

Identification of failures in flexible pavement using Machine Learning, Cajamarca 2022

Goicochea Limay Kevin Junior Dagoberto, estudiante¹ Quiliche Marín Lizeth Karina del Rosario, estudiante². Romero Cueva Yoner Jaime, Doctor³, Quevedo Porras Violeta Zarela, Magister⁴ y Martínez Zapana Cesar Augusto, Magister⁵

¹Universidad Privada del Norte, Perú, N00186566@upn.pe

²Universidad Privada del Norte, Perú, N00184521@upn.pe

³Universidad Privada del Norte, Perú, yoner.romero@upn.edu.pe

⁴Universidad Privada del Norte, Perú, violeta.quevedo@upn.pe

⁵Universidad Privada del Norte, Perú, camz1486@gmail.com

Abstract – For many years, fault detection in flexible pavements has been carried out using traditional methods such as PCI, VIZIR, and visual observation. However, recent technologies such as artificial intelligence (AI) have been developed due to their efficiency and accuracy, using deep learning techniques related to image processing to achieve object detection and analysis. The objective of the research is to use AI through the Yolov5 software to detect and analyze faults in the pavement of the Southern Bypass, in the stretch between Óvalo Musical (Jr. Atahualpa) and Avenida Industrial. The study has an applicative and experimental scope and design, with a non-probabilistic sample based on the two most common types of faults in flexible pavements: alligator cracking and fissures.

Keywords – Paved Road, Flexible Pavement, Failure, Machine Learning, Yolov5.

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

Identificación de fallas en pavimento flexible usando Machine Learning, Cajamarca-2022

Durante muchos años, la detección de fallas en pavimentos flexibles se ha llevado a cabo mediante métodos tradicionales como PCI, VIZIR y observación visual. Sin embargo, se han desarrollado tecnologías recientes como la inteligencia artificial (IA) debido a su eficiencia y precisión, utilizando técnicas de aprendizaje profundo (machine learning) relacionadas con el procesamiento de imágenes para lograr la detección y análisis de objetos. El objetivo de la investigación es utilizar la IA a través del software Yolov5 para detectar y analizar fallas en el pavimento de la Vía de Evitamiento Sur, en el tramo comprendido de las calles Óvalo Musical (Jr. Atahualpa) y Avenida Industrial. El estudio tiene un alcance y diseño aplicativo y experimental, con una muestra no probabilística basada en los dos tipos más comunes de fallas en pavimentos flexibles: piel de cocodrilo y fisuras.

Palabra clave--Vía pavimentada, pavimento flexible, Falla, Machine Learning, Yolov5.

I. INTRODUCCIÓN

Con el paso del tiempo, las vías, pistas y carreteras han llegado a ser consideradas como las principales fuentes de comunicación entre ciudadanos del planeta, ya que estas posibilitan el traslado de bienes y servicios, y permiten su crecimiento y avance socioeconómico. Aquellas en su mayoría son construidas con pavimentos flexibles, no obstante, estas poseen incidencia de factores, lo que provocaría alteraciones o fallas de la superficie de rodadura que a su vez perjudica la seguridad, comodidad y rapidez con que debe circular el tráfico presente y el futuro[1]. Esta problemática se ha vuelto muy frecuente debido a que siempre se utilizaron métodos tradicionales para la detección de fallas en pavimentos flexibles tales como:

i) PCI, procedimiento que consiste en la determinación de la condición del pavimento a través de inspecciones visuales, identificando la clase, severidad y cantidad de fallas encontradas[2], ii) VIZIR, sistema que permite evidenciar fallas de tipo estructural y funcional (clasificación que se obtiene al emplear este método), y que puede ser producto de la insuficiencia de la capacidad estructural del pavimento (A) o relacionados con aspectos netamente constructivos (B) [3], y observación en el que se analiza y fotografía la zona de estudio, de esta forma por conocimientos previos sobre fallas en pavimentos flexibles, se los clasifica por tramos, sin embargo, en los últimos años ya se hecho más frecuente el uso nuevas tecnologías de inteligencia artificial (IA), mediante el aprendizaje profundo (Machine Learning), debido a que las obras tradicionales de construcción y mantenimiento en pavimentos se han remodelado y automatizado, de tal forma que se proporcione mayor eficiencia, confiabilidad y productividad[4].

Las fallas en pavimentos flexibles se clasifican en dos clases: 1) las estructurales, que se encuentran relacionadas con obras de rehabilitación de un costo elevado, y 2) las superficiales, que corresponden a obras de mantenimiento periódico

Las Fallas estructurales determinan el estado estructural del pavimento, en razón al conjunto sus capas o de la superficie; y en caso de presentar deterioro no se aparece de forma inmediata, sino al cabo de la repetición de cargas definidas por la curva de fatiga de cada material [5].

TABLA 1

TIPOS DE FALLAS ESTRUCTURALES

Código	Deterioro/Falla	Gravedad
1	Piel de cocodrilo	1: Malla grande > (0.5m) sin material suelto. 2: Malla mediana (entre 0.3 y 0.5m) sin o con material suelto. 3: Malla pequeña < (0.3m) sin o con material suelto.
2	Fisuras longitudinales	1: Fisuras finas en las huellas del tránsito (ancho \leq 1 mm) 2: Fisuras medias corresponden a fisuras abiertas y/o ramificadas (ancho > 1 mm y \leq 3 mm) 3: Fisuras gruesas corresponden a fisuras abiertas y/o ramificadas (ancho > 3 mm). También se denominan grietas.
3	Deformación por deficiencia estructural	1: Profundidad sensible al usuario < 2 cm 2: Profundidad entre 2 cm y 4 cm 3: Profundidad > 4 cm
4	Ahuellamiento	1: Profundidad sensible al usuario, pero \leq 6 mm 2: Profundidad > 6 mm y \leq 12 mm 3. Profundidad > 12 mm
5	Reparaciones o parchados	1: Reparación o parchado para deterioros superficiales. 2: Reparación de piel de cocodrilo o de fisuras longitudinales, en buen estado. 3: Reparación de piel de cocodrilo o de fisuras longitudinales, en mal estado.

A diferencia de un programa normal diseñado solo para ejecutar líneas de código previamente programadas, un algoritmo permite aprender por sí mismo y corregir errores. Es decir, esta innovación les da a los ordenadores el poder de resolver las cosas sin que las tengan programadas explícitamente. Como ejemplo de un aprendizaje automático, está aquel programa que pueda identificar gatos en imágenes. En este procedimiento el algoritmo realiza la tarea de la siguiente forma: Darle a la IA un conjunto de características de cómo es un gato, para que sepa reconocerlo. Colores, formas, etc. [6]

Uno de los algoritmos basados en el reconocimiento de imágenes es el denominado: YOLO, acrónimo de "You only look once". Sirve para la detección de objetos a través de la división de imágenes en un sistema de cuadrículas. Cada celda de la cuadrícula se encarga de detectar objetos dentro de ella [7].

Poco después del lanzamiento de YOLOv4, Glenn Jocher presentó YOLOv5 utilizando el marco de trabajo Pytorch [8, p. 5].

Un detector de objetos está diseñado para crear características a partir de imágenes de entrada y luego alimentar estas características a través de un sistema de predicción para dibujar cuadros alrededor de los objetos y predecir sus clases.

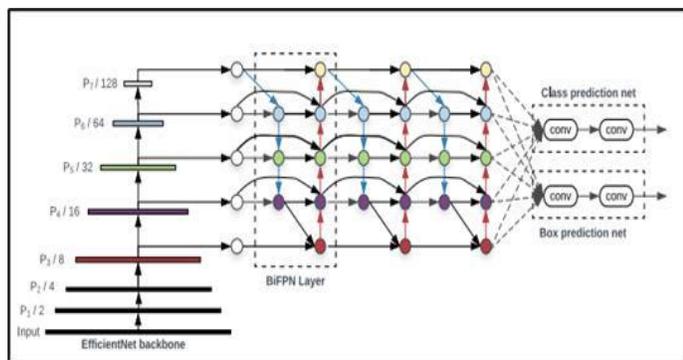


Fig. 1 La anatomía de un detector de objetos. Tomado de YOLOv5 Documentation, 2022

El modelo YOLO fue el primer detector de objetos en conectar el procedimiento de predicción de cuadros delimitadores con etiquetas de clase en una red diferenciable de extremo a extremo.

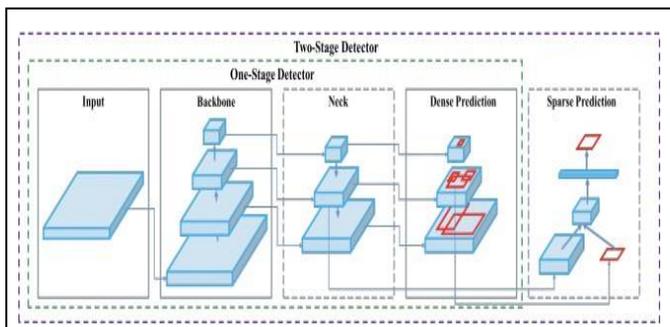


Fig. 2. Proceso de detección de objetos. Tomado de YOLOv5 Documentation, 2022

La red YOLO consta de tres piezas principales.

*Columna vertebral: una red neuronal convolucional que agrega y forma características de imagen en diferentes granularidades.

*Cuello : una serie de capas para mezclar y combinar características de imagen para pasarlas a la predicción.

*Cabeza : consume las características del cuello y realiza los pasos de predicción de cuadro y clase.

Una herramienta adicional y complementaria con el algoritmo YOLO es el Roboflow, el que permite a los desarrolladores crear sus propias aplicaciones de visión por computadora, sin importar su conjunto de habilidades o experiencia.

Proporcionando todas las herramientas necesarias para convertir imágenes sin procesar en un modelo de visión por computadora capacitado, personalizado e implementando su uso en aplicaciones, hoy en día, Roboflow admite modelos de detección y clasificación de objetos [9].

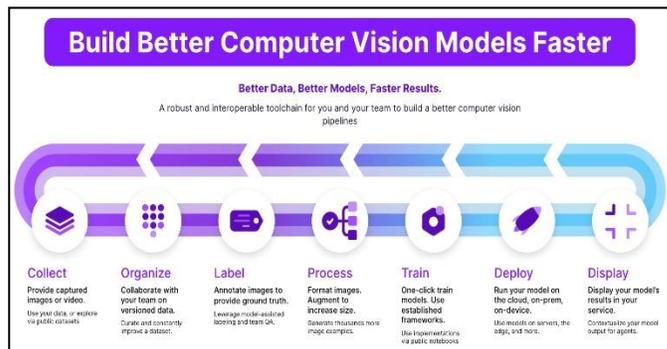


Fig. 3 Proceso de desarrollo de trabajo en Roboflow. Tomado de Roboflow, 2022

De este modo la investigación pretende detectar fallas en pavimento flexible mediante el uso de machine Learning, que servirá para facilitar el procedimiento de reconocimiento de fallas en pavimento flexible. Este proyecto contribuye al mantenimiento de las vías, pues el sistema puede decirnos el tipo de falla [10].

II. METODOLOGÍA

La investigación tiene enfoque cuantitativo ya que utiliza la recolección de datos con medición numérica para validar o afinar la pregunta de investigación sobre la efectividad software Machine Learning de Yolov5, en la detección de 2 tipos de fallas más comunes: **i)** piel de cocodrilo y **ii)** fisuras en la Vía de Evitamiento Sur-Cajamarca

El trabajo es de diseño experimental, por cuanto en el proceso se somete a un objeto o individuo a experimentos que permitan analizar el comportamiento de aquél.

De acuerdo con lo mencionado, se tomó como muestra la zona Vía de Evitamiento Sur PE-3N en la ciudad de Cajamarca, de modo que se pueda determinar las fallas que presenta.

Ahora bien, a efectos de poder determinar la muestra se empleó el método no probabilístico, es decir, se elegirá el tramo ubicado entre el Óvalo Musical y la Avenida industrial de la vía de evitamiento Sur de la ciudad de Cajamarca.

Según el Manual de Mantenimiento o conservación vial, el objeto del proceso para fallas califica la condición superficial de un pavimento flexible de la carretera por secciones de 200m de calzada y bermas. Considerando cada tipo de deterioro o falla según el nivel de gravedad de dicho tipo y su clase de extensión. El inicio o fin del nivel de gravedad de cada tipo de deterioro o falla observado tienen que localizarse [5].

Con el método inductivo-deductivo se obtendrá conocimientos de lo general a lo particular y viceversa; es decir, del análisis de cada variable involucrada en nuestro objetivo de investigación se podrá efectuar generalizaciones con relevancia científica que

permitan sustentar afirmaciones en relación con la hipótesis. La técnica que se empleó para la recolección de datos fue la observación y análisis mediante Yolov5 de fallas en pavimento flexible. Para el recojo de información se utilizaron cámaras fotográficas por medio de la cual se recogieron imágenes de la zona de estudio, y base de datos obtenida de buscadores de imágenes como Google, Bing y DuckDuckGo.



Fig. 4 Ubicación 1° tramo de la Vía de evitamiento sur, comprendido entre el Óvalo Musical (Jr. Atahualpa) y Avenida Industrial.

En la figura 4 se puede observar el tramo de la vía propuesta que se utilizara para realizar el estudio de las fallas.

El procedimiento empleado consistirá en recoger imágenes de la zona afectada y reconocer las fallas mediante el algoritmo Yolov5, para luego determinar los resultados contrastándolos con la normativa vigente. En la recolección de imágenes para el reconocimiento de fallas con el algoritmo elegido se utilizó una cámara NIKON D3400, y con las que se detectó o encontró dos tipos de fallas: Piel de cocodrilo y fisuras.

Para determinar la validez y confiabilidad de los instrumentos, se utilizó la opinión y el visto bueno de expertos en el tema y de la carrera profesional de Ingeniería Civil de nuestra casa superior de estudios sede Cajamarca.

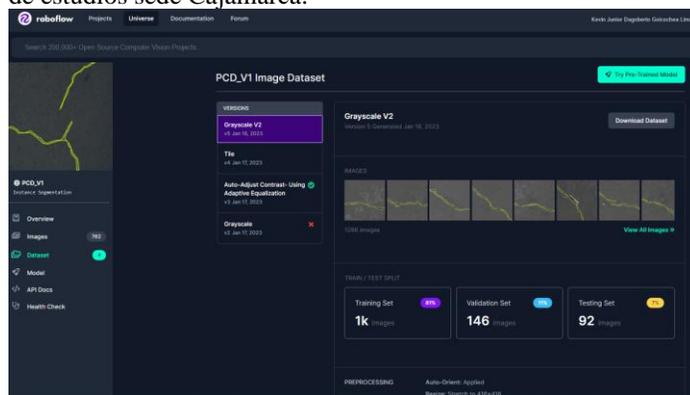


Fig. 5 Base de datos para entrenamiento de algoritmo.

Después de haber aplicado el instrumento, se procedió a etiquetar las imágenes obtenidas de bases de datos en internet, así como también usar bases de datos Open Source contenidas en Roboflow y ordenar los tipos de falla elegidos al entrenar el algoritmo (utilizando roboflow) [11] (ver fig. 5). Cabe destacar que estas etiquetas le mostrarán al algoritmo que tipo de falla tiene que reconocer en las imágenes con las que se entrenó. Respecto al entrenamiento, se consultó el manual de uso de la página oficial del desarrollador del algoritmo Yolov5 (Ultralytics) [12], para posteriormente usar el algoritmo en un entorno de ejecución que en este caso viene a ser Google Colab[13] (ver fig. 6). Para la visualización de gráficas y testeo del algoritmo con las imágenes de la Vía de Evitamiento Sur, se utilizó la herramienta brindada por el desarrollador (Ultralytics HUB BETA). Para la redacción del artículo se utilizó el paquete office.

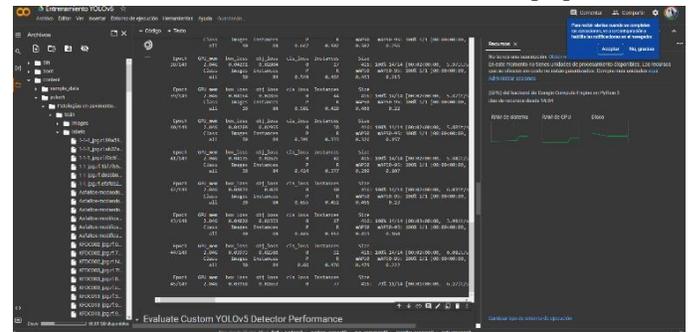


Fig. 6 Entrenamiento de Algoritmo.

Referido a los aspectos éticos de la investigación, se están citando a todas las fuentes consultadas y consideradas en esta investigación. También contamos con la autorización de la institución en estudio para recolectar la información necesaria que será usada solo con fines académicos, basándonos en el método científico y sin dejar de lado valores que un investigador debe observar. Resultado que son presentados sin alterar datos reales.

III. RESULTADOS

Al haber entrenado al algoritmo para el reconocimiento de la primera falla (piel de cocodrilo), obtuvimos los siguientes resultados:



Fig. 7 Resultados de aprendizaje de falla de piel de cocodrilo.

Los resultados obtenidos en la figura 7 muestran el nivel de aprendizaje del algoritmo, donde se observa el porcentaje de reconocimiento y la precisión que este tiene durante el entrenamiento, se puede apreciar que el valor máximo alcanza un nivel de precisión del 83%, indicando que el algoritmo tiene un nivel adecuado de aprendizaje.

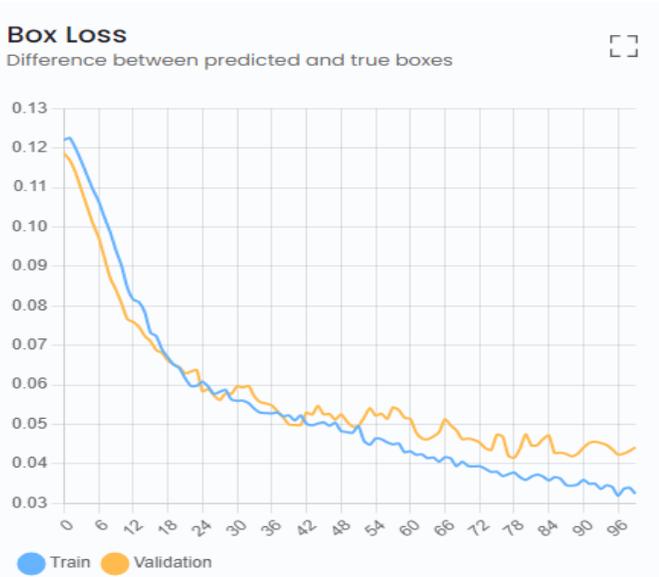


Fig. 8 Reconocimiento de piel de cocodrilo en imágenes de entrenamiento.

La figura 8 muestra la evolución de la pérdida de cajas durante el entrenamiento y la validación del algoritmo Yolov5. La pérdida de cajas se refiere a la discrepancia entre las coordenadas de las cajas detectadas y las coordenadas reales de los objetos en la imagen. Es importante observar la diferencia entre la pérdida de cajas de entrenamiento y validación para evaluar la capacidad del modelo y evitar el sobreajuste. En este caso, se busca que la curva de entrenamiento baje gradualmente para corroborar que el modelo está aprendiendo, como podemos ver el resultado hace lo que pretendíamos, por lo tanto, el entrenamiento es correcto.

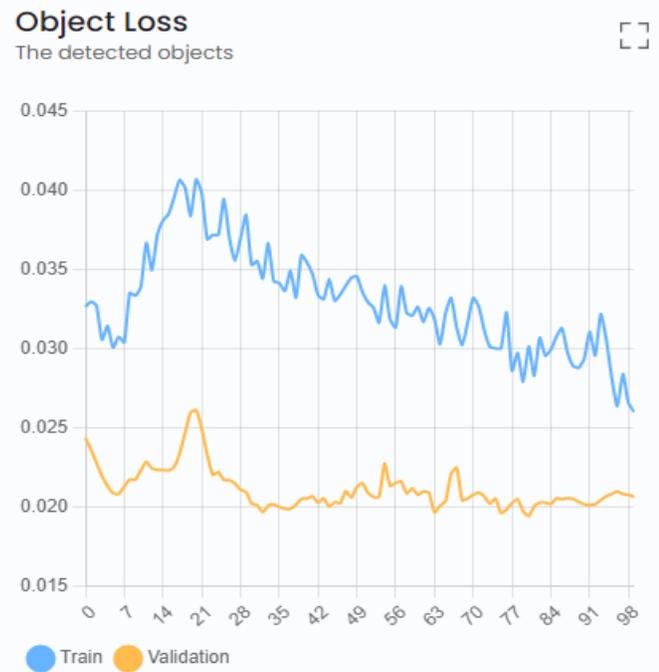


Fig. 9 Perdida de objetos-Falla de piel de cocodrilo.

La figura 9 muestra la perdida de objetos que nos permite determinar el nivel de precisión del reconocimiento en las imágenes, al igual que la perdida de cajas se busca una

reducción gradual de la curva para determinar que el modelo trabaje correctamente, en este caso nos indica que el entrenamiento en la falla de cocodrilo es correcto.

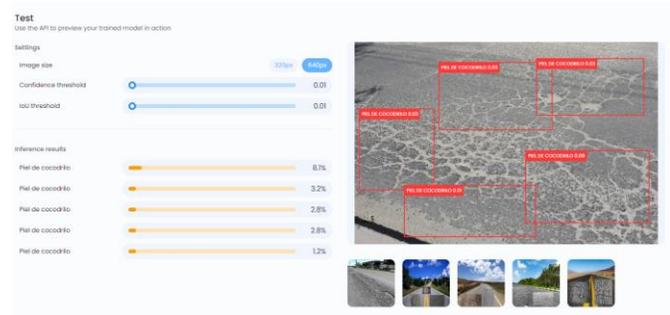


Fig. 10 Prueba en imágenes de vía-Falla de piel de cocodrilo.

En la figura 10 podemos observar el reconocimiento de la falla de piel de cocodrilo en las imágenes hechas en la vía de estudio, en donde podemos observar el porcentaje de certeza que tiene en el reconocimiento de la falla estudiada.

Para el entrenamiento en el reconocimiento de fallas de fisura se realizó el mismo procedimiento.



Fig. 11 Resultados de aprendizaje de falla de fisura.

Los resultados obtenidos en la figura 11 muestran el nivel de aprendizaje del algoritmo, donde se observa el porcentaje de reconocimiento y la precisión que este tiene durante el entrenamiento, se puede apreciar que el valor máximo alcanza un nivel de precisión del 73%, indicando que el algoritmo tiene un nivel adecuado de aprendizaje.

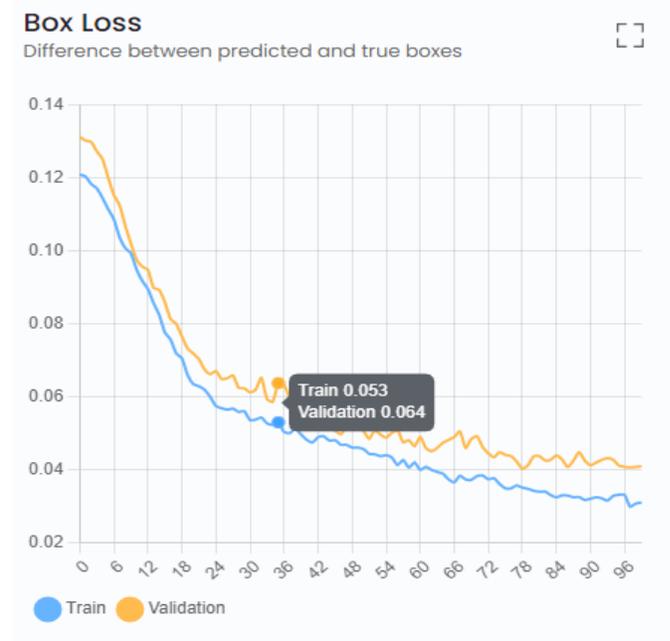


Fig. 12 Perdida de cajas-Falla de fisura.

En la figura 12 podemos observar la pérdida de cajas en la falla de fisura durante el entrenamiento, la imagen nos muestra una curva descendente que para nuestro propósito viene a indicar que se tiene un entrenamiento adecuado

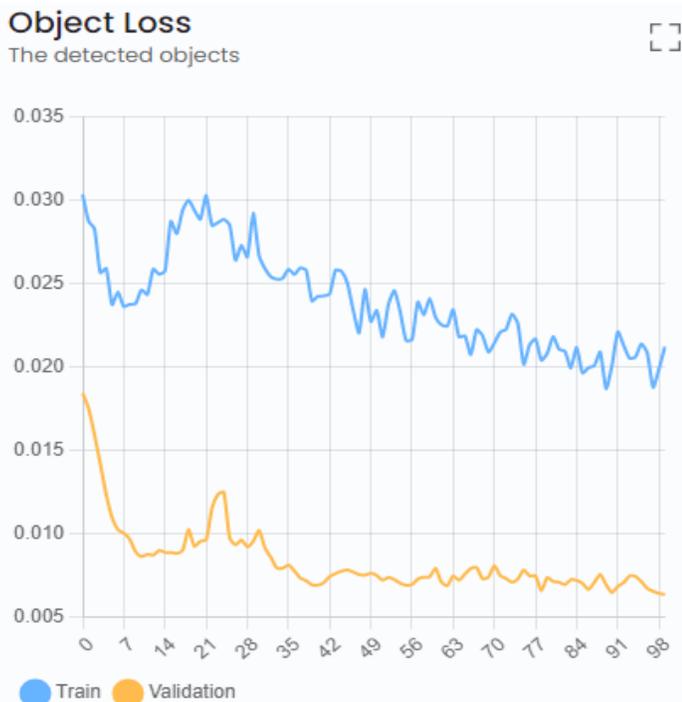


Fig. 13 Perdida de objetos-Falla de fisura.

La figura 13 muestra la perdida de objetos en la falla de fisura podemos observar que la curva de entrenamiento tiende a elevarse bastante en algunas partes del entrenamiento, lo que nos indica que podría haber un sobreajuste en algunos momentos esto hace que la precisión pueda ser menor por lo tanto el entrenamiento se termina en el mejor momento para tener un entrenamiento adecuado.

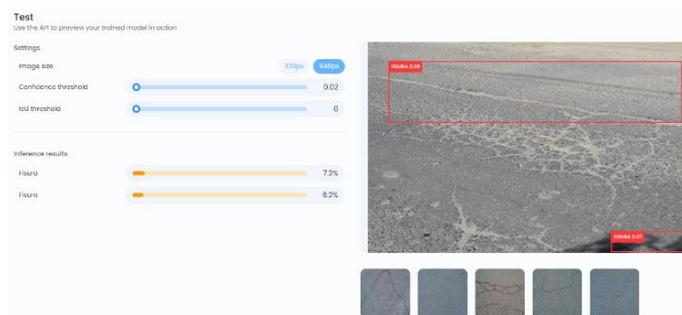


Fig. 14 Prueba en imágenes de vía-Falla de fisura.

En la figura 14 podemos observar el reconocimiento en las imágenes hechas en la vía de estudio, donde podemos observar el porcentaje de certeza con el que el algoritmo es capaz de distinguir la fisura de la falla de cocodrilo.

IV. DISCUSIÓN

Al analizar las imágenes de la zona de estudio ubicada en Vía de Evitamiento Sur (tramos desde Ovalo Musical hasta Av.

Industrial), se logró determinar que la IA es capaz de reconocer las dos fallas propuestas en el pavimento flexible.

Según Zúñiga Guisado[10], se puede apreciar que el análisis hecho en su tesis “Deep Learning Para la Detección de Fallas en Pavimentos”, tiene un mayor nivel de confianza con indicadores entre el 0.32 a 0.85 e imágenes con resolución de 1920x1080 pixeles, y esto se debe al uso de imágenes de su propia zona de estudio (Distrito de Villa María del Triunfo), en comparación con el de la Vía de Evitamiento Sur con indicadores del 0.20-0.65, en el que se presenta tramos más cortos y como consecuencia limita el número de imágenes y su calidad en la base de datos para el entrenamiento.

A diferencia de los tipos de fallas utilizados en esta investigación, como la piel de cocodrilo y la fisura, el tipo de fallas que este utilizó previamente fueron grietas y huecos. Esto nos permite incrementar la base de datos y las fallas presentes en el pavimento, así como detectar otros tipos de fallas, ya que el algoritmo Yolov5 puede utilizarse en diferentes campos.

Es cierto que en países desarrollados el uso de la IA es mucho más frecuente y común que en países Sudamericanos, como en Perú, donde es una realidad un tanto alejada. Esto nos motiva a investigar y recibir nuevas formas de apoyo para realizar actividades que los ingenieros civiles aún llevan a cabo de forma visual, como la detección de fallas. De esta manera, pueden centrarse en otras actividades más importantes.

Sin embargo, es importante resaltar que se necesitan conocimientos previos sobre el tema para permitir que la herramienta reciba una base de datos óptima y adecuada a la falla que se desea entrenar y detectar. De este modo, en un futuro no muy lejano, la IA puede convertirse en un complemento que permita el desarrollo y la evolución de las actividades dentro del campo de la ingeniería civil.

En resumen, las inteligencias artificiales, el análisis de datos computarizados y el aprendizaje profundo están siendo ampliamente utilizados en la actualidad, lo que ofrece muchas posibilidades para las aplicaciones en análisis de datos por imágenes, como el Yolov5 utilizado en esta investigación para la detección de fallas de pavimento flexible. Los resultados obtenidos fueron altamente confiables, pero es importante tener en cuenta que la precisión del algoritmo dependerá en gran medida del aprendizaje que adquiera a través del entrenamiento adecuado. En consecuencia, se espera que el uso de herramientas como esta continúe evolucionando en el campo de la ingeniería civil y se adapte a nuevas aplicaciones en el futuro.

V.CONCLUSIONES

Los resultados obtenidos indican que el algoritmo tiene un reconocimiento adecuado de las fallas en la zona de estudio, lo que representa un resultado óptimo para los objetivos planteados en esta investigación.

Finalmente, se recomienda una capacitación exhaustiva en el desarrollo de algoritmos Yolov5, tanto en la parametrización de imágenes como en su calidad, ya que estos factores pueden afectar de manera positiva o negativa la obtención de resultados óptimos. Es importante que el algoritmo sea capaz de reconocer las dos fallas o patologías planteadas en la zona de estudio mediante la inteligencia artificial, que es el objetivo principal de esta investigación.

REFERENCIAS

- [1] MTC, «Manual De Carreteras Suelos Geología, Geotecnia Y Pavimentos». Ministerio de Transportes y Comunicaciones, 9 de abril de 2014. [En línea]. Disponible en: https://portal.mtc.gob.pe/transportes/caminos/normas_carreteras/documentos/manuales/MANUALES%20DE%20CARRETERAS%202019/MC-05-14%20Seccion%20Suelos%20y%20Pavimentos_Manual_de_Carreteras_OK.pdf
- [2] ASTM, «Standard Guide for Property Condition Assessments: Baseline Property Condition Assessment Process». 2018.
- [3] R. A. Medina Chamaya, «Evaluación del pavimento flexible por el método Pci y Vizir, tramo Rejopampa – Chaupelanche, distrito de Chota, Cajamarca-2018», 2018.
- [4] Y. Pan y L. Zhang, «Roles of artificial intelligence in construction engineering and management: A critical review and future trends», *Autom. Constr.*, vol. 122, p.103517, feb. 2021, doi: 10.1016/j.autcon.2020.103517.
- [5] MTC, «Manual de Carreteras Mantenimiento o Conservación Vial». Ministerio de Transportes y Comunicaciones, 2018. [En línea]. Disponible en: https://portal.mtc.gob.pe/transportes/caminos/normas_carreteras/documentos/manuales/MANUALES%20DE%20CARRETERAS%202019/MC-08-14%20Mantenimiento%20o%20Conservacion%20y%20Parte_4_Mant_Rutinario_Caminos_Vecinales_GL_OK.pdf
- [6] «Diferencias entre IA, Machine Learning y Deep Learning», *HardZone*. <https://hardzone.es/tutoriales/rendimiento/diferencias-ia-deep-machine-learning/> (accedido 19 de mayo de 2022).
- [7] G. Keyouo, H. Chengbo, Y. Min, y W. Sudong, «Scopus - Document details - A pavement distresses identification method optimized for YOLOv5s». https://scopus.bibliotecaupn.elogim.com/record/display.uri?eid=2-s2.0-85125687550&origin=resultslist&sort=plf-f&src=s&st1=pavement&sid=bb58021e99d265893235abbc3b4bb5dc&ot=b&sdt=b&sl=23&s=TITLE-ABS-KEY%28pavement%29&relpos=1&citeCnt=0&searchTerm=&featureToggles=FEATURE_NEW_DOC_DETAIL_S_EXPORT:1 (accedido 5 de abril de 2022).
- [8] «YOLOv5 Documentation». <https://docs.ultralytics.com/> (accedido 19 de mayo de 2022).
- [9] J. S. JUN 29 y 2020 13 Min Read, «What is YOLOv5? A Guide for Beginners. », *Roboflow Blog*, 29 de junio de 2020. <https://blog.roboflow.com/yolov5-improvements-and-evaluation/> (accedido 20 de noviembre de 2022).
- [10] Y. Zúñiga Guisado, «Deep Learning para la detección de fallas en pavimentos de una zona del distrito de Villa María del Triunfo 2022», *Repos. Inst. - UCV*, 2022, Accedido: 1 de diciembre de 2022. [En línea]. Disponible en: <https://repositorio.ucv.edu.pe/handle/20.500.12692/93124>
- [11] «Roboflow: Give your software the power to see objects in images and video». <https://roboflow.com/> (accedido 12 de diciembre de 2022).
- [12] G. Jocher, «YOLOv5 by Ultralytics». mayo de 2020. doi: 10.5281/zenodo.3908559.
- [13] «Google Colaboratory». <https://colab.research.google.com/> (accedido 12 de diciembre de 2022).