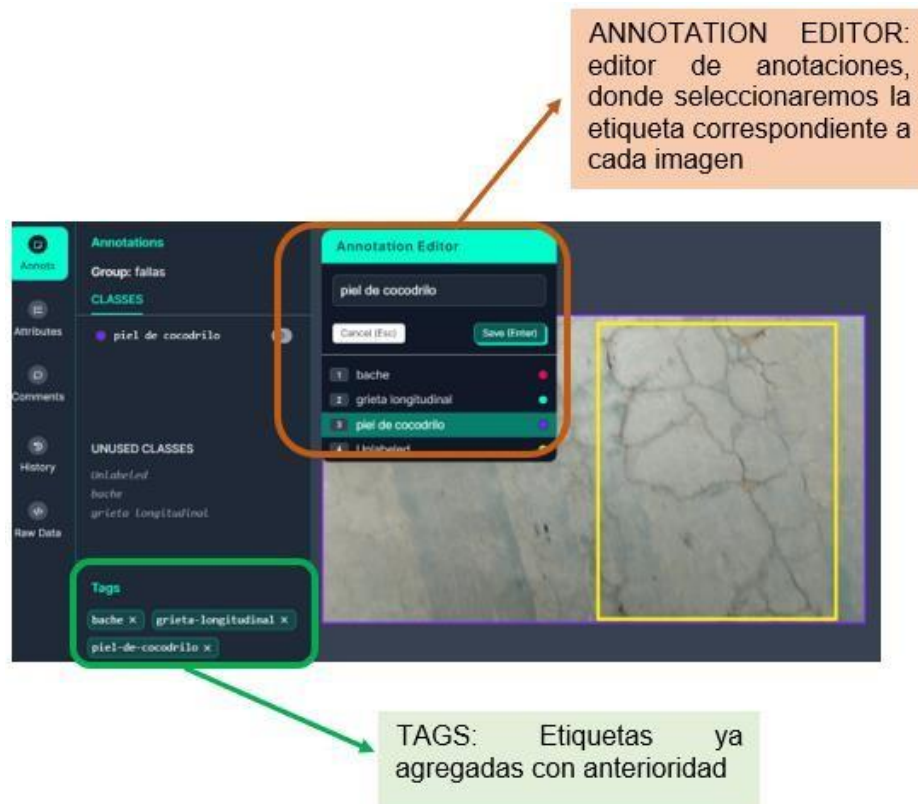


**Figura 23.** Carga de Datos

Fuente: Elaboración Propia

3. **Proceso de etiquetado;** luego de realizar la carga de imágenes se procedió a realizar el etiquetado o labelin de cada imagen subida, este procedimiento consiste en marcar o evidenciar cada falla encontrada en la superficie del pavimento flexible y brindarle así su clasificación correspondiente (clase) como se muestra en la figura N°24, esta acción debe realizarse sobre cada imagen.


- Se debe de identificar cada falla que se pueda encontrar en la superficie del pavimento flexible y etiquetarla con un nombre correspondiente a las clases ya definidas, las cuales ya fueron definidas con anterioridad como son grieta longitudinal, piel de cocodrilo, baches respectivamente.
- Una vez que ya se hayan agregado las etiquetas de cada clase de imagen que se propone de acuerdo a nuestros requerimientos, se procedió a exportar las etiquetas de cada imagen para que pudieran seguir de esa manera su proceso de etiquetado y de esa manera lograr también la obtención del dataset correspondiente, que es donde termina el proceso de etiquetado y procesado de nuestras imágenes para su posterior uso en el entrenamiento de la red neuronal convolucional.



**Figura 24.** *Proceso de Etiquetado con Herramienta Roboflow*

Fuente: Elaboración Propia

4. **Generación de datasets para correcto el entrenamiento de nuestro modelo de red neuronal convolucional;** realizado el etiquetado de nuestras imágenes se procedió con la descarga de nuestro archivo de imágenes para poder usarlas en nuestro modelo de entrenamiento de red neuronal convolucional.



**Figura 25. Dataset Obtenido**

Fuente: Elaboración Propia

**OBJETIVO ESPECIFICO 3: “Evaluar los resultados obtenidos de la inspección realizada a la superficie del pavimento flexible usando las redes neuronales convolucionales, Juliaca 2023”;** una vez realizado el debido procesamiento de nuestras imágenes y el análisis de estas de acuerdo a los tipos ya establecidos como son : grietas longitudinales, piel de cocodrilo y baches; se procedió con el entrenamiento de la red neuronal convolucional , el cual se detalla a continuación a través de la ejecución de procedimientos como son : elección de la red neuronal convolucional y el entrenamiento de la misma, los cuales se detalla a continuación:

**Elección de la red neuronal convolucional CNN;** Para la realización de esta tesis elegimos realizarla con una red neuronal convolucional ya que estas impulsan el reconocimiento de los diferentes patrones a encontrar en una imagen para de esa manera poder realizar las diferentes tareas de visión artificial.

Como primera tarea realizaremos la elección de algoritmos donde según Wang (2019) se evalúa 18 diferentes algoritmos de detección de grietas en diversas imágenes, en escalas de malo siendo este 1, regular siendo este 2, bueno siendo este 3 y excelente siendo este 4 y se procede a ordenar según su eficacia.

**Tabla 4.** Algoritmos de de Grietas Según su Nivel de Eficacia

Nº	ALGORITMO	1	2	3	4	5	6	7	8	9	TOTAL
1	Global thresholding	4	2	1	1	1	1	1	1	1	13
2	Fractal análisis	4	3	2	1	1	1	1	2	1	16
3	Quaternion Edge detection	2	1	3	3	1	1	1	4	1	17
4	FMC	1	1	3	3	3	1	1	1	4	18
5	SVM	3	4	3	2	2	1	1	1	1	18
6	Dynamic thresholding	3	4	3	2	2	1	1	1	2	19
7	Región splitting	3	3	4	2	2	1	1	2	1	19
8	Canny Edge detection	3	4	3	1	2	1	2	2	1	19
9	Wavelet transform	3	1	3	4	3	1	1	1	2	20
10	Región merging/growing	3	3	4	2	2	1	1	2	2	20

11	Región merging and splitting	3	3	2	2	3	1	1	1	4	20
12	Clustering	2	3	3	4	1	1	1	3	2	20
13	Graph (MST)	3	3	3	3	1	1	1	1	4	20
14	Valley Edge detection	2	3	1	2	1	1	4	4	3	21
15	Fractional differential	2	3	2	3	1	1	4	3	2	21
16	Multiple scales	3	3	2	3	1	1	3	4	1	21
17	Neural network	2	2	2	2	2	2	3	3	4	22
<b>18</b>	<b>Deep Learning</b>	<b>2</b>	<b>2</b>	<b>2</b>	<b>4</b>	<b>2</b>	<b>2</b>	<b>4</b>	<b>3</b>	<b>3</b>	<b>24</b>


Fuente: Wang, 2019.

Como observamos en la tabla N°4 según Wang la Deep Learning es el algoritmo con mejor puntaje en cuanto el entrenamiento de redes neuronales en lo que es la detección de grietas en pavimentos asfaltados o de concreto alcanzando un puntaje de 24.

Seguido de esto se procedió a la elección del lenguaje de programación para un correcto entrenamiento de la red neuronal convolucional siendo elegido Python el cual cuenta con una amplia velocidad de lectura y de fácil comprensión.

Para poder realizar el entrenamiento se decide trabajar en anaconda que es un desarrollador de entrega libre que contiene todos los lenguajes de programación como son Python y R, las cuales son utilizadas en entrenamiento automatizado,

análisis predictivos, entre otros. Dentro de este sistema haremos uso JupyterLab como mostramos en la Figura N°26 que es un desarrollador que nos permite poder dividir un código en segmentos que nos permiten trabajar en ellos sin importar el orden y realizar así ciencia de datos y lo que vendría a ser el aprendizaje automático en Python , para poder trabajar en JupyterLab con Python se tiene que tener dispensables librerías para el correcto entrenamiento de esta como es keras , tensorflow, matplotlib, pandas, entre otros así como también sus extensiones para de esta manera poder realizar un correcto procesamiento de nuestras imágenes y posterior entrenamiento de nuestra red neuronal convolucional , y poder realizar el análisis estadístico de nuestros indicadores obtenidos después del entrenamiento de nuestra red neuronal haremos uso de herramientas como son Tensorboard,pithorch que nos permiten analizar las diferentes hipótesis propuestas mediante gráficos ,visualizar de esa manera nuestros datos y poder determinar así su validez.




**Figura 26.** *Desarrollador y Lenguaje de Programación utilizados como son JupyterLab y Python respectivamente*

*Fuente:* Elaboración Propia



Seguido de esto es muy necesario mencionar los tipos y estructuras de las RNA que fueron usadas en este trabajo de investigación la cual es una arquitectura de tipo convolucional como es una red neuronal convolucional Como se muestra en la Figura N°27 la cual está conformada por una capa de entrada la cual en nuestro tema es el conjunto de datos que se tiene o el dataset ya preparado este a fin de poder escalar a la siguiente capa de convolución la cual es el proceso de filtrado de nuestros datos en el cual procederemos realizar nuestra red convolucional de aprendizaje profundo en el realiza la detección de las grietas longitudinales ,baches y piel de cocodrilo sobre la superficie del pavimento flexible de la avenida héroes del pacifico dela ciudad de Juliaca en el tramo que comprende entre el jirón mi Perú y la I.E. Esquen donde se aplicaron los algoritmos basados en la red neuronal convolucional que permitió la detección automática de estas, de la misma manera los algoritmos mejoran la precisión en el pixelado de las imágenes.



**Figura 27.** *Arquitectura de Tipo Convolucional CNN*

*Fuente:* Calvo , 2017

Las imágenes ya anteriormente procesadas y etiquetadas se subieron a nuestra red neuronal de entrenamiento donde también pasaron por un proceso de redimensionamiento para de esta manera ser procesadas de mejor manera dentro de nuestra red neuronal convolucional haciendo también uso de las diferentes librerías ya mencionadas en la tabla N°5 las cuales nos ayudan a un mejor filtrado y redimensionamiento de los datos ingresados.

**Tabla 5. Principales Librerías Utilizadas**

<b>LIBRERÍA</b>	<b>DESCRIPCION</b>
<b>KERAS</b>	Es una librería de CNN que permite la experimentación o la creación de estas en poco tiempo, Keras va de la mano con Tensor Flow
<b>TENSORFLOW</b>	Es una librería multiplataforma de código abierto que nos ayuda a realizar de manera fácil modelos de aprendizaje
<b>MATPLOTLIB</b>	Es una biblioteca que nos ayuda a la creación de gráficos en dos dimensiones a partir de listas de datos en lenguaje de Python.
<b>NUMPY</b>	Es una biblioteca especializada en el lenguaje de programación para calculo numérico y análisis de


---

<b>OS</b>	<p>datos en gran cantidad, también brinda soporte para la creación de vectores y matrices.</p> <p>Es una biblioteca que nos proporciona una mejor interfaz para así relacionar con el sistema con el cual opera sistema operativo con el cual se va a ejecutar el programa.</p> <p>Es una biblioteca que se especializa en la manipulación y análisis de datos que ofrece sistemas de datos y operación para así poder manejar diferentes tablas numéricas y series.</p>
<b>PANDAS</b>	<p>Es una biblioteca que nos proporciona un acceso a diferentes formatos efectivos de variedades de algoritmos.</p>
<b>SCIKIT-LEARN</b>	<p>Es un grupo de herramientas de visualización el cual nos ayuda a evaluar e interpretar los diferentes gráficos que podamos obtener.</p>
<b>TENSORBOARD</b>	

---

Fuente: Elaboración Propia

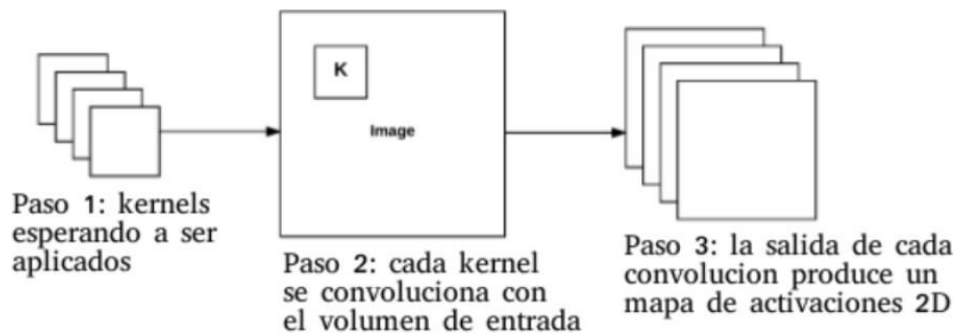
Seguir con el entrenamiento de la red neuronal convolucional, donde una imagen para la vista humana es de fácil lectura pero para un sistema de detección automática es un conjunto de pixeles que va de 0 hasta los 255 pero en nuestra red neuronal se lee de 0 a 1 , seguido bajo este concepto como se muestra en la figura N°28 ,donde se observa la detección de un mapa de detección de características para los cuales se deben de agregar filtros o los llamados kernels que son vectores de soporte los cuales ayudan a que las imágenes que están pasando por un proceso de filtrado a cuanto menor sea su tamaño la cantidad de información que esta posee también es mayor gracias a las convoluciones que estas realizan de acuerdo a los diferentes patrones que van encontrando en cada convolución. La imagen mostrada a continuación detalla una convolución de kernel y también aplica una función para activación en este caso Relu



**Figura 28.** Obtención de un Mapa de Detección de Características

Fuente: Pixelabs ,2021

La convolución de kernel donde ya se empieza a obtener los primeros patrones; los cuales se detalla en la figura N°29 donde se observa que una imagen logra convolucionar con cada uno de los filtros dando como salida mapas de activación.




**Figura 29.** *Capa Convolutiva*

Fuente: KeepCoding , 2024

En esta etapa procedemos con las siguientes capas de convoluciones como se muestra en la Figura N°30 estos son los mapas de características representativas las cuales serán capaces de reconocer formas de más complejidad y así poder realizar una inspección mejorada de las imágenes luego de múltiples convoluciones las cuales después serán conectadas con una red neuronal convolutiva, en la Figura N°30 se visualiza también un modelo de arquitectura de red neuronal donde se puede observar que cada circunferencia manifiesta una neurona las cuales se agrupan en capas donde podemos visualizar que las neuronas de color amarillo representan las entradas , las neuronas de color verde representan las salidas y las neuronas de color gris representan las capas ocultas las cuales engloban cálculos medios de la red neuronal convolutiva , regularmente todas las neuronas de cada una de las capas posee una conexión con cada una de las neuronas de la capa siguiente las cuales tiene un número vinculado el cual se le denomina peso, como se observa en la Figura N°30 una de las principales operaciones que ejecuta una red neuronal convolutiva comprende en realizar la multiplicación de cada valor de cada neurona por los pesos obtenidos de las neuronas salientes .Cada una de las neuronas de la próxima capa

decepciona los números de las diferentes conexiones provenientes , y como actividad principal , lo que realiza es realizar la sumatoria de todos para así obtener las neuronas de salida (Lopez, 2014).




**Figura 30.** *Arquitectura de Red de Neuronas / Capas de Convoluciones*

Fuente: Lopez , 2014

Siguiendo con lo anteriormente mencionado , este procedimiento de capas convolucionales las cuales son conectadas de manera oculta con una red neuronal multicapa de la cual ya va adquiriendo una capa de salida la cual tendrá tres neuronas las cuales según nuestra clasificación son grietas longitudinales , baches y piel de cocodrilo para poder realizar más convoluciones donde se van detectando más características y se van incrementando de la misma manera el número de neuronas donde para reducir el tamaño de las neuronas se hace uso de MaxPooling el cual nos ayuda a contener la cantidad de neuronas que van surgiendo a partir de cada nueva convolución , una vez realizado este proceso y de ajustar nuestra cantidad de kernel y convoluciones se tendrá como resultado una red neuronal convolucional entrenada capaz de reconocer de manera automática y distinguir entre los diferentes tipos de

fallas como son en nuestro proyecto grietas longitudinales, baches y piel de cocodrilo, teniendo en cuenta que la función softmax realiza la función de conversión de datos ya procesados en probabilidades.



**Figura 31.** *Proceso de Convolución*

Fuente: Pixelabs, 2022

Después de haber mencionado un poco de los conceptos a considerar para la realización de este objetivo específico 3 como es **“Evaluar los resultados obtenidos de la inspección realizada a la superficie del pavimento flexible usando las redes neuronales convolucionales, Juliaca 2023”**; para la realización de este objetivo se realizó el entrenamiento de nuestra red neuronal convolucional para la obtención y resultados y su posterior evaluación el cual se detalla a continuación:

**Entrenamiento de red neuronal convolucional para realizar la detección de fallas en la superficie del pavimento flexible;** Una vez ya realizado el procedimiento de análisis de imágenes tanto como el proceso de filtrado y etiquetado de imágenes se procederá con la realización del entrenamiento de la red neuronal convolucional, para

lo cual se utilizará el lenguaje de programación denominado Python el cual viene siendo utilizado por su fácil comprensión y por su velocidad en lectura, el proceso de entrenamiento se de red neuronal convolucional se llevara a cabo realizando una serie de procedimientos el cual se detalla en la Figura N°32 donde se observa cada uno de ellos como son: creación del entorno de desarrollador de Python (Deep Learning) , uso de Python - JupyterLab, preparación del entorno y finalmente el entrenamiento del modelo.



**Figura 32.** Procedimiento para el Entrenamiento de Red Neuronal Convolucional

Fuente: Elaboración propia



Como podemos visualizar en la Figura N°32 el proceso de entrenamiento de nuestra red neuronal convolucional está compuesto por diferentes procedimientos que se detallan uno a uno a continuación:

### **Creación de nuestro entorno de desarrollador de Python (Deep learning);**

Primero debemos de realizar la instalación de un desarrollador denominado anaconda navigator el cual es de descargar gratuita en cualquier navegador como se muestra en la Figura N°33 la cual se muestra a continuación.




**Figura 33.** *Descarga desarrollador Anaconda Navigator*

Fuente: Pagina de Descarga. Disponible en <https://www.anaconda.com/anaconda-navigator>

Una vez realizado la descarga del desarrollador que utilizamos se procedió con la creación de nuestro entorno, para este proyecto iniciamos con la creación de nuestro entorno para lo cual primero nos dirigimos a la pestaña de Environments o entornos ubicado en la parte superior izquierda del desarrollador , luego nos ubicamos en la parte inferior izquierda donde damos clic en la pestaña Create seguido aparecerá una

ventana de dialogo denominada “Create new environment” donde como detallamos en la Figura N°34 se procedió a la creación de nuestro entorno denominándolo **RGMC-IC** y elegimos Python en su versión 3.8 como mostramos a continuación:



**Figura 34.** Creación de Entorno en Anaconda Navigator

*Fuente:* Elaboración Propia

Como se muestra en la Figura N°34 debe de realizarse la creación del entorno con la versión 3.8.18 de Python ya que algunas librerías que utilizamos no son compatibles con otras versiones de Python creando dificultad posteriormente en el entrenamiento de la red neuronal , una vez que se realizó la creación del entorno donde se iniciarían los trabajos de entrenamiento se procede con la descarga de las diferentes librerías que se utilizaron dentro de las cuales se encuentran keras, tensorflow, matplotlib, scikit-learn, numpy entre otras.

Para la descarga de las diferentes librerías se procede a realizar las descargas dentro del entorno ya creado , debemos de realizar el siguiente procedimiento para realizar la descarga de las librerías a utilizar : debemos de dar clic en la pestaña ubicada en la parte superior izquierda denominada not installed que son las librerías no instaladas y también esta pestaña posee la opción de mostrarnos a la vez las librerías

que vamos instalando haciendo clic en la opción installed y empezamos a realizar la descarga de cada una de ellas ayu dándonos también de la pestaña ubicada en la parte superior derecha denominada search packages donde podemos buscar las librerías por nombre facilitándonos de esa manera la búsqueda y descarga como podemos visualizar en la Figura N°35 la cual mostramos a continuación:



**Figura 35.** *Proceso de Descarga de Librerías*

Fuente: Elaboración Propia

Una vez realizado la descarga de las diferentes librerías que usaríamos se procedió con la obtención de un entorno listo para trabajar como podemos visualizarlo en la Figura N°36 mostrada a continuación




**Figura 36.** *Desarrollador Anaconda- Entorno Listo*

Fuente: Elaboración Propia

Como se muestra en la Figura N°36 una vez ya creado el entorno dentro de Anaconda se procedió con la descarga y ejecución de JupyterLab el cual ya se encuentra disponible dentro del desarrollador Anaconda Navigator.

**Uso de Python – JupyterLap;** una vez creado el entorno se procedió a realizar la descarga del desarrollador donde trabajamos ya con las librerías necesarias dentro de JupyterLab siendo esta una aplicación de código abierto comprendido por una estructura de notebooks el cual posee tres lenguajes de programación diferentes como son Python y R; en JupyterLab se puede realizar trabajos con el uso de Python ya que es un lenguaje que ya viene incorporado dentro de este como se muestra en la Figura N°37, una vez ya dentro de este se da inicio a la creación del modelo de entrenamiento.



**Figura 37.** Ejecución de Python 3 dentro de JupyterLab

Fuente: Elaboración Propia

Como se muestra en la Figura N°37 se realizó la ejecución de Python dentro de JupyterLab donde procedimos a realizar el entrenamiento de la red neuronal convolucional con la cual se trabajó realizando la ejecución de los diferentes procedimientos como son:

**Preparación del entorno;** dentro de este se da inicio al entrenamiento del modelo en el cual fue necesario la preparación de nuestro entorno dentro del script de JupyterLab el cual también nos ayuda a ejecutar Python ya que tiene incorporado este lenguaje de programación ya incorporado en la versión que nosotros ya elegimos en la

creación de nuestro entorno RGMC-IC, en el cual se procedió a realizar la importación de las diferentes librerías de Python.

Para realizar la importación de las diferentes librerías como son pandas, keras, tensorflow, matplotlib, numpy, os, tqdm, cv2, sklearn, skimage, entre otros se procedió a escribir los siguientes comandos mostrados a continuación:

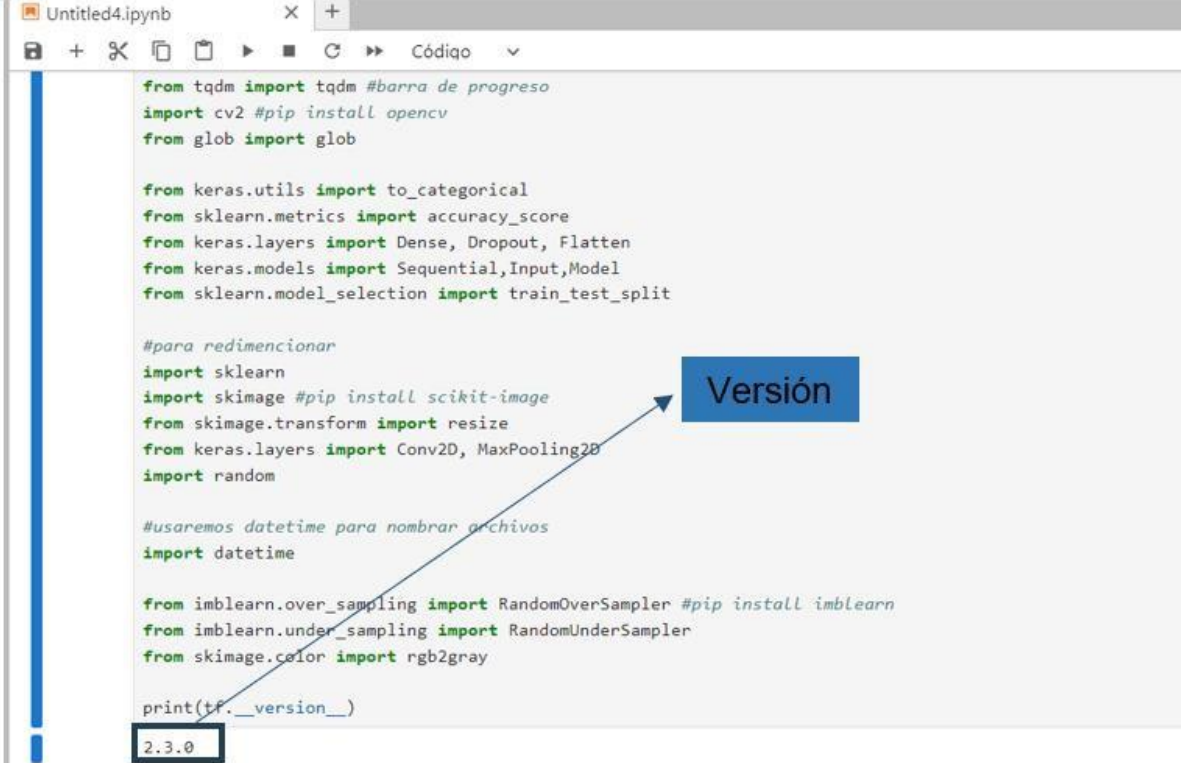
```
#librerias
from __future__ import absolute_import, division, print_function, unicode_literals
import pandas as pd
import keras
import tensorflow as tf
from tensorflow.keras import datasets, layers, models

import matplotlib.pyplot as plt
import numpy as np
import os
from tqdm import tqdm #barra de progreso
import cv2 #pip install opencv
from glob import glob

from keras. utils import to_categorical
from sklearn.metrics import accuracy_score
from keras. layers import Dense, Dropout, Flatten
from keras. models import Sequential, Input, Model
from sklearn. model_selection import train_test_split

import sklearn
import skimage #pip install scikit-image
from skimage.transform import resize
from keras.layers import Conv2D, MaxPooling2D
import random
import datetime
from imblearn.over_sampling import RandomOverSampler #pip install imblearn
from imblearn.under_sampling import RandomUnderSampler
from skimage.color import rgb2gray
print(tf._version_)
```

Una vez importados las diferentes librerías y ejecutado el algoritmo se obtuvo como resultado 2.3.0 referente a la versión en la cual se trabajó como se muestra en la Figura N°38 mostrada a continuación.



```
from tqdm import tqdm #barra de progreso
import cv2 #pip install opencv
from glob import glob

from keras.utils import to_categorical
from sklearn.metrics import accuracy_score
from keras.layers import Dense, Dropout, Flatten
from keras.models import Sequential, Input, Model
from sklearn.model_selection import train_test_split

#para redimensionar
import sklearn
import skimage #pip install scikit-image
from skimage.transform import resize
from keras.layers import Conv2D, MaxPooling2D
import random

#usaremos datetime para nombrar archivos
import datetime

from imblearn.over_sampling import RandomOverSampler #pip install imblearn
from imblearn.under_sampling import RandomUnderSampler
from skimage.color import rgb2gray

print(tf.__version__)
```

2.3.0

Versión

**Figura 38.** Versión de Algoritmo

*Fuente:* Elaboración Propia

**ENTRENAMIENTO DEL MODELO;** para lograr un correcto entrenamiento del modelo de red neuronal convolucional se hizo en partes dentro de las cuales tenemos: carga de datos, creación de histograma de imágenes, creación de red neuronal, modelo de entrenamiento y el entrenamiento de nuestra red neuronal convolucional en sí, para su mejor entendimiento procedemos a desarrollar estos puntos a continuación:

**Carga de datos;** este procedimiento se realizó con ayuda de librerías ya importadas con anterioridad que nos ayudaron a realizar la correcta importación de nuestros

datos guardados dentro de nuestra carpeta de entrenamiento que es donde se realizara el entrenamiento, donde se guardara el cuaderno donde desarrollamos nuestro modelo de red neuronal en el cual también se realizó el etiquetado dentro de Python como bache=0, .grieta longitudinal=1 , piel de cocodrilo = 2 , donde también se realizó el redimensionamiento de nuestras imágenes para un mejor procesamiento con la ejecución del comando `resize(150,150,3)` el cual indica las dimensiones con las cuales fueron procesadas nuestras imágenes ya que con dimensiones superiores se dificulta un poco la realización del proceso de convoluciones en las diferentes capas , para realizar este procedimiento se procedió con la ejecución de nuestro algoritmo mostrado a continuación:

```
Carpeta="DATOS_1/ENTRENAMIENTO"
#CARGA DE IMAGENES = false
def Conv_img(folder):
    x = []
    y = []
    for folderName in os.listdir(folder):
        if not folderName.startswith('.'):
            if folderName in ["BACHE"]:
                label = 0
            elif folderName in ["GRIETA_LONGITUDINAL"]:
                label = 1
            elif folderName in ["PIEL_DE_COCODRILO"]:
                label = 2
            else:
                label = 3
            for image_filename in tqdm(os.listdir(folder + folderName)):
                img_file = cv2.imread(folder + folderName + '/' + image_filename)
```




```

if img_file is not None:
    img_file = skimage.transform.resize(img_file, (150, 150,
3),mode='constant',anti_aliasing=True)
    img_file = rgb2gray(img_file) # = (150, 150, 1)
    #img_file = spicy.misc.imresize(arr=img_file, size=(150, 150, 3))
    img_arr = np.asarray(img_file)
    X.append(img_arr)
    y.append(label)

x = np.asarray(x)
y = np.asarray(y)
return X,y
X, y =Conv_img(carpeta)

print(X)
print(y)

```



**Figura 39.** Obtención de la Ejecución de Algoritmo para Carga de Datos

Fuente: Elaboración Propia


Luego de la ejecución del algoritmo de carga de datos se tiene la obtención de las barras de carga como se muestra en la Figura N°39 el total de imágenes cargadas a

nuestro sistema, donde se visualiza que fueron cargadas en su totalidad como son 204 en baches, 220 en grieta longitudinal y 222 en piel de cocodrilo respectivamente.

**Creación de histograma;** para la obtención de este histograma se utilizó la biblioteca de histogram y plot para de esa manera obtener un histograma que pueda mostrar la frecuencia de una muestra de acuerdo a los valores que obtiene dentro de nuestro modelo de entrenamiento, se procedió a introducir los siguientes comandos que podemos visualizar a continuación:

```
def plotHistogram(a):  
    plt.figure(figsize=(12,6))  
    plt.subplot(1, 2, 1)  
    plt.hist(a.ravel(), bins=255)  
    plt.subplot(1, 2, 2)  
    plt.imshow(a, cmap='gray',vmin=0, vmax=1)  
    plt.show()  
plotHistogram(X[50])
```

De nuestros comandos ingresados se visualiza a la ejecución del algoritmo el histograma obtenido con el uso del comando imshow el cual nos ayuda para la representación de los intervalos de nuestros valores en pixeles como se muestra en la Figura N°39 mostrada a continuación:



**Figura 40.***Histograma Obtenido*

Fuente: Elaboración Propia

Como se muestra en la Figura N°41 el análisis de imágenes se puede apreciar el realce de los gráficos de barra permitiendo detectar las características específicas de las imágenes que se usaron para así comprobar la validación estas.

**Creación de nuestra red neuronal;** en esta parte del procedimiento se tendrá en los resultados de carga de datos en valores de 80% que corresponden a el entrenamiento y un 20% destinados a la validación, para este proceso se realizó la ejecución de los siguientes comandos mostrados a continuación:

```
X_Reformado = X. reshape(len(x),150,150,1)
Y_Categ=to_Categorical(y)

#A-ENTRENAMIENTO Y VALIDACION
X_e,X_v,Y_e,Y_v=train_test_split(X_Reformado,Y_Categ,
test_size=0.20,random_state=4)
print(X_e.shape,X_v.shape,Y_e.shape)
```

```

X_Reformado = X.reshape(len(x),150,150,1)
Y_Categ=to_Categorical(y)

#A-ENTRENAMIENTO Y VALIDACION
X_e,X_v,Y_e,Y_v= train_test_split(X_Reformado,Y_Categ, test_size=0.20,random_state=4)
print(X_e.shape,X_v.shape,Y_e.shape)

```

```
(516, 150, 150, 1) (130, 150, 150, 1) (516, 3) (130, 3)
```

**Figura 41.** *Imágenes de Entrenamiento y Validación*

Fuente: *Elaboración Propia*

De este algoritmo se obtuvo como se muestra en la figura N°42 como parte de la creación de nuestra red neuronal donde se obtuvo (156,150,150,1) (130,150,150,1) (516,3) (130,3) de las cuales nos indica un total de 516 imágenes que corresponde a nuestra cantidad usada para el entrenamiento y 130 imágenes que corresponde a nuestro total de validación.

**Creación de modelo de red neuronal convolucional;** para la creación de nuestra red neuronal la cual consta de 3 convoluciones de 64píxeles, las cuales se acumularon en una matriz de 3x3 que cuenta con la función de activación Relu, las convoluciones se guardaron en una matriz de 2x2, seguido de esto se realizó la conversión de nuestros mapas de características 3D en vectores de características 1D, se procedió a la ejecución de los siguientes comandos:

```

modelo=models.Sequential()
Modelo de la red neuronal
modelo.add(layers.Conv2D(64,(3,3),activation='relu',Input_shape=(150,150,1)))
modelo.add(layers.MaxPooling2D((2, 2)))
modelo.add(layers.Conv2D(64,(3,3),activation='relu'))
modelo.add(layers.MaxPooling2D((2, 2)))

```

```

modelo.add(layers.Conv2D(64,(3,3),activation='relu'))
modelo.add(layers.MaxPooling2D((2,2)))
Convirtiendo nuestros mapas de características 3D en vectores de características 1D
modelo.add(layers.Flatten())
modelo.add(layers.Dense(64,activation='relu'))
modelo.add(layers.Dense(3, activation='softmax'))
Compilador de la red neuronal
modelo.compile(optimizer='adam',loss='categorical_crossentropy',metrics=['accuracy'])
modelo.summary()

```

Seguido de la ejecución del algoritmo se obtuvo nuestro modelo de red neuronal el cual se muestra a continuación:

```

Model: "sequential"

```

Layer (Type)	Output Shape	Param #
conv2d (Conv2D)	(None, 148, 148, 64)	640
max_pooling2d (MaxPooling2D)	(None, 74, 74, 64)	0
conv2d_1 (Conv2D)	(None, 72, 72, 64)	36928
max_pooling2d_1 (MaxPooling2D)	(None, 36, 36, 64)	0
conv2d_2 (Conv2D)	(None, 34, 34, 64)	36928
max_pooling2d_2 (MaxPooling2D)	(None, 17, 17, 64)	0
flatten (Flatten)	(None, 18496)	0
dense (Dense)	(None, 64)	1183808
dense_1 (Dense)	(None, 3)	195

```

=====
Total params: 1,258,499
Trainable params: 1,258,499
Non-trainable params: 0
=====

```

**Figura 42.** Modelo de Red Neuronal

Fuente: Elaboración Propia

En la Figura N°42 podemos ver la compilación de nuestros datos donde se observa la totalidad de parámetros listos para su entrenamiento como son 1,258,499 con los cuales se procederá a ejecutar el entrenamiento de nuestro modelo de red neuronal convolucional.

**Entrenamiento;** dentro de este procedimiento se vio el history y las diferentes épocas comprendiendo un total de 125 épocas las cuales representan rondas completas sobre las iteraciones, en el cual podremos visualizar un gráfico de pérdida y precisión, para la obtención de nuestro grafico de pérdida y precisión se procedió a realizar la ejecución de los comandos siguientes:

```
print ()
history = modelo.fit(X_e, Y_e, epochs=125, validation_data =
(X_v,Y_v)verbose=0)
print('keys:',history.history.keys())

Gráfico de la función de pérdida y precisión
plt.figure(figsize=(8,4))
plt.subplot(1,2,1)
plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.ylabel('Pérdida')
plt.xlabel('Epocas')
plt.legend(['Entrenamiento','Validación'])

plt.subplot(1,2,2)
plt.plot(history.history['accuracy'])
plt.plot(history.history['val_accuracy'])
```

```

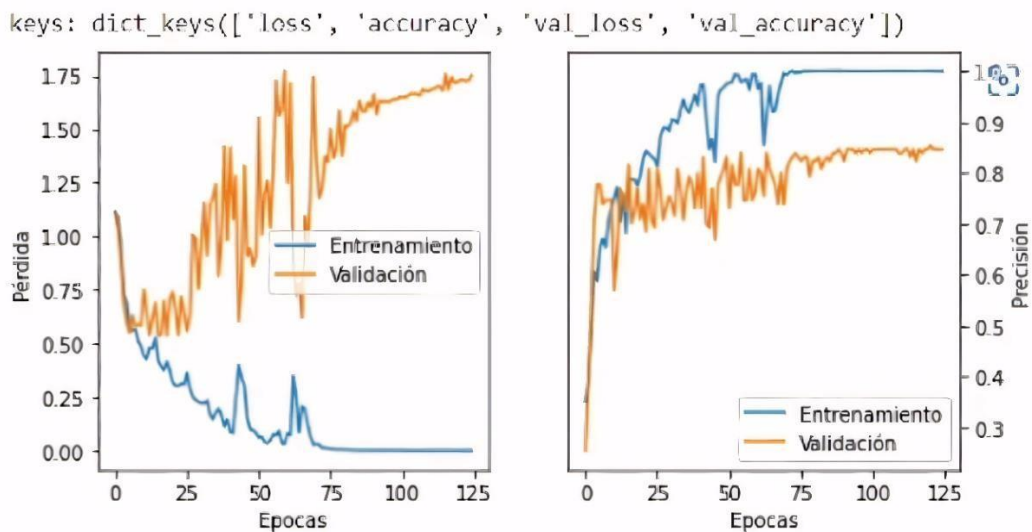
plt.ylabel('Precisión')
plt.xlabel('Epocas')
plt.legend(['Entrenamiento','Validación'])

ax = plt.gca()
ax.yaxis.set_label_position("right")
ax.yaxis.tick_right()

plt.show()

```

De la ejecución del algoritmo se obtuvo la imagen de pérdida y precisión que nos demuestra el nivel de entrenamiento y confiabilidad de nuestro modelo de entrenamiento de red neuronal convolucional.



**Figura 43.** *Perdida y Precisión del Modelo*

*Fuente:* Elaboración Propia

Como podemos visualizar en la Figura N°43 se podrá visualizar en la primera imagen de perdida versus épocas donde nuestro entrenamiento realizado ha tenido pocas

deficiencias en el entrenamiento, en validación tuvo unos inconvenientes ya sea por incongruencia de imágenes o una interpretación baja; en la segunda imagen se visualiza la precisión donde se observa que se llegó al 100% del entrenamiento, pero alcanzando un 0.85 en validación correspondiente al 85% en confiabilidad obtenido , siendo este aceptable dentro del rango donde debe de obtener una puntuación .

### **Método de análisis de datos**

Este proyecto de investigación se realizará con el enfoque de investigación cuantitativo de manera sistémica, siempre y cuando nos permita ejecutar de manera satisfactoria los objetivos ya mencionados. De igual manera según Shim (2020) indica que la técnica de análisis de datos radica en analizar rendimientos, asimismo Opara (2021) detalla que muchos métodos de instrucción profunda fueron hechos para estudiar e identificar elementos usando variedades de algoritmos.

### **Aspectos éticos**

Está conformado por un conjunto de referencias que obliga a incorporar el proyecto de investigación, sometiéndonos totalmente a determinadas fuentes bibliográficas, así como el respeto y cumplimiento de la norma Apa séptima edición, también indicando que cualquier imagen, fotografía deberán de contar con un control riguroso para asegurar que sea original y no contener plagio. Según el Ministerio de Educación a través del diario El Peruano; indica que la investigación conforma una parte primordial y comprometida de cada universidad, garantizando por medio de la elaboración de saberes y crecimiento de tecnologías acorde a lo que necesita la sociedad, haciendo un énfasis específico en lo que es la problemática nacional.



Así mismo para poder dar fe de los ya mencionado este proyecto de investigación ha sido sometido por el programa llamado Turnitin el cual hace un cotejo de la información de este proyecto con algunos similares en caso existan , ayudándonos de esa manera a realizar este trabajo de tesis sin rastro de plagio o copia alguna.


Tomando en cuenta los puntos ya mencionados se viene realizando este proyecto de investigación acatando la normatividad en su totalidad, garantizando de esta manera la originalidad de este.

### III. RESULTADOS

En este capítulo se mostrará los resultados obtenidos de manera parcial y total de los diferentes procesos de identificación de fallas sobre fotografías tomadas de manera aérea a partir de un video , para el reconocimiento de estas fallas se realizaron a partir de la clasificación de las imágenes obtenidas , de las cuales luego de ser procesadas y debidamente etiquetadas ; para el entrenamiento de una red neuronal convolucional donde se realizó una disposición del 80% destinado al entrenamiento y el 20% destinado para la validación de este las cuales fueron seleccionadas de los diferentes tipos, cabe recalcar que las imágenes destinadas para entrenamiento y validación son totalmente diferentes. Seguido se muestra a continuación los resultados obtenidos de cada objetivo propuesto, teniendo como principal contraste nuestra hipótesis general, la cual es: **“Es posible realizar una inspección automatizada de la superficie del pavimento flexible con el uso de redes neuronales convolucionales, Juliaca 2023”** a través de nuestros objetivos específicos, demostrándose que sí, a través de la confirmación de nuestros objetivos específicos los cuales procedemos a detallar a continuación:


**OBJETIVO ESPECIFICO 1: “Determinar las fallas que se encuentran en la superficie del pavimento flexible haciendo uso de las redes neuronales convolucionales , Juliaca 2023 ”** ; Para nuestro primer objetivo específico es necesario indicar la ubicación de la vía a evaluar , para la realización de la detección del video de la zona de estudio como se detalla en la Figura N°12 (Ubicación del tramo evaluado de la ciudad de Juliaca, iniciando en el Jirón Mi Perú y concluyendo en la I,E, Esquen , tramo que corresponde a la Avenida Héroes de la Guerra del Pacifico

donde se realizó la toma de video en diferentes horas para así evitar errores como se muestra en la figura N°13 (Esquema de captura de imágenes del Pavimento Flexible) donde se puede visualizar el uso del celular inteligente y su acoplamiento sobre una camioneta para poder evitar interferencias o movimientos bruscos durante la toma de imágenes , en la Figura N° 14 podemos ver el recorrido y captura de imágenes para su procesamiento ; donde podemos observar que se logró la correcta toma de video para poder realizar la ejecución del siguiente objetivo ;donde podemos determinar que se logró la correcta determinación de fallas a lo largo del tramo de la Av. Héroes de la Guerra del Pacífico comprendido entre el jirón Mi Perú siendo la progresiva 0+580 km y la I.E. Central Esquen siendo también la progresiva 4+250 km que comprende un total de 3+670 km donde se realizó la inspección .



**Figura 44.** Tramo Recorrido de la Avenida Héroes de la Guerra del Pacífico

Fuente: Elaboración Propia




**Figura 45. Universo Total de Fallas Encontradas**

Fuente: Elaboración Propia

Como se muestra en la Figura N°46 realizada la toma del video se obtuvieron un total de 14768 fotogramas, de las cuales según una clasificación previa se obtuvieron un total de imágenes 2879 en lo que son grietas longitudinales, en baches un total de 3375, en piel de cocodrilo un total de 3432 y en otras fallas un total de 5083 las cuales no se tomaron en cuenta ya que no se cumple la cantidad necesaria de estos para realizar un entrenamiento.

**OBJETIVO ESPECIFICO 2 : “Analizar las fallas que se encuentran en la superficie del pavimento flexible con el uso de las redes neuronales convolucionales , Juliaca 2023”** ; Asimismo, culminada la captura de imágenes, se procedió con el procesamiento y etiquetado de imágenes siguiendo el esquema detallado en la Figura N°17 de clasificación y toma de imágenes donde se detallan los diferentes procedimientos realizados , donde , en inicio luego de la toma de video

y su procesamiento se obtuvo un total de 14769 imágenes o fotogramas con ayuda de herramientas como fue el media player VLC como se muestra en la Figura N°18 de Imágenes obtenidas y proceso de obtención , en la Figura N°19 se muestra el total de fotogramas de las cuales se tuvieron que depurar las que se encontraron deficientes ya sea por la calidad o el tipo de toma , una vez terminado este proceso se obtuvo un total de 646 entre baches, grietas longitudinales y piel de cocodrilo como se detalla en la Figura N°20 denominado Registro total de imágenes obtenidas luego del proceso de selección ; siguiendo el proceso de etiquetado de imágenes indicado en la Figura N°16 denominado Etapas de la obtención de imágenes.



**Figura 46.** *Proceso de Selección de Imágenes*

*Fuente:* Elaboración Propia

Se realizó el proceso de filtrado y etiquetado de imágenes con ayuda de la herramienta Robo Flow que es de acceso libre y gratuito donde se realizó el proceso de etiquetado de nuestras imágenes previamente seleccionadas donde para la realización de nuestro objetivo que es el etiquetado se realizaron diferentes procedimientos como la creación de la estructura de datos mostrado en la Figura N°22, la carga de datos como se muestra en la Figura N°23 y el procedimiento realizado para el etiquetado de imágenes mostrado en la Figura N°24 , seguido de estos procedimientos se realizó la obtención del Dataset como se muestra en la


Figura N°25 para realizar nuestro entrenamiento. Teniendo como resultado final un total de 646 imágenes distribuidos como se muestra en la tabla N°6.

**Tabla 6.** *Cantidad de Imágenes Obtenidas*

TIPO DE FALLA	CANTIDAD
PIEL DE COCODRILO	222
BACHE	204
GRIETA LONGITUDINAL	220
<b>TOTAL</b>	<b>646</b>

Fuente: Elaboración Propia

Los cuales representan el conjunto de datos que fueron sometidos a entrenamiento y validación siendo estos representados en cantidades de 516 para entrenamiento y 130 para validación mostrados en la Figura N°47 detallada a continuación:



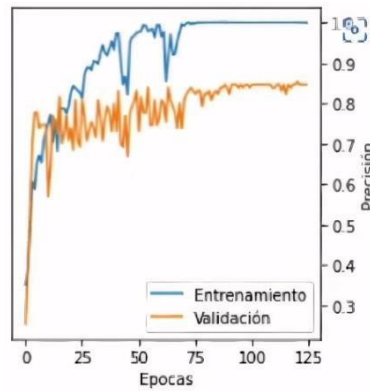
**Figura 47.** *Conjunto de Imágenes que Representa la Dataset*

Fuente: Elaboración Propia

Como podemos observar en la Figura N°47 nuestro dataset conto con un total de 646 imágenes de las cuales se realizará una designación de cantidades para el entrenamiento y validación correspondiente al 80% y 20% respectivamente demostrando así que se logró el correcto análisis de fallas que se encuentran en la superficie del pavimento flexible en sus respectivos tipos como son grietas longitudinales, piel de cocodrilo y baches respectivamente los cuales fueron llevados a nuestro desarrollador para poder realizar el correcto entrenamiento de nuestra red neuronal y lograr así el correcto diseño de nuestra red neuronal convolucional.


**OBJETIVO ESPECIFICO 3: “Evaluar los resultados obtenidos de la inspección realizada a la superficie del pavimento flexible usando las redes neuronales convolucionales , Juliaca 2023”;** Seguido de haber realizado el proceso de etiquetado y procesamiento de imágenes se procedió con el entrenamiento del modelo de red neuronal convolucional como se muestra en la Figura N°32 denominado Proceso de Entrenamiento de Red Neuronal Convolucional detallándose los pasos a ejecutar como la creación del entorno de desarrollador, el uso de JupyterLab y Python, Preparación del entorno así como la importación de las diferentes librerías a utilizar y por último el Entrenamiento del modelo ; dentro del proceso de entrenamiento se obtuvieron resultados favorables como se muestra en la Figura N°32 como es todo el proceso de entrenamiento de red neuronal convolucional realizado para la obtención de nuestros parámetros, como se obtuvo en la Figura N°39 donde podemos observar que seguido de la ejecución de nuestro algoritmo de carga de datos se obtuvo como resultado la carga total como son 204 en baches,220 en grieta longitudinal y 222 en piel de cocodrilo; también se obtuvo como resultado del modelo de red neuronal la compilación total de datos obteniéndose un

total de 1,258,499 parámetros listos para su entrenamiento como muestra en la Figura N°43 ; se obtuvo también la comparación de pérdida y precisión donde se logró obtener un índice de confiabilidad del 85% como se muestra en la figura N°43 logrando obtener este resultado de la ejecución de los algoritmos ya mencionados con anterioridad.



**Figura 48.** Validación y Entrenamiento

Fuente: Elaboración Propia



**Figura 49.** Precisión del Modelo

Fuente: Elaboración del Modelo

Como podemos apreciar en la Figura N°48 y 49 el modelo propuesto logra alcanzar un entrenamiento del 100 % y una confiabilidad total del 85% llegando a la conclusión




que nuestro modelo es apto para la predicción de fallas en la superficie del pavimento flexible.

En consecuencia, con el uso de los diferentes algoritmos y formas fijadas se logró alcanzar las dimensiones que se propusieron en la matriz de operacionalización de variables Anexo N°2 las cuales fueron algoritmo de red neuronal y la identificación de fallas en la superficie del pavimento flexible, logrando obtener como resultado la detección de las diferentes fallas como bache, grieta longitudinal y piel de cocodrilo, logrando hacerlo con una confiabilidad del 85% siendo esta aceptable.

**Matriz de confusión;** siendo este un analizador de gran importancia en el ambiente de la inteligencia artificial o también la denominada Deep Learning, permite evaluar los datos de la forma en la que trabaja un algoritmo de aprendizaje, nos facilita medir el desempeño de un determinado modelo de clasificación, analizando todos sus aciertos y errores, donde:

- VP: verdadero positivo, el modelo lo cataloga asignándole un signo de “+”
- VN: verdadero negativo, el modelo lo cataloga como si estos presentaran fallas asignándole el signo de “-”
- FN: falso negativo, el modelo lo cataloga como falla sobre el pavimento, indicando así un error “-”

- FP: falso positivo, el modelo lo cataloga como si estos presentaran fallas, dándole el signo de “+”, considerándose como un error en el calculo



**Figura 50.** Matriz de Confusión

Fuente: Mukhopadhyaye, 2021

- **EXACTITUD** →  $\frac{(VP+VN)}{(VP+FP+FN+VN)}$
- **PRECISION** →  $\frac{VP}{(VP+FP)}$
- **SENSIBILIDAD** →  $\frac{VP}{(VP+FN)}$
- **ESPECIFICAD** →  $\frac{VN}{(VN+FP)}$

#### IV. DISCUSIÓN

Los resultados que se obtuvieron del modelo entrenado son óptimos en cuanto a la detección de baches, grietas longitudinales y piel de cocodrilo hallados en la superficie del pavimento flexible de la ciudad de Juliaca , donde se logró alcanzar el 85% de confiabilidad o exactitud de manera general; para alcanzar la confiabilidad se realizó un conjunto de convoluciones dentro de un modelo de red neuronal convolucional haciendo uso de diferentes algoritmos y librerías , para de esa manera lograr alcanzar un óptimo entrenamiento de la red neuronal convolucional , de esta manera podemos apreciar que se realizaron algunos métodos de detección de las diferentes fallas en pavimento flexible similares a esta, tales como :

Según Tello Cifuentes y otros ( 2021) , quienes realizaron una investigación similar , alcanzando un nivel de exactitud general del 96% , realizando la evaluación de sus imágenes con un tamaño de 2624x3680 pixeles a velocidad similar de 30km/h, donde realizado su entrenamiento con 365 imágenes ya procesadas y debidamente etiquetadas; hizo uso de una red neuronal perceptrón multicapa ; la ejecución de este trabajo se llevó a cabo con un tamaño de imágenes de 1920x1088 pixeles a una velocidad de 25-30km/h , se realizó el entrenamiento con 646 imágenes debidamente etiquetadas y filtradas también haciendo uso de una red neuronal perceptrón multicapa ;encontrándose deficiencias en ambas investigaciones por la confusión o mala lectura de ciertas imágenes como baches con piel de cocodrilo o con las grietas las cuales ayudaron en la baja de la confiabilidad , se tuvo también la descripción de una técnica que usa las redes neuronales convolucionales y fotografía terrestre para

la evaluación de los diferentes fallas que se presentaron en la superficie del pavimento flexible .


Dentro de nuestra amplia compilación de antecedentes también tenemos a Madroño y Valencia (2019) , quienes realizaron una investigación de alguna manera similar, en su investigación encuentran que su modelo de red neuronal convolucional pone en funcionamiento su técnica para la detección de las diferentes patologías que encontró en la superficie del pavimento flexible realizándola con imágenes una dimensión de 30x30 correspondientemente para su proceso de validación y entrenamiento ; en cambio en nuestro modelo de red neuronal convolucional se realiza el proceso de entrenamiento y validación con imágenes de 150x150 pixeles ; usando la misma metodología de evaluación de imágenes pero haciendo uso de un desarrollador denominado Matlab el cual le brindo resultados óptimos ya que este también es considerado un desarrollador de alta confiabilidad en este tipo de trabajos , donde se realizó la detección de manera individual obteniendo resultados como 82% para baches y 70% para grietas , en el cual de manera general alcanza una confiabilidad admisible ; también se encontró un margen de error ocasionado por la confusión o una mala detección de ciertas imágenes las cuales al igual que en nuestro modelo presentado ocurren por la confusión al momento de leer nuestras imágenes, ya que algunas de estas presentaron marcas de llantas , entre otros .

También se contara con la evaluación de otra investigación de carácter similar ya que se emplea el mismo desarrollador para el entrenamiento de una red neuronal convolucional , donde según Ignacio (2022) quien realizó la ejecución de una metodología similar en el entrenamiento de red neuronal convolucional , realizo el

procedimiento de captación de imágenes de tamaño 5888 x 3584 pixeles siendo adaptadas a la medida de 256 x 256 pixeles para así realizar su entrenamiento sin ninguna dificultad , una vez realizado el procesamiento y el debido etiquetado de imágenes se obtuvo un dataset de 160 imágenes para el proceso de entrenamiento y posterior validación de la red neuronal de las pistas de asfalto a evaluar; en nuestra investigación se realizó con imágenes de 1920x1088 pixeles las cuales fueron adaptadas en el proceso de entrenamiento a 150x150 pixeles trabajando también con un dataset de 646 imágenes; para la realización de una buena focalización de imágenes y facilitar de esta manera la visualización de fallas en el pavimento Ignacio realizo la programación en el desarrollador Python ya que dicho programador viene ganando acogida en el ámbito de la evaluación de datos , el uso de algoritmos de redes neuronales convolucionales demostró tener un adecuado funcionamiento en la detección de grietas donde se logró alcanzar en esta investigación una exactitud del 98%, donde se puede ver que este procedimiento presenta niveles muy altos de asertividad así como exactitud , al igual que en nuestra investigación.

Se analizo también el proyecto de Zúñiga (2022) , donde se estableció que a través del Deep Learning la exploración de las diferentes patologías que se encontró en las vías asfaltadas del distrito de Villa María del Triunfo , evaluando la vía asfaltada de José Carlos Mariátegui , realizando una recolección de imágenes de manera especial en lo que son grietas y huecos con una cantidad en total de 420 imágenes de dimensiones 1920x1080 pixeles donde se trabajó con el desarrollador denominado YoloV5 aplicado con las diferentes librerías donde YoloV5 es un sistema que contiene código abierto el cual se podría decir es especialmente para el uso en lo que vendría a ser la detección de determinados objetos el cual es ya pre entrenado con el dataset

COCO, el cual hace uso solamente de una red neuronal convolucional para la detección de objetos en imágenes , en su proyecto se obtuvieron niveles de 85% de exactitud de manera general en lo que son grietas y huecos respectivamente; al igual que en este trabajo de investigación se lograron alcanzar un 85% de exactitud en lo que son grietas longitudinales, piel de cocodrilo y baches haciendo uso de Python siendo este también un desarrollador confiable para este tipo de trabajos.



**Figura 51. Confiabilidad**

*Fuente:* Elaboración Propia

Como se muestra en la Figura N°51 nuestro proyecto de investigación alcanzo un 85% de confiabilidad ubicándose así dentro de lo permitido.

Se logro determinar haciendo uso de la inteligencia artificial o el aprendizaje profundo la detección de diferentes fallas aplicando diferentes técnicas para la detección de determinados objetos en fotogramas e imágenes a través de la captura de las diferentes imágenes o toma de videos haciendo uso de un teléfono inteligente el cual fue hecha su implementación por Maeda (2018) donde también se obtuvieron resultados altamente significativos en la detección de fallas en pavimentos ; dentro de los cuales también fueron aplicados dentro de este trabajo de investigación el cual ayudo a la obtención de los objetivos trazados en este proyecto.

## V. CONCLUSIONES

En primera instancia se concluye que el procedimiento que se ha realizado para la detección de fallas en la superficie del pavimento flexible viene a ser una propuesta innovadora ya que realiza la detección de manera automática teniendo como base las imágenes obtenidas y el proceso de entrenamiento de redes neuronales como son las CNN para así lograr la clasificación de las diferentes fallas como son grietas longitudinales, piel de cocodrilo y baches; se pudo lograr evidenciar que este método es confiable y se puede hacer uso de ella ya que ayuda a reducir costos y el nivel de asertividad.

La propuesta de un modelo de red neuronal convolucional alcanza un porcentaje del 85% en exactitud para lo que es grietas longitudinales, piel de cocodrilo y baches de manera general, dentro de lo cual se tuvieron falsos positivos debido a la existencia de ciertas sombras y a ciertas zonas que presentan algún tipo de humedad sobre la superficie en el pavimento las cuales dificultaron de cierta manera la precisión.

Se logro la comprobación de nuestro objetivo general haciendo uso de nuestro adecuado procesamiento y etiquetado de imágenes, así como también el adecuado uso del lenguaje de programación denominado Python ya que reúne las condiciones y a lo largo del tiempo ha demostrado buenos resultados, gracias a lo cual se ha logrado alcanzar los objetivos.

## **VI. RECOMENDACIONES**

En primera instancia se recomienda que el proyecto realizado bajo los procedimientos propuestos sea considerado como una base dentro de proyectos futuros para realizar la automatización de procedimientos dentro de la ingeniería civil ya que nos permite reducir costo y tiempo en procedimientos determinados e incluso realizar ciertos trabajos sin darle importancia al clima.

Para una mejor precisión se recomienda tomar en cuenta algunas consideraciones para la hora de la obtención de las imágenes que sean en días con luz moderada constante, en días secos, cuando haya cantidad moderada de tráfico, ya que esos aspectos influyeron en el nivel de confiabilidad evidenciando así ciertas debilidades en la metodología propuesta.

Como se indica Python es una herramienta de desarrollador muy buena y de gran trayectoria en lo que son entrenamiento de modelos con redes neuronales convolucionales y los diferentes tipos de redes neuronales artificiales, pero este no es el único, se recomienda realizar futuros proyectos con alternativas de mejores desarrolladores en Machine Learning, Deep Learning.



## REFERENCIAS

1. **Lopez Saca, Fidel.** *Clasificación de imágenes usando redes neuronales convolucionales [ Tesis de Maestría , UNIVERSIDAD AUTÓNOMA METROPOLITANA].* Repositorio Institucional, s.l. : 2019.
2. **Ulloa, Norman Ismael Orellana.** *Categorización de daños georeferenciados de los ejes viales de la ciudad de Quito- Ecuador, usando algoritmos de inteligencia artificial y Python , 2022 [ Tesis de maestría, Universidad de Salzburg].* Repositorio digital, s.l. : 2022.
3. **Madroñero Urcuqui Jaime David, Valencia Lopez Yuri Catalina.** *Metodología para la identificación automática del deterioro en pavimento flexible , por medio de fotografías aéreas tomadas desde vehículos no tripulados , [ Tesis de pregrado , Universidad del Valle].* Repositorio institucional, s.l. : 2019.
4. **Rodríguez Lozano, Francisco J.** *Sistema automático para la detección y clasificación de grietas en pavimentos [ Tesis de pregrado, Universidad de Córdoba].* Repositorio Institucional, s.l. : 2020.
5. . **Tello Cifuentes , Lizette, y otros.** 50, 2021, TecnoLogicas, Vol. 24, págs. 1-13.  
*Evaluación de daños de pavimento flexible usando fotogrametría terrestre y redes neuronales*
6. . **Bayat, Ramin, y otros.** 62, 2023, Informacion, Vol. 14, págs. 1-23.  
*Redes neuronales artificiales para pavimento flexible*
7. **Vila Zuñiga, Rocio.** *Análisis del comportamiento lineal de la estructura del pavimento flexible mediante redes neuronales en la carretera Panamericana*

Norte [ Tesis de Pregrado , Universidad Nacional del Centro del Peru].  
Repositorio Institucional, s.l. : 2017.

**8. Murrugarra Sanchez, Ana Liliana y Ruiz Olortegui, Jenny Yadira.**  
*Caracterización del uso de modelos de deterioro para optimizar la gestión del mantenimiento de carreteras, Cajamarca, 2020*[ Tesis de Pregrado ,  
Universidad Privada del Norte]. Repositorio Institucional, s.l. : 2020.

**9. Paytán Ordoñez, Jhonatan.** *Estimación del Índice de Regularidad Internacional en Pavimentos Flexibles Usando Redes Neuronales Artificiales*[  
Tesis de Pregrado , Universidad ]. Repositorio Institucional, s.l. : 2018.

**10. Zúñiga Guisado, Yenmy.** *Deep Learning para la detección de fallas en pavimentos de una zona del distrito de Villa María del Triunfo 2022*[ ]Tesis de  
Pregrado , Universidad Cesar Vallejo. Repositorio Institucioonal, s.l. : 2022.

**11. Ortega Alarcon, Deyvi.** *Software para la evaluación superficial de pavimentos flexibles basado en la metodología Pavement Condition Index*[  
Tesis de Pregrado , Universidad Catolica San Pablo]. Repositorio Institucional,  
s.l. : 2021.

**12. Reyes Ortiz, Oscar Javier, Mejia, Marcela y Useche Castelblanco, Juan Sevástian.** 31, 2019, Revista EIA, Vol. 16, págs. 189 -207.

*Técnicas de inteligencia artificial utilizadas en el procesamiento de imágenes y su aplicación en el análisis de pavimentos.*

**13. . Abdalrahman, Milad, Majeed, Sayf A. y Nur Izzi Md, Yusoff a.** 10, 2020,  
Revista de Ingenieria Civil, Vol. 6, págs. 1895-1905.

*Estudio comparativo de la utilización de redes neuronales y  
Metodología de Superficie de Respuesta para Pavimentos Flexibles  
Tratamientos de mantenimiento*

14. **Llopis Castello, David.** Evaluacion del pavimento mediante Inteligencia Artificial . *La carretera como forma de vida*. [En línea] 2 de mayo de 2020. <https://dalocas.blogs.upv.es/2020/05/02/evaluacion-del-pavimento-mediante-inteligencia-artificial/>.
15. *Uso de redes neurales artificiales para predecir las molestias del pavimento flexible.* **Badr , Zahran, El gendy, Mohamed y El Refaey, Mohamed.** 62, 2022, Revista del Sector de Ingeniería de la Universidad AlAzhar, Vol. 17, págs. 17-25.
16. **Calvo, Diego.** Red Neuronal Convolutacional CNN . *Diego Calvo*. [En línea] 20 de julio de 2017. <https://www.diegocalvo.es/red-neuronal-convolutacional/>.
17. **La Libreria del Ingeniero.** Conceptos Basicos de Pavimentos . *La Libreria del Ingeniero* . [En línea] 2023. [https://www.libreriaingeniero.com/2020/06/conceptos-basicos-de-pavimentos.html#Pavimentos\\_Flexibles](https://www.libreriaingeniero.com/2020/06/conceptos-basicos-de-pavimentos.html#Pavimentos_Flexibles).
18. **Ministerio de Transporte y Comunicaciones Republica del Peru.** *Manual Tecnico de Mantenimiento Rutinario para la Red Vial Departamental no Pavimentada*. Lima : s.n., 2006.
19. **León , Ryan, y otros.** 1, Trujillo : s.n., 2020, Ciencia y Tecnologia, Vol. 16, págs. 21-32. *Deteccion y extraccion de muestras falladas usando vision artificial y un brazo robotico*.
20. **Arriola Oregui, Ignacio.** *Deteccion de objetos basada en Deep Learning y aplicada a vehiculos autónomos [ Tesis de maestria,Universidad del pais Vasco]*. repositorio institucional, España : 2018.

21. **Ignacio Soto, Percy Robustiano.** *Identificación automática de las grietas en pistas de asfalto utilizando procesamiento digital de imágenes [ tesis de pregrado , Universidad Señor de Sipan].* repositorio institucional, s.l. : 2022.
22. **Ander-Egg Hernández, Ezequiel.** *Aprender a investigar .* s.l. : Editorial Brujas, 2011.
23. **Guillen Valle, Oscar Rafael, Sánchez Camargo, Mario Rodolfo y Begazo de Bedoya, Luis Hernando.** *Pasos para elaborar una tesis de tipo correlacional.* [ed.] Oscar Rafael Guillen Valle. 2020.
24. **Abdullah, salwani y Nezhad, Majid Abdolrazzagh.** 2014, Ciencias de la Informacion, Vol. 278, págs. 380-407.  
*Problemas confusos de programacion de talleres:una revision.*
25. **Almási, Adela Diana, y otros.** 2016, Neurocomputacion, Vol. 174, págs. 31-41.*Revisión de avances en redes neuronales: pila de tecnología de diseño neuronal.*
26. . **Galdámez, Pedro Luis, Raveane, Guillermo y Gonzales Arrieta, Angelica.** 2017, Journal of Applied Logic, Vol. 24, págs. 62-70.  
*Una breve revisión del proceso de reconocimiento de oído mediante redes neuronales profundas*
27. **Banitalebi, Akbar, y otros.** 2015, Ciencias de la información, Vol. 298, págs. 491-511. *Colonia de abejas artificial compacta mejorada.*
28. **Bayar, Nawel , y otros.** 2015, Aplicaciones de Ingenieria de la inteligencia Aritificial, Vol. 46, págs. 43-57. *Detección, diagnóstico y recuperación de fallas mediante sistemas inmunológicos artificiales: una revisión.*
29. **Tamayo y Tamayo, Mario.** *El Proceso de la Investigacion Cientifica.* s.l. : Editorial Limusa S.A. de C.V., 2003.

30. **Menéndez Acurio, Rafael.** *Ingeniería de Pavimentos Materiales , Diseño y Conservación.* s.l. : Instituto de la construcción y gerencia, 2012.
31. **Pixelabs.** Pixelabs. [En línea] 29 de Septiembre de 2021.  
<https://pixelabs.es/que-son-las-redes-neuronales-convolucionales-parte-2/>.
32. **Lopez, Ruben .** WordPress. [En línea] 7 de mayo de 2014.  
<https://rubenlopezg.wordpress.com/2014/05/07/que-es-y-como-funciona-deep-learning/>.
33. **KeepCoding.** KeepCoding Tech School. [En línea] 8 de enero de 2024.  
<https://keepcoding.io/blog/tipos-capas-red-neuronal-convolucional/>.

## ANEXOS

### ANEXO 1

#### Operacionalización de Variables

	DEFINICION CONCEPTUAL	DEFINICION OPERACIONAL	INDICADORES	ESCALA DE MEDICION
<b>V.I. RED NEURONAL CONVOLUCIONAL</b>	Debido al aumento de costos en rehabilitaciones , mantenimientos y ejecución de vías, analizar las estructuras y superficie del pavimento para de esa manera precisar su propio comportamiento y sus particularidades propias es que la inteligencia artificial se ha vuelto un ámbito de mucha relevancia en la ingeniería civil, para el análisis de estas imágenes se vienen desarrollando herramientas que ayudan a la simplificación de estos trabajos y as poder automatizarlos en gran escala causando así mayor velocidad en entrega de resultados y menor costo.(Reyes, Mejía y Useche,2019)	Una red neuronal convolucional consta de variables capas de filtros en o más dimensiones. Después de cada status, en su mayoría se inserta una función para de esa manera lograr un mapeo, en la red de clasificación primero se tendrá una fase de extracción que tiene neuronas de convolución y neuronas de reducción de resolución. Finalmente encontraremos una neurona perceptrón simple que realiza la categorización final de las particularidades extraídas. Esta fase consta decapas alternas de convolución y neuronas de reducción de resolución. Mientras estos datos avanzan a través de esta fase, su dimensionalidad disminuye y las neuronas en capas distantes disminuyen su sensibilidad a las alteraciones en la información de entrada, pero de igual manera se activan por propiedades cada vez más profundas y complejas	<ul style="list-style-type: none"> <li>• instrucción automatizada</li> <li>• variedad de capas</li> <li>• datos (imágenes)</li> <li>• modelos</li> <li>• efectos</li> <li>• efectos futuros</li> <li>• algoritmos.</li> </ul>	<ul style="list-style-type: none"> <li>• ordinal</li> </ul>
<b>V.D. PAVIMENTO FLEXIBLE</b>	Lo importante de las propiedades de la superficie del pavimento flexible radica sobre todo en su influencia en el correcto funcionamiento, conformando así las únicas propiedades de interés para el usuario, ya que debido a ellas dependen en gran parte la seguridad y el confort necesario para el área usuaria, de manera estética también hay un impacto en el entorno urbano afectando de esta manera a los peatones y también a los residentes (Menéndez, 2012, p. 271).	Las diferentes fallas a encontrar en la superficie del pavimento flexible se determinarán a través de su profundidad y longitud, estas fallas son causadas por el aumento de tráfico, condiciones climáticas, procesos constructivos o también malos mantenimientos anteriores.	<ul style="list-style-type: none"> <li>• tipo de daño</li> <li>• medidas</li> <li>• severidad</li> </ul>	<ul style="list-style-type: none"> <li>• nominal</li> </ul>

## ANEXO 2

### Matriz de Consistencia

PROBLEMA	OBJETIVOS	HIPOTESIS	VARIABLES	DIMENSIONES	INDICADORES	ESCALA	METODOLOGIA
<b>PROBLEMA GENERAL</b> ¿Cómo realizar una inspección automatizada de la superficie de pavimento flexible con el uso de redes neuronales convolucionales, Juliaca 2023 ?	<b>OBJETIVO GENERAL</b> Diseñar una red neuronal convolucional para realizar una inspección automatizada de la superficie de pavimento flexible haciendo uso de redes neuronales convolucionales, Juliaca 2023	<b>HIPOTESIS GENERAL</b> Es posible realizar una inspección automatizada de la superficie del pavimento flexible con el uso de redes neuronales convolucionales, Juliaca 2023	<b>VARIABLE INDEPENDIENTE RED NEURONAL CONVOLUCIONAL</b>	Algoritmo de Red Neuronal Convolucional	-Instrucción automatizada -Variedad de capas - Datos (imágenes) - Modelos -Efectos -Algoritmos	Ordinal	
<b>PROBLEMA ESPECIFICO 1</b> ¿De qué manera se realizará la detección de las fallas de la superficie del pavimento flexible haciendo uso de redes neuronales convolucionales, Juliaca 2023?	<b>OBJETIVO ESPECIFICO 1</b> Determinar las fallas que se encuentran en la superficie del pavimento flexible haciendo uso de las redes neuronales convolucionales , Juliaca 2023	<b>HIPOTESIS ESPECIFICA 1</b> La utilización de redes neuronales convolucionales permite la detección de las diferentes fallas de la superficie del pavimento flexible , Juliaca 2023			Tipo de daños		Tipo de investigación: Aplicada Nivel de investigación: Descriptiva Diseño de Investigación: Pre experimental Enfoque de Investigación: Cuantitativa Población: las calles pavimentadas de la ciudad de Juliaca siendoun total de 180km
<b>PROBLEMA ESPECIFICO 2</b> ¿Cómo realizar una buena elección de la red neuronal convolucional para realizar la inspección de las fallas en la superficie del pavimento flexible , Juliaca 2023?	<b>OBJETIVO ESPECIFICO 2</b> Analizar las fallas que se encuentran en la superficie del pavimento flexible con el uso de las redes neuronales convolucionales ,Juliaca 2023	<b>HIPOTESIS ESPECIFICA 2</b> Realizar una adecuada inspección de las fallas encontradas en la superficie del pavimento flexible con el uso de las redes neuronales convolucionales, Juliaca 2023	<b>VARIABLE DEPENDIENTE PAVIMENTO FLEXIBLE</b>	Identificación y selección de fallas en la superficie del pavimento flexible	Cantidad	Nominal	
<b>PROBLEMA ESPECIFICO 3</b> ¿Cómo mejorar la inspección de las fallas en pavimentos flexibles haciendo uso de las redes neuronales convolucionales, Juliaca 2023?	<b>OBJETIVO ESPECIFICO 3</b> Evaluar los resultados obtenidos de la inspección realizada a la superficie del pavimento flexible usando las redes neuronales convolucionales , Juliaca 2023	<b>HIPOTESIS ESPECIFICA 3</b> Las redes neuronales convolucionales realizan una adecuada validación de datos para poder proceder con un mantenimiento adecuado, Juliaca 2023.			Severidad		

**ANEXO 3**

**ANEXO 3**



**VALIDACION DE EXPERTOS**

**I. DATOS GENEALES**

Apellidos y Nombres del Experto: **Mamani Apaza Wilber**  
 Título y Grado Académico: **Ingeniero Civil**  
 C.I.P. : **73003**  
 Fecha: **27/02/2024**

**TITULO DEL PROYECTO:**

**"INSPECCION AUTOMATIZADA DE LA SUPERFICIE DEL PAVIMENTO FLEXIBLE CON EL USO DE REDES NEURONALES CONVOLUCIONALES, JULIACA 2023"**

**AUTOR:** Rosmeri Glenda Mamani Coasaca

**II. PROPOSITO DE EVALUACION**

Dar validez al contenido del instrumento, por juicio de expertos.

**III. CONSIDERACIONES PARA LA EVALUACION / SOPORTE TEORICO**

N°	DIMENSIONES	PERTINENCIA		RELEVANCIA		CLARIDAD		OBSERVACIONES
		SI	NO	SI	NO	SI	NO	
1	<b>INDICADOR 1: ALGORITMO DE RED NEURONAL CONVOLUCIONAL</b> Instrucción automatizada Variedad de capas Datos (imágenes) Modelos Efectos Algoritmos	X		X		X		
2	<b>INDICADOR 2: IDENTIFICACION Y SELECCION DE FALLAS EN LA SUPERFICIE DEL PAVIMENTO FLEXIBLE</b> Tipo de daño Severidad Cantidad	X		X		X		

**Opinión de aplicabilidad:**

Aplicable (  ) Aplicable luego de ser corregido (  ) No aplicable (  )

**Pertinencia:** Corresponde el concepto teórico formulado.

**Relevancia:** Es apropiado para representar al componente o dimensión específica.

**Claridad:** Sin dificultad alguna, es conciso, claro y directo.




**IV. CRITERIOS DE EVALUACION**

A continuación, presento ante Ud. El siguiente cuestionario, de acuerdo con los siguientes indicadores califique cada uno de los ítems según corresponda:

DEFICIENTE	REGULAR	BUENO	MUY BUENO	EXCELENTE
0-20	21-50	51-70	71-85	85-100

	CRITERIO	PUNTUACION				
		0-20	21-50	51-70	71-85	85-100
<b>CLARIDAD</b>	Es formulado con el lenguaje adecuado				80	
<b>OBJETIVIDAD</b>	Esta expresado en la conducta observable				80	
<b>ACTUALIDAD</b>	Es adecuado de acuerdo a la ciencia y tecnología				80	
<b>ORGANIZACIÓN</b>	Existe una organización lógica				80	
<b>SUFICIENCIA</b>	Comprende los aspectos de calidad y cantidad				80	
<b>INTENCIONALIDAD</b>	Adecuado para valorar los aspectos del sistema metodológico y científico				80	
<b>CONSISTENCIA</b>	Está basado en conceptos teóricos y científicos				80	
<b>COHERENCIA</b>	En datos en relación al objetivo				80	
<b>METODOLOGIA</b>	Responde al propósito de la investigación				80	
<b>PERTENENCIA</b>	El instrumento es el adecuado de acuerdo a la investigación				80	

**V. PROMEDIO DE EVALUACION**

80



.....  
**FIRMA DEL EXPERTO**

**VALIDACION DE EXPERTOS**

**I. DATOS GENEALES**

Apellidos y Nombres del Experto: DIONY MAMANI CALLOAPAZA  
 Título y Grado Académico: INGENIERO CIVIL  
 C.I.P. : 308417  
 Fecha: 23-02-2024

**TITULO DEL PROYECTO:**

**"INSPECCION AUTOMATIZADA DE LA SUPERFICIE DEL PAVIMENTO FLEXIBLE CON EL USO DE REDES NEURONALES CONVOLUCIONALES, JULIACA 2023"**

**AUTOR:** Rosmeri Glenda Mamani Coasaca

**II. PROPOSITO DE EVALUACION**

Dar validez al contenido del instrumento, por juicio de expertos.

**III. CONSIDERACIONES PARA LA EVALUACION / SOPORTE TEORICO**

N°	DIMENSIONES	PERTINENCIA		RELEVANCIA		CLARIDAD		OBSERVACIONES
		SI	NO	SI	NO	SI	NO	
1	<b>INDICADOR 1: ALGORITMO DE RED NEURONAL CONVOLUCIONAL</b>	X		X		X		
	Instrucción automatizada Variedad de capas Datos (imágenes) Modelos Efectos Algoritmos					X		
2	<b>INDICADOR 2: IDENTIFICACION Y SELECCIÓN DE FALLAS EN LA SUPERFICIE DEL PAVIMENTO FLEXIBLE</b>	X		X				
	Tipo de daño Severidad Cantidad							

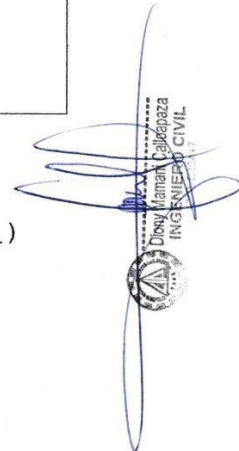
**Opinión de aplicabilidad:**

Aplicable (X)    Aplicable luego de ser corregido ( \_ )    No aplicable ( \_ )

**Pertinencia:** Corresponde el concepto teórico formulado.

**Relevancia:** Es apropiado para representar al componente o dimensión específica.

**Claridad:** Sin dificultad alguna, es conciso, claro y directo.



Diony Mamani Calloapaza  
INGENIERO CIVIL

**IV. CRITERIOS DE EVALUACION**

A continuación, presento ante Ud. El siguiente cuestionario, de acuerdo con los siguientes indicadores califique cada uno de los ítems según corresponda:

DEFICIENTE	RÉGULAR	BUENO	MUY BUENO	EXCELENTE
0-20	21-50	51-70	71-85	85-100

	CRITERIO	PUNTUACION				
		0-20	21-50	51-70	71-85	85-100
<b>CLARIDAD</b>	Es formulado con el lenguaje adecuado				75	
<b>OBJETIVIDAD</b>	Esta expresado en la conducta observable				78	
<b>ACTUALIDAD</b>	Es adecuado de acuerdo a la ciencia y tecnología				80	
<b>ORGANIZACIÓN</b>	Existe una organización lógica				80	
<b>SUFICIENCIA</b>	Comprende los aspectos de calidad y cantidad				80	
<b>INTENCIONALIDAD</b>	Adecuado para valorar los aspectos del sistema metodológico y científico				80	
<b>CONSISTENCIA</b>	Está basado en conceptos teóricos y científicos				80	
<b>COHERENCIA</b>	En datos en relación al objetivo				80	
<b>METODOLOGIA</b>	Responde al propósito de la investigación				80	
<b>PERTENENCIA</b>	El instrumento es el adecuado de acuerdo a la investigación				80	

**V. PROMEDIO DE EVALUACION**

79
----




 Diony Mamani Cachoapaza  
 INGENIERO CIVIL  
 C.R. 308417

**FIRMA DEL EXPERTO**

## VALIDACION DE EXPERTOS

## I. DATOS GENEALES

Apellidos y Nombres del Experto: *Rosendo Flores Cusi*  
 Título y Grado Académico: *Ingeniero Civil*  
 C.I.P. : *144579*  
 Fecha: *23-02-2024*

## TITULO DEL PROYECTO:

"INSPECCION AUTOMATIZADA DE LA SUPERFICIE DEL PAVIMENTO FLEXIBLE CON EL USO DE REDES NEURONALES CONVOLUCIONALES, JULIACA 2023"

AUTOR: Rosmeri Glenda Mamani Coasaca

## II. PROPOSITO DE EVALUACION

Dar validez al contenido del instrumento, por juicio de expertos.

## III. CONSIDERACIONES PARA LA EVALUACION / SOPORTE TEORICO

N°	DIMENSIONES	PERTINENCIA		RELEVANCIA		CLARIDAD		OBSERVACIONES
		SI	NO	SI	NO	SI	NO	
1	<b>INDICADOR 1: ALGORITMO DE RED NEURONAL CONVOLUCIONAL</b> Instrucción automatizada Variedad de capas Datos (imágenes) Modelos Efectos Algoritmos	X		X		X		
2	<b>INDICADOR 2: IDENTIFICACION Y SELECCIÓN DE FALLAS EN LA SUPERFICIE DEL PAVIMENTO FLEXIBLE</b> Tipo de daño Severidad Cantidad	X		X		X		

## Opinión de aplicabilidad:

Aplicable (X) Aplicable luego de ser corregido ( \_ ) No aplicable ( \_ )

**Pertinencia:** Corresponde el concepto teórico formulado.

**Relevancia:** Es apropiado para representar al componente o dimensión específica.

**Claridad:** Sin dificultad alguna, es conciso, claro y directo.

  
 Ing. Rosendo Flores Cusi  
 CIP: 144579

**IV. CRITERIOS DE EVALUACION**

A continuación, presento ante Ud. El siguiente cuestionario, de acuerdo con los siguientes indicadores califique cada uno de los ítems según corresponda:

DEFICIENTE	REGULAR	BUENO	MUY BUENO	EXCELENTE
0-20	21-50	51-70	71-85	85-100

	CRITERIO	PUNTUACION				
		0-20	21-50	51-70	71-85	85-100
CLARIDAD	Es formulado con el lenguaje adecuado				80	
OBJETIVIDAD	Esta expresado en la conducta observable				80	
ACTUALIDAD	Es adecuado de acuerdo a la ciencia y tecnología				80	
ORGANIZACIÓN	Existe una organización lógica				80	
SUFICIENCIA	Comprende los aspectos de calidad y cantidad				80	
INTENCIONALIDAD	Adecuado para valorar los aspectos del sistema metodológico y científico				80	
CONSISTENCIA	Está basado en conceptos teóricos y científicos				80	
COHERENCIA	En datos en relación al objetivo				80	
METODOLOGIA	Responde al propósito de la investigación				80	
PERTENENCIA	El instrumento es el adecuado de acuerdo a la investigación				80	


**V. PROMEDIO DE EVALUACION**

80


**FIRMA DEL EXPERTO**

## ANEXO 4


Ubicación del tramo recorrido para la obtención de imágenes




### LEYENDA

- 1: Mapa de la Ciudad de Juliaca
- 2: Tramo evaluado, conformado entre el jirón mi Perú y la I.E. Central Esquen

← Videos en mapa  
glenrouzs.mc.95@gmail.com



Mis videos  Video público





## PANEL FOTOGRAFICO



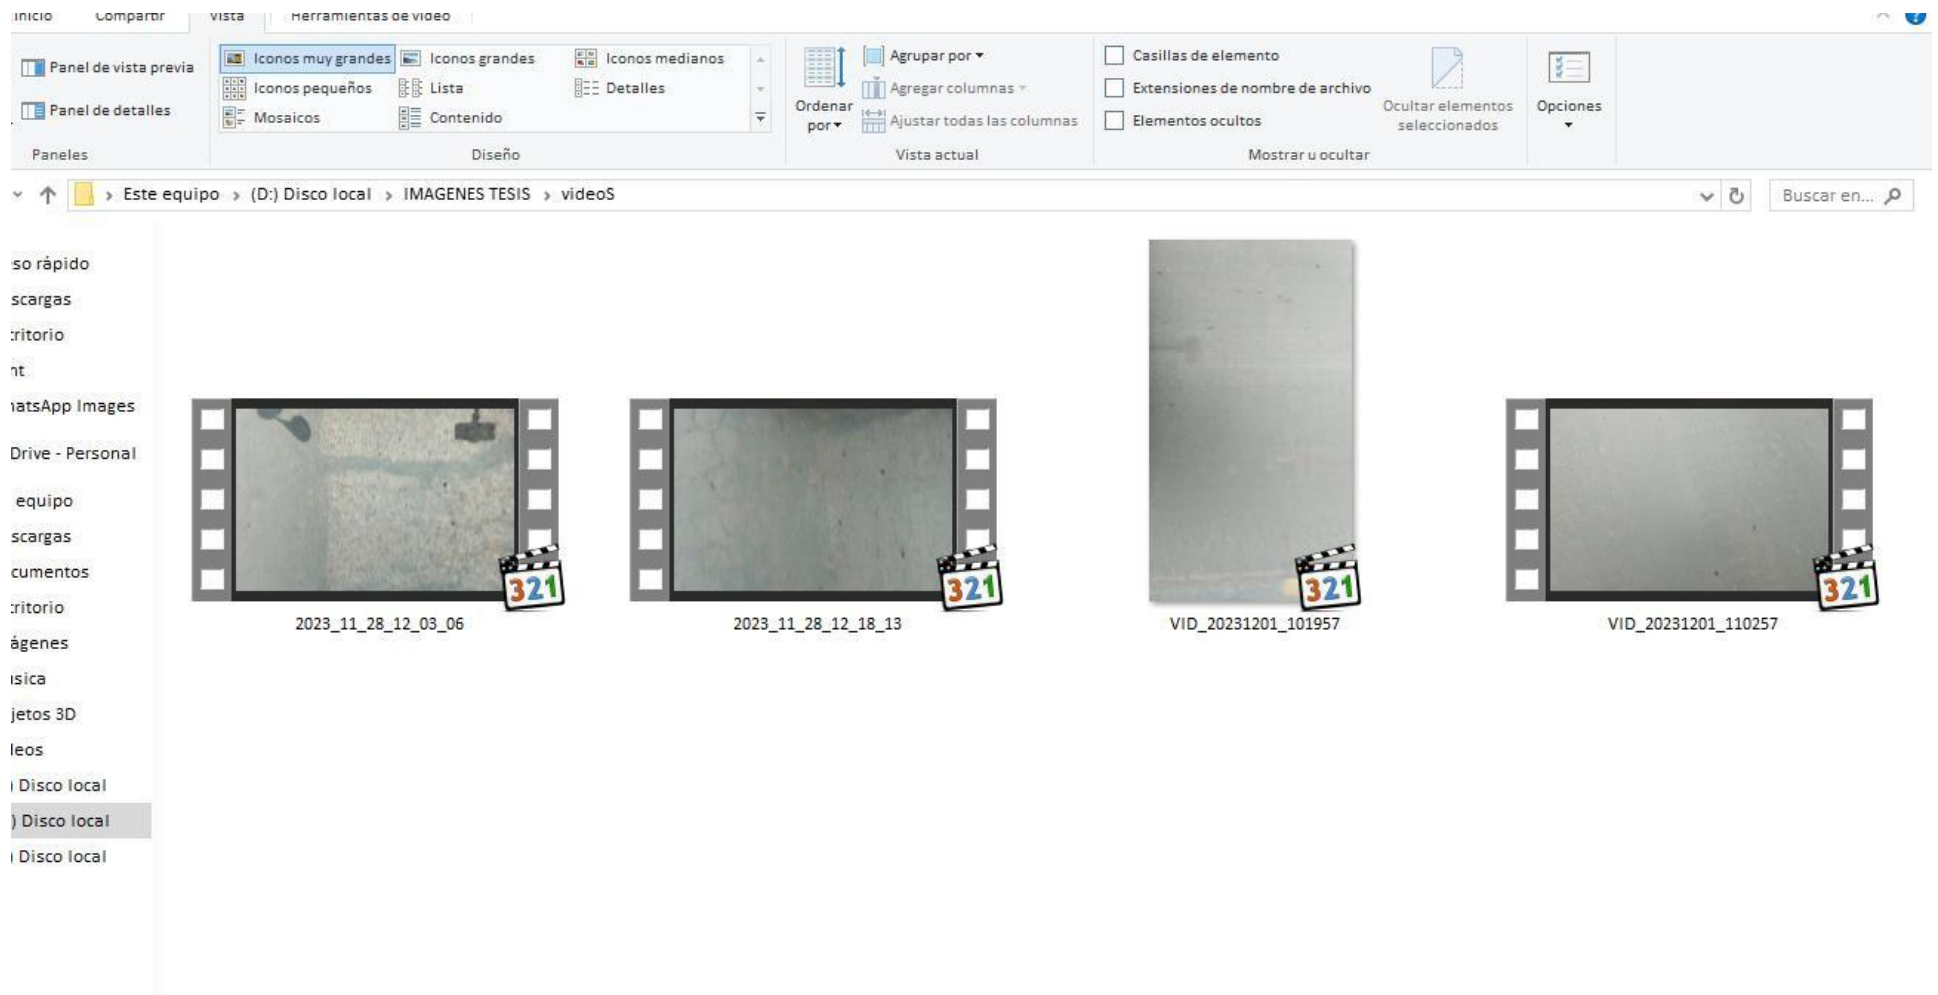













# ANEXO 5

## Obtencion de Imágenes





## ANEXO 6

Selección de imágenes



ENTRENAMIENTO



VALIDACION



BACHE



GRIETA  
LONGITUDINAL



PIEL DE  
COCODRILO

# ANEXO 7

## Etiquetado y dataset

### Let's create your project.

DATOS > [New Public Project](#)

Project Name


DATOS\_1

License <sup>Ⓢ</sup>

CC BY 4.0

Project Type

Classification Type  Single-Label  Multi-Label



**Object Detection**

Identify objects and their positions with bounding boxes.

Best For

# Counting Tracking




**Classification**

Assign labels to the entire image.

Best For

Filtering  Content Moderation



**Instance Segmentation**

Detect multiple objects and their actual shape.

Best For

Measurements Odd Shapes

Show More

Annotation Group <sup>Ⓢ</sup>

fallas

Cancel

Create Public Project

DATOS



DATOS\_1

Classification

Data

Classes 1

Upload Data

Assign Images

Annotate

Dataset 0

Health Check

## PIEL DE COCODRILO

Start Annotating

Add to Dataset



### Progress



240 Images

0 Annotated  
240 Unannotated

### Instructions

Edit

No specific instructions were added when this job was assigned

### Assignment


glenda mamani  
Labeler Reassign

### Timeline

glenda mamani created this Job and assigned it to glendamamani661@gmail.com. 23/2/2024, 15:46:36

Unannotated 240

Annotated 0



### Annotations

Group: fallas

#### CLASSES

- piel de cocodrilo 0

#### UNUSED CLASSES

- Unlabeled
- bache
- grieta longitudinal

#### Tags


- bache x
- grieta-longitudinal x
- piel-de-cocodrilo x

### Annotation Editor

piel de cocodrilo

Cancel (Esc) Save (Enter)

- 1 bache
- 2 grieta longitudinal
- 3 piel de cocodrilo
- 4 Unlabeled



- |          |          |          |          |          |          |          |          |           |           |           |           |
|----------|----------|----------|----------|----------|----------|----------|----------|-----------|-----------|-----------|-----------|
| img (1)  | img (10) | img (20) | img (29) | img (42) | img (51) | img (61) | img (70) | img (80)  | img (100) | img (110) | img (119) |
| img (1)  | img (11) | img (20) | img (30) | img (42) | img (52) | img (61) | img (71) | img (80)  | img (101) | img (110) | img (120) |
| img (2)  | img (11) | img (21) | img (30) | img (43) | img (52) | img (62) | img (71) | img (81)  | img (101) | img (111) | img (120) |
| img (2)  | img (12) | img (21) | img (31) | img (43) | img (53) | img (62) | img (72) | img (81)  | img (102) | img (111) | img (121) |
| img (3)  | img (12) | img (22) | img (31) | img (44) | img (53) | img (63) | img (72) | img (82)  | img (102) | img (112) | img (121) |
| img (3)  | img (13) | img (22) | img (32) | img (44) | img (54) | img (63) | img (73) | img (82)  | img (103) | img (112) | img (122) |
| img (4)  | img (13) | img (23) | img (32) | img (45) | img (54) | img (64) | img (73) | img (83)  | img (103) | img (113) | img (122) |
| img (4)  | img (14) | img (23) | img (33) | img (45) | img (55) | img (64) | img (74) | img (83)  | img (104) | img (113) | img (123) |
| img (5)  | img (14) | img (24) | img (33) | img (46) | img (55) | img (65) | img (74) | img (84)  | img (104) | img (114) | img (123) |
| img (5)  | img (15) | img (24) | img (34) | img (46) | img (56) | img (65) | img (75) | img (84)  | img (105) | img (114) | img (124) |
| img (6)  | img (15) | img (25) | img (34) | img (47) | img (56) | img (66) | img (75) | img (85)  | img (105) | img (115) | img (124) |
| img (6)  | img (16) | img (25) | img (38) | img (47) | img (57) | img (66) | img (76) | img (85)  | img (106) | img (115) | img (125) |
| img (7)  | img (16) | img (26) | img (38) | img (48) | img (57) | img (67) | img (76) | img (86)  | img (106) | img (116) | img (125) |
| img (7)  | img (17) | img (26) | img (39) | img (48) | img (58) | img (67) | img (77) | img (86)  | img (107) | img (116) | img (126) |
| img (8)  | img (17) | img (27) | img (39) | img (49) | img (58) | img (68) | img (77) | img (87)  | img (107) | img (117) | img (126) |
| img (8)  | img (18) | img (27) | img (40) | img (49) | img (59) | img (68) | img (78) | img (87)  | img (108) | img (117) | img (127) |
| img (9)  | img (18) | img (28) | img (40) | img (50) | img (59) | img (69) | img (78) | img (99)  | img (108) | img (118) | img (127) |
| img (9)  | img (19) | img (28) | img (41) | img (50) | img (60) | img (69) | img (79) | img (99)  | img (109) | img (118) | img (128) |
| img (10) | img (19) | img (29) | img (41) | img (51) | img (60) | img (70) | img (79) | img (100) | img (109) | img (119) | img (128) |

## ANEXO 8

Inicio de Programación

ANACONDA. Plataforma Soluciones Precios Socios Recursos Compañía Iniciar sesión Contacto

### Distribución Anaconda

# Descarga gratis

Todo lo que necesitas para iniciarte en la ciencia de datos en tu estación de trabajo.

- ✓ Instalación de distribución gratuita
- ✓ Miles de los paquetes DS, AI y ML más básicos
- ✓ Administre paquetes y entornos desde la aplicación de escritorio
- ✓ Implementación en plataformas de hardware y software

Descargar

Obtenga instaladores adicionales

Windows | Apple | Linux

Hey! 🌟 Welcome back. Can I help you find something today?

## Creacion del entorno de trabajo y descarga de librerias

Create new environment ✕

Name:

Location: *C:\Users\Hp\anaconda3\envs\RGMC-IC*

Packages:  Python

R

The screenshot shows the Anaconda Navigator interface. The top left features the Anaconda Navigator logo and a navigation sidebar with options: Home, Environments (selected), Learning, and Community. The top right shows 'Connected to Cloud' and a 'Connect' button. The main area is divided into two panes. The left pane, titled 'Search Environments', lists the following environments: 'base (root)', 'RGMC-IC' (highlighted with a green play button), 'UCV', and 'labelme'. The right pane, titled 'Not installed', shows a list of packages with columns for Name, Description, and Version. The packages listed are:

Name	Description	Version
7za	Open-source file archiver primarily used to compress files	920
7zip	7-zip is a file archiver with a high compression ratio.	19.00
_anaconda_depends	Simplifies package management and deployment of anaconda	2024.0...
_go_select	The golang select package.	2.3.0
_ipyw_lab_nb_ex...	A configuration metapackage for enabling anaconda-bundled jupyter extensions	0.1.0
_libarchive_stati...	A static build of libarchive containing only conda-related parts	3.6.1

Anaconda Navigator

File Help



















**ANACONDA**.NAVIGATOR




Upgrade Now Connected to Cloud Connect

Home


Environments Learning Community

All applications on RGMCI-C Channels

 <p><b>DataSpell</b></p> <p>DataSpell is an IDE for exploratory data analysis and prototyping machine learning models. It combines the interactivity of Jupyter notebooks with the intelligent Python and R coding assistance of PyCharm in one user-friendly environment.</p> <p><a href="#">Install</a></p>	 <p><b>Anaconda Toolbox</b> 0.4.0 Anaconda Assistant</p> <p>JupyterLab supercharged with a suite of Anaconda extensions, starting with the Anaconda Assistant AI chatbot.</p> <p><a href="#">Install</a></p>	 <p><b>Anaconda Cloud Notebooks</b></p> <p>Cloud-hosted notebook service from Anaconda. Launch a preconfigured environment with hundreds of packages and store project files with persistent cloud storage.</p> <p><a href="#">Launch</a></p>	 <p><b>JupyterLab</b> 4.0.11</p> <p>An extensible environment for interactive and reproducible computing, based on the Jupyter Notebook and Architecture.</p> <p><a href="#">Launch</a></p>	 <p><b>Notebook</b> 7.0.6</p> <p>Web-based, interactive computing notebook environment. Edit and run human-readable docs while describing the data analysis.</p> <p><a href="#">Launch</a></p>	 <p><b>anaconda</b></p> <p>Anaconda on AWS Graviton</p> <p>Running your Anaconda workloads on AWS Graviton-based processors could provide up to 40% better price performance</p> <p><a href="#">Launch</a></p>
 <p><b>Datalore</b></p> <p>Kick-start your data science projects in seconds in a pre-configured environment. Enjoy coding assistance for Python, SQL, and R in Jupyter notebooks and benefit from no-code automations. Use Datalore online for free.</p> <p><a href="#">Launch</a></p>	 <p><b>watsonx</b></p> <p>IBM watsonx is an enterprise-ready AI platform including a data store, model builder, and AI model management and monitoring.</p> <p><a href="#">Launch</a></p>	 <p><b>ORACLE</b> Cloud Infrastructure</p> <p>Oracle Data Science Service</p> <p>OCI Data Science offers a machine learning platform to build, train, manage, and deploy your machine learning models on the cloud with your favorite open-source tools</p> <p><a href="#">Launch</a></p>	 <p><b>CMD.exe Prompt</b> 0.1.1</p> <p>Run a cmd.exe terminal with your current environment from Navigator activated</p> <p><a href="#">Install</a></p>	 <p><b>console_shortcut_miniconda</b> 0.1.1 Anaconda Powershell Prompt</p> <p><a href="#">Install</a></p>	 <p><b>Glueviz</b> 1.2.4</p> <p>Multidimensional data visualization across files. Explore relationships within and among related datasets.</p> <p><a href="#">Install</a></p>
 <p><b>Orange 3</b> 3.34.0</p> <p>Component based data mining framework. Data visualization and data analysis for</p>	 <p><b>Powershell Prompt</b> 0.0.1</p> <p>Run a Powershell terminal with your current environment from Navigator</p>	 <p><b>owershell_shortcut_miniconda</b> 0.0.1 Anaconda Powershell Prompt</p>	 <p><b>PC</b></p> <p>PyCharm Professional</p> <p>A full-fledged IDE by JetBrains for both Scientific and Web Python development.</p>	 <p><b>IPyQt</b> 5.5.1</p> <p>PyQt GUI that supports inline figures, proper multiline editing with syntax</p>	 <p><b>R</b></p> <p>RStudio 1.1.456</p> <p>A set of integrated tools designed to help you be more productive with R. Includes R</p>

[Documentation](#)  
[Anaconda Blog](#)  
  





Archivo Editar Vista Correr Núcleo Pestañas Ajustes Ayuda

Untitled4.ipynb Python 3 (ipykernel)

Filtrar archivos por nombre

Name	Last Modified
3D Objects	last mon
anaconda3	last mon
ansel	last mon
Contacts	22 days ago
DATOS_1	last mon
Desktop	16 days ago
Docume...	8 hours ago
Downloa...	2 hours ago
Favorites	22 days ago
Graphisoft	last mon
Links	22 days ago
Music	22 days ago
OneDrive	last mon
Pictures	4 hours ago
RED NEU...	11 days ago
Saved Ga...	22 days ago
Searches	22 days ago
Videos	22 days ago

```
[1]: #Librerias
from __future__ import absolute_import, division, print_function, unicode_literals
import pandas as pd
import keras
import tensorflow as tf
from tensorflow.keras import datasets, layers, models

import matplotlib.pyplot as plt
import numpy as np
import os
from tqdm import tqdm #barra de progreso
import cv2 #pip install opencv
from glob import glob

from keras.utils import to_categorical
from sklearn.metrics import accuracy_score
from keras.layers import Dense, Dropout, Flatten
from keras.models import Sequential, Input, Model
from sklearn.model_selection import train_test_split

#para redimensionar
import sklearn
import skimage #pip install scikit-image
from skimage.transform import resize
from keras.layers import Conv2D, MaxPooling2D
import random

#usaremos datetime para nombrar archivos
import datetime

from imblearn.over_sampling import RandomOverSampler #pip install imblearn
```

```

Untitled4.ipynb
+
Código
from tqdm import tqdm #barra de progreso
import cv2 #pip install opencv
from glob import glob

from keras.utils import to_categorical
from sklearn.metrics import accuracy_score
from keras.layers import Dense, Dropout, Flatten
from keras.models import Sequential, Input, Model
from sklearn.model_selection import train_test_split

#para redimensionar
import sklearn
import skimage #pip install scikit-image
from skimage.transform import resize
from keras.layers import Conv2D, MaxPooling2D
import random

#usaremos datetime para nombrar archivos
import datetime

from imblearn.over_sampling import RandomOverSampler #pip install imblearn
from imblearn.under_sampling import RandomUnderSampler
from skimage.color import rgb2gray

print(tf.__version__)
2.3.0

```

Versión

```

y.append(label)
x = np.asarray(x)
y = np.asarray(y)
return X,y
X, y =Conv_img(carpeta)

print(X)
print(y)
#if CARGA DE IMAGENES:
# cargamos las imagenes a los arrays
#X, Y= Conv_img(carpeta)
# grabamos los arrays en archivos
# np.save('X_data1.npy', X)
# np.save('Y_data1.npy', Y)
#else:
# cargamos los arrays anteriormente grabados
# X = np.load('X_data.npy')
# Y = np.load('Y_data.npy')
#print(X.shape)

```

Carga total de datos

```

100%|██████████| 204/204 [06:10<00:00, 1.81s/it]
100%|██████████| 220/220 [08:14<00:00, 2.25s/it]
100%|██████████| 222/222 [10:50<00:00, 2.93s/it]

```