



AVANCES EN EL RECONOCIMIENTO DE PLACAS VEHICULARES CON VISIÓN COMPUTACIONAL Y MACHINE LEARNING EN COSTA RICA

T. Bermúdez

*Universidad Cenfotec, Francisco Peralta, San José
tbermudezm@ucenfotec.ac.cr*

J. Hidalgo

*(Universidad Cenfotec, Francisco Peralta, San José
jhidalgou@ucenfotec.ac.cr)*

L. Naranjo

*(Universidad Cenfotec, Francisco Peralta, San José
lnaranjo@ucenfotec.ac.cr)*

RESUMEN

El presente artículo documenta el desarrollo de un sistema de visión computacional y aprendizaje automático para el reconocimiento de placas vehiculares en Costa Rica, un área poco investigada localmente. Utiliza el algoritmo YOLOv5 y técnicas de OCR para detectar vehículos y procesar texto en tres etapas: detección vehicular, detección de placas y reconocimiento de caracteres. Se entrenaron dos modelos, con lo cual se logró un 77 % de precisión en detección de vehículos y 96 % en detección de placas. Además, se creó un dataset experimental con 729 placas costarricenses, donde el modelo alcanzó un 69 % de verdaderos positivos. Esta solución representa un avance significativo para aplicaciones de seguridad vial y propone una base sólida para futuros desarrollos. Se recomienda ampliar el dataset nacional para mejorar el rendimiento.

Palabras clave: Aprendizaje automático, conjunto de datos vehiculares, placas vehiculares, reconocimiento de caracteres, reconocimiento de matrículas, seguridad vial, visión computacional.

ABSTRACT

This paper documents the development of a computer vision and machine learning system for license plate recognition in Costa Rica, a field with limited local research. It employs the YOLOv5 algorithm and OCR techniques to detect vehicles and process text in three stages: vehicle detection, license plate detection, and character recognition. Two models were trained, achieving 77% accuracy in vehicle detection and 96% in plate detection. Additionally, an experimental dataset of 729 Costa Rican license plates was created, where the model achieved a 69% true positive rate. This solution represents a significant advancement for road safety applications and provides a solid foundation for future developments. Expanding the national dataset is recommended to improve performance.

Keywords: Character recognition, computer vision, license plate recognition, license plates, machine learning, road safety, vehicle datasets.

I. INTRODUCCIÓN

En la actualidad, la seguridad vial se ha convertido en una preocupación primordial en muchas sociedades, y Costa Rica no es una excepción. La necesidad de implementar soluciones innovadoras que contribuyan a prevenir siniestros y mejorar la identificación de vehículos implicados en eventos delictivos ha llevado al desarrollo de proyectos basados en tecnologías informáticas avanzadas, como la visión computacional y el machine learning.

Bajo este sentido, la investigación tiene como objetivo principal desarrollar un sistema de reconocimiento de placas vehiculares en vías públicas de Costa Rica. De modo que se enmarca en un enfoque alternativo, orientado hacia la demostración, pruebas y análisis práctico, se prioriza el desarrollo funcional del sistema, y el cumplimiento de los objetivos de investigación, estableciendo un avance en esta área.

La relevancia de este trabajo radica en la ausencia de implementación de sistemas de detección de vehículos en vías públicas en Costa Rica, situación que ha generado la necesidad de investigar y desarrollar un proyecto que aborde esta problemática de manera integral. Esto cobra especial importancia ante estadísticas preocupantes de muertes en sitio por accidentes de tránsito, ya que, para el año 2024, se registraron 513 personas fallecidas en el lugar del accidente, lo que representa una tasa de mortalidad de 9,93 por cada 100 000 habitantes, esto deja en evidencia la urgencia de fortalecer la seguridad vial en el país [1]. Asimismo, según el Organismo de Investigación Judicial [2], en 2020 se contabilizaron 3165 denuncias por robo de vehículos, mientras que en 2023 esta cifra aumentó a 4562, ello refleja un incremento significativo en este delito [2]. Esta alta incidencia y el aumento sostenido de casos, junto con los riesgos persistentes en carretera, resaltan la imperiosa necesidad de implementar sistemas de detección que contribuyan a la reducción de estos delitos y al mejoramiento de la seguridad en las vías públicas de forma preventiva.

El enfoque alternativo, basado en el paradigma pragmático [3], responde directamente al objetivo de desarrollar un sistema funcional y práctico para Costa Rica, donde no existen implementaciones previas. Al priorizar el desarrollo funcional y un producto de software operativo, se asegura la creación de un sistema tangible y utilizable. Asimismo, la orientación hacia la demostración, las pruebas y el análisis práctico garantiza que el sistema sea evaluado rigurosamente en su capacidad para reconocer placas vehiculares en el contexto costarricense, con lo cual cumple con los objetivos de investigación y aborda la necesidad de una herramienta innovadora para fortalecer la seguridad vial en el país. Este enfoque en particular se basa en tres dimensiones fundamentales:

- Epistemológica: Centrada en la posición de los investigadores como observadores en la búsqueda de comparar diversas técnicas y arquitecturas de reconocimiento de matrículas.
- Ontológica: Enfocada en la conceptualización de los elementos clave para entender la estructura del sistema ALPR (Automatic License Plate Recognition).
- Axiológica: Estudia los valores y define criterios de eficiencia y precisión para la evaluación de los resultados del sistema.

La investigación se apoya en el uso de técnicas de visión por computador y aprendizaje automático, basándose en el análisis de conceptos relevantes para el reconocimiento de placas vehiculares. El

sistema resultante ha sido sometido a una evaluación rigurosa, considerando factores como la velocidad de procesamiento y la precisión en la identificación de placas.

En el apartado 2, se expone una revisión de literatura en la que se abordarán las bases teóricas sobre sistemas ALPR, dichas bases guiarán los métodos a seguir en el capítulo 3 para la elaboración del sistema. En el apartado 4, se abordarán y expondrán los resultados experimentales encontrados en el desarrollo. Finalmente, en el apartado 5 se entrará en discusión sobre el avance alcanzado junto con las limitaciones técnicas del sistema para la detección de placas vehiculares en vías públicas, además, se presentarán puertas de investigación en campos similares y trabajos a futuro.

II. REVISIÓN DE LITERATURA

En esta sección los autores detallan una revisión de literatura, enfocada en formar criterio técnico sobre el machine learning y visión computacional para el proceso de detección de placas vehiculares. Siguiendo la metodología planteada por Biolchini et al. [4], se realizó la selección de los trabajos candidatos y su posterior revisión, bajo la cual se eligieron artículos y artículos académicos para formar parte de las bases teóricas y técnicas de la investigación. Los artículos seleccionados contienen una gran cantidad de conceptos, información, modelos, técnicas y recomendaciones para la construcción de un sistema LPR eficiente y robusto.

Como punto de partida, Kulkarni et al. [5] abordaron una revisión de los sistemas de reconocimiento automático de matrículas vehiculares (ALPR), en la cual describieron tres procesos principales: extracción de matrícula, segmentación de caracteres de matrícula y reconocimiento de la matrícula, adicionalmente a estas tres etapas referentes a la arquitectura del sistema ALPR, Du et al. [6] definieron una cuarta etapa anterior a estas, denominada adquisición de imágenes, prestando especial atención a los datasets empleados en el aprendizaje automático.

Para cubrir el tema de adquisición de imágenes, Björklund et al. [7] emplearon un dataset constituido por imágenes sintéticas para el entrenamiento de un modelo de detección, el cual evaluaron posteriormente en un conjunto de datos de imágenes de placas vehiculares del mundo real, donde se evidencia efectividad para reconocer con precisión placas de matrícula en diversos escenarios. Asimismo, Wang et al. [8] utilizaron también un

dataset sintético y compararon la precisión y la eficacia en la detección y reconocimiento con matrículas vehiculares reales y se obtuvieron buenos resultados en estos dos aspectos.

En contraposición a esta técnica, Laroca et al. [9] entrenaron con un dataset público para ALPR con más de 4500 imágenes de matrículas vehiculares, se alcanzaron mejores resultados comparados con sistemas comerciales y datasets existentes. Similar a estos autores, Amirgaliyev et al. [10] implementaron y probaron un método ALPR, en un dataset de 1470 imágenes, donde resultó que había una mayoría de falsos positivos antes de la verificación.

Para la siguiente etapa, referente a la extracción de placas vehiculares, Xu et al. [11] presentaron un método de detección de placas vehiculares, utilizando OpenCV, comparando y evaluando el rendimiento de varios algoritmos de detección de matrículas. Entre ellos evaluaron el método de detección de bordes de Canny, el método de detección de características de Haar, el método de detección de características de LBP y el método de detección de características de HOG, destacando este último como el método con mejor precisión y velocidad de detección. Por otro lado, Yu et al. [12] propusieron un método para ubicar placas vehiculares mediante la transformación de Wavelet y el análisis de descomposición modal empírica (EMD). Los resultados demuestran su efectividad para ubicar con precisión las placas de matrícula en varios escenarios.

Lin et al. [13] propusieron un método para la ubicación de placas vehiculares combinando la detección de bordes y la morfología matemática. El algoritmo fue diseñado para reducir la interferencia del ruido en las imágenes y aumentar la precisión en tiempo real. De forma similar, Giannoukos et al. [14] presentaron un algoritmo llamado Operator Context Scanning (OCS), que mejora la velocidad de procesamiento de videos e imágenes de alta definición en el reconocimiento de matrículas de vehículos en tiempo real en más del 250 % sin afectar la precisión.

Ahn et al. [15] describieron el diseño de un algoritmo de detección de zonas de interés (ROI) de placas vehiculares para mejorar su reconocimiento, empleando una combinación de técnicas de detección de bordes y análisis de características para identificar las ROI propensas a contener una placa de matrícula.

La capacidad de detección de ROI es un paso clave al que prestarle especial atención, esto se ve reforzado por el artículo de Bakhtan et al. [16] en el que, examinando los pasos claves para la extracción de la región de interés, concluyen que los métodos basados en redes neuronales y aprendizaje profundo se destacan por su precisión y eficiencia.

Sadique y Haque [17] revisaron varios trabajos sobre técnicas de detección y reconocimiento de placas vehiculares, incluyendo métodos basados en características, aprendizaje profundo y redes neuronales, de igual forma, se concluye que estos son más precisos y eficientes, que métodos previos. Pustokhina et al. [18], por ejemplo, presentaron un método ALPR utilizando una combinación de clustering K-means óptimo y redes neuronales convolucionales (CNN), teniendo como objetivo mejorar precisión y eficiencia en sistemas ALPR para el transporte inteligente. Los autores realizaron experimentos en un conjunto de datos de imágenes de matrículas y lograron altas tasas de precisión, superando otros métodos. Pu et al. [19] presentaron un método de CNN de detección de matrículas vehiculares extrayendo y fusionando características de bajo y alto nivel de las matrículas. El resultado del modelo fue eficiente en variedad de entornos complicados y logró una detección precisa y en tiempo real.

Los avances contemporáneos en cuanto al uso de deep learning para la detección de placas en imágenes proporcionan una guía para el desarrollo del sistema ALPR y la arquitectura a utilizar para su implementación en diversos entornos. Como evidenciaron Menon y Omman [20], con su sistema de reconocimiento de placas de matrícula, empleando técnicas de procesamiento de imágenes y aprendizaje automático, los autores probaron placas vehiculares de India y España, demostrando una alta precisión.

En este punto, también se aborda el trabajo de Shobha y Deepu [21], los cuales llevaron a cabo una revisión de métodos de detección de vehículos basados en visión, incluyendo enfoques de aprendizaje profundo como CNN, RCNN y DNN, además de analizar los desafíos asociados con la detección y clasificación de vehículos. Previamente, Kuo et al. [22] presentaron un sistema ALPR conformado por dos subsistemas para detección de automóviles y extracción de placas. Para el primero, usaron reglas de decisión de cantidad mínima de movimiento para encontrar la ubicación de los automóviles en la pantalla, para el segundo utilizaron características de las placas y un algoritmo de búsqueda para extraer las placas.

Palanivel et al. [23] propusieron un sistema para detectar placas vehiculares en situaciones difíciles, como en condiciones de luz distorsionada, alta o baja, y polvo, usando Faster R-CNN, segmentación de cuadros, interpolación de imágenes y reconocimiento óptico de caracteres (OCR). Este enfoque para la detección de caracteres destaca para la etapa de extracción de los números de matrícula vehicular. Este paso previo de detección vehicular se presenta como una etapa extra para realizar una depuración de datos previo a la extracción de las zonas de interés, los cuales pueden brindar una ventaja a la hora de descartar falsos positivos.

Por tanto, basados en este conjunto de artículos, se tomaron las bases para definir los métodos empleados para la creación de un sistema ALPR. El planteamiento es posible gracias a las múltiples intervenciones de autores internacionales en este ámbito, guiándonos con base en su experiencia y recomendaciones. Estos métodos, los cuales se detallan a continuación, parten del diseño metodológico, la recolección de datos y los ambientes y tecnologías de desarrollo.

III. MÉTODOS

En este apartado, se detallan los elementos críticos bajo los cuales se elabora la construcción del sistema.

Tipo de investigación

El tipo de investigación abordado para la selección de métodos o técnicas es evaluativo, derivado de los hallazgos en la revisión de literatura previamente planteada.

Alcance investigativo

Dado el tipo de investigación que se está realizando, esta se circunscribe a los siguientes alcances investigativos:

- **Exploratorio**
La investigación exploratoria busca familiarizar al investigador con un tema no abordado antes, novedoso o poco estudiado [24]. En nuestro caso, si bien se han efectuado investigaciones sobre reconocimiento de matrículas vehiculares alrededor del mundo, no se encontraron estudios o aplicaciones para Costa Rica.
- **Descriptivo**
Las investigaciones descriptivas se definen como “útiles para analizar cómo es y cómo se manifiesta un fenómeno y sus componentes” [24]. Este enfoque resulta útil para el análisis e interpretación de experimentos que se realicen a lo largo de la investigación.

Enfoque

Como parte del apartado de marco metodológico, se plantea el uso del enfoque alternativo para el desarrollo del reporte de investigación. Lo anterior dada la necesidad de generar una investigación orientada en la demostración, pruebas y análisis. Como resultado del uso de este enfoque, se presentarán tres dimensiones de investigación fundamentales abordadas de forma detallada en este reporte:

Dimensión epistemológica

Esta dimensión abarca la posición de los investigadores frente al fenómeno o acontecimiento de estudio. En este caso, dada la naturaleza de una investigación evaluativa de las principales técnicas y arquitecturas usadas en las fases de un sistema ALPR, los investigadores van a asumir un rol de observadores, en la búsqueda de comparar diversas hibridaciones de técnicas, sus resultados y precisión.

Dimensión ontológica

Desde el punto de vista ontológico, se parte de la conceptualización de los conceptos relevantes para el entendimiento de una estructura LPR, derivados de la profundización por medio de la revisión de literatura. La Fig. 1 representa los conceptos más relevantes para este fin:



Fig. 1. Ontología de estructura LPR (Elaboración propia).

Dimensión axiológica

La dimensión axiológica corresponde al estudio de los valores, definiendo escalas de valores para evitar el uso de conceptos cuya definición llegue a ser muy ambigua o vaga en el contexto de la investigación. Los resultados de las estructuras planteadas deben ser sometidos a una evaluación de acuerdo con las rúbricas planteadas en la Tabla 1.

Tabla 1. Criterios para clasificar eficiencia y precisión (Elaboración propia).

| Nombre | Descripción | Evaluación |
|------------|--|--|
| Eficiencia | Velocidad del sistema o método a la hora de su ejecución en tiempo real. Se mide en segundos. | <p>Altamente eficiente</p> <p>Se considera altamente eficiente un sistema o método que produzcan su resultado en un tiempo menor de 5 segundos.</p> <p>Medianamente eficiente</p> <p>Se considera medianamente eficiente un sistema o método que llegue a un resultado en un tiempo de 5 a 8 segundos.</p> <p>Poco eficiente</p> <p>Se considera poco eficiente un sistema o método que llegue a un resultado en tiempo mayor a 8 segundos.</p> |
| | | <p>Altamente preciso</p> <p>Es altamente preciso el sistema o método con un porcentaje de aciertos mayor o igual al 95 %.</p> <p>Preciso</p> <p>Es preciso el sistema o método con un porcentaje de aciertos mayor o igual a 90 % y menor a 95 %.</p> <p>Medianamente preciso</p> <p>Es medianamente preciso el sistema o método cuyo porcentaje de aciertos sea mayor o igual a 70 % y menor a 90 %.</p> <p>Poco preciso</p> <p>Es poco preciso el sistema o método con un porcentaje de aciertos menor al 70 % y mayor a 60 %.</p> <p>Apenas preciso</p> <p>Es apenas preciso el sistema o método con un porcentaje de aciertos menor a 60 %.</p> |
| Precisión | <p>Porcentaje de procesamiento de datos exitoso del sistema o método.</p> <p>El porcentaje se calcula respecto a la cantidad de datos y a la cantidad de aciertos.</p> | |

Dataset

A pesar de que este tema de investigación ha sido abordado por parte de diferentes autores internacionales, no fue posible encontrar un conjunto de datos de placas vehiculares exclusivamente costarricenses y de acceso al público para el uso de datos a nivel nacional. Debido a esta situación,

se han utilizado datasets de origen internacional, siguiendo la etapa de la adquisición de imágenes para el aprendizaje automático recomendada en [6]. Estos se detallan a continuación como el material de entrenamiento de los modelos desarrollados.

Dataset de detección de placas

El dataset empleado para el entrenamiento del modelo destinado a la detección de placas vehiculares e identificación de ROI se denomina "Automatic Number Plate Recognition" y fue subido a la plataforma Kaggle por el usuario Aslan Ahmedov, contando con una calificación de 10 en usabilidad dada por la plataforma. Este dataset contiene 453 archivos, compuestos de 228 imágenes en formato JPEG en distintas resoluciones y 225 archivos en formato XML, donde se incluyen anotaciones de las imágenes. Las anotaciones se proporcionan en el formato PASCAL VOC, un estándar en el campo de la detección de objetos y localización, ampliamente utilizado por diferentes editores y herramientas de anotación para entrenar modelos de aprendizaje automático. Dichas anotaciones incluyen información como cuadros delimitadores (bounding box) de las matrículas de vehículos presentes en las imágenes, detalles de la imagen, clases, rotación y otros datos relevantes. Las zonas de interés se encuentran etiquetadas bajo la clase "license_plate" para diferenciar la placa vehicular del resto de la imagen.

Dataset de detección de vehículos

Para el entrenamiento del modelo de detección de vehículos utilizando YOLOv5, se ha empleado un dataset específico a partir del trabajo previo de Anhalu en su repositorio "vehicle-object-detection-using-YOLOv8", dataset originalmente creado para YOLOv8. Este conjunto de datos se compone de imágenes variadas que representan diferentes tipos de vehículos, como automóviles, motos, buses, camiones y bicicletas. El dataset se divide en tres segmentos principales: uno para entrenamiento, con 1197 imágenes; otro para validación, que incluye 117 imágenes; y un último para pruebas, con 16 imágenes. A pesar de que el dataset fue inicialmente recopilado para YOLOv8, se realizó una adaptación cuidadosa para que pudiera ser empleado eficazmente en el entrenamiento de un modelo basado en YOLOv5, una versión previa del algoritmo. Este proceso de adaptación fue crucial para asegurar la compatibilidad y eficacia del modelo en la tarea de detección de vehículos.

Tecnologías

Para el espacio de trabajo en que se desarrolló la aplicación, se utilizaron los ambientes de Google Colab contando con el plan “Pay As You Go”, el cual brinda una cantidad de 100 unidades informáticas para la GPU T4. El desarrollo del sistema se estableció usando Python 3.9, junto con el framework de Flask para el servidor web donde se hospeda el modelo de machine learning.

El sistema de reconocimiento automático de matrículas vehiculares desarrollado emplea una serie de fases trascendentales recomendadas por distintos autores para asegurar un funcionamiento eficiente en tiempo real, las cuales se encuentran representadas en la Fig. 2. Estas incluyen la extracción de placas vehiculares destacada en [11], la detección de zonas de interés (ROI) enfatizada en [15] y el reconocimiento óptico de caracteres (OCR), fase en la que en [23] se sugieren métodos avanzados para enfrentar condiciones de iluminación diversas.



Fig. 2. Flujo desarrollado (Elaboración propia).

Estas fases constituyen el eje central del sistema ALPR y son el reflejo de una integración de conocimientos y técnicas recomendadas por diversos autores con énfasis en la materia. Se logró implementar un flujo de trabajo que comienza con la detección del área de interés en la que se presente un vehículo de forma precisa, siguiendo las recomendaciones en [22], previa a la identificación y captura de la matrícula del vehículo. Para ambos modelos de detección de objetos se decidió utilizar el algoritmo YOLO, principalmente para seguir la recomendación en [16] y [17], sobre enfocar los esfuerzos en métodos que utilizan redes neuronales convolucionales. Para el desarrollo del modelo, se utilizaron las versiones del algoritmo v5 y v8. Debido al tamaño de los datasets empleados, se eligió el tamaño de modelo “S”. Los modelos YOLO poseen diferentes letras que representan los tamaños de los modelos preentrenados. Estos modelos varían en complejidad y capacidad de detección de objetos, con tamaños que van desde “n” (más ligero) hasta “x” (más pesado), lo que afecta la precisión y el rendimiento del modelo en tareas de detección de objetos, para la ejecución de pruebas.

Este proceso se optimiza mediante un preprocesamiento que incluye técnicas de binarización, dilatación, erosión y desenfoque gaussiano, los cuales son de suma importancia para preparar las imágenes para el proceso de OCR. El sistema utiliza EasyOCR, una librería de código abierto y robusta, para la detección de textos en distintas zonas de una imagen. Este enfoque permite una lectura precisa de las matrículas en condiciones variables y complejas.

En el siguiente apartado se detallan los resultados obtenidos usando estas bases y tecnologías para el entrenamiento del modelo de visión computacional y cómo se desenvuelven bajo los criterios establecidos.

IV. ANÁLISIS DE RESULTADOS

A continuación, se describen los resultados obtenidos usando la metodología planteada sobre el conjunto de tecnologías de desarrollo detallado en la Fig.3 y con el conjunto de datos descrito con anterioridad.



Fig. 3. Stack empleado para el desarrollo del sistema ALPR (Elaboración propia).

En primer lugar, se contempló el uso de modelos de la familia de EfficientNet, pero fueron descartados al estar orientados principalmente al área de clasificación de objetos, en lugar de la detección de objetos en tiempo real, en contraste con los modelos de la familia

Se empleó YOLO, que posee una gran capacidad para realizar detecciones en tiempo real, utilizando la menor cantidad de recursos computacionales y priorizando la eficiencia. Ambos modelos, YOLOv5 y YOLOv8, fueron entrenados durante el mismo número de épocas y tomando el mismo conjunto de datos internacionales descrito en el apartado de métodos.

Tabla 2. Parámetros y resultados de entrenamiento con los modelos de la familia YOLO para detección de placas (Elaboración propia).

| Modelo | YOLOv5 | YOLOv8 |
|--|---------------|---------------|
| Tamaño | S | S |
| Épocas | 100 | 100 |
| background vs. license_plate (Data de pruebas) | 96 % | 92 % |
| Confianza F1 | 0,96/0,442 | 0,96/0,524 |
| Precision-Confidence | 1,00/0,821 | 1,00/0,558 |
| Precision-Recall | 0,966 mAP@0,5 | 0,965 mAP@0,5 |
| Recall-Confidence Curve | 0,98/0,000 | 0,98/0,000 |
| Modelo | YOLOv5 | YOLOv8 |

De acuerdo con la Tabla 2, el modelo v5 exhibió una leve superioridad en la tarea de distinguir entre el fondo de la imagen y las matrículas, de modo que se alcanzó una precisión del 96 %, en comparación con el 92 % del modelo v8. El rendimiento de ambos tuvo una puntuación de 0,960, lo que indica alta precisión y sensibilidad en la detección de matrículas. Sin embargo, v8 tuvo un ligero incremento en términos de confianza, con un puntaje de 0,524 frente al 0,442 de v5. Este último mostró una mayor confianza (0,821) en comparación con YOLOv8 (0,558), lo que sugiere que mientras YOLOv5 fue más confiable, YOLOv8, aunque es preciso, fue menos consistente en sus predicciones.

Así, dichos resultados se representan también por medio de una matriz de confusión en la Fig.4 y Fig. 5, correspondientes al modelo YOLOv5 y YOLOv8, respectivamente.




Fig. 4. Matriz de confusión matrículas vehiculares con YOLOv5 (Elaboración propia).

La matriz de confusión en la Fig. 4 evalúa el rendimiento del modelo en la clasificación de matrículas vehiculares. De acuerdo con esta, se proyectan los siguientes resultados sobre el modelo YOLOv5 comparando fondos y placas en la imagen:

- Verdaderos positivos: Las matrículas se clasificaron correctamente el 96 % del tiempo.
- Falsos positivos: A veces se clasificó erróneamente algún elemento del fondo como matrículas en un 4 % de los casos.
- Falsos negativos: No se perdieron matrículas.
- Verdaderos negativos: Todo el fondo se clasificó correctamente.

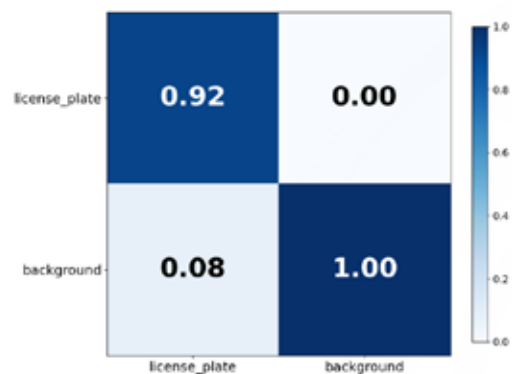


Fig. 5. Matriz de confusión matrículas vehiculares con YOLOv8 (Elaboración propia).

La Fig. 5 muestra una matriz de confusión para la detección de matrículas vehiculares utilizando el modelo YOLOv8. Los resultados bajo las mismas condiciones de la Fig. 4 son los siguientes:

- Verdaderos positivos: Las matrículas se clasificaron correctamente el 92 % del tiempo.
- Falsos positivos: A veces se clasificó erróneamente algún elemento del fondo como matrículas en un 8 % de los casos.
- Falsos negativos: No se perdieron matrículas.
- Verdaderos negativos: Todo el fondo se clasificó correctamente.

Dado que es evidente la consistencia altamente precisa del modelo YOLOv5, con base en la Tabla 2 y la Fig. 4, este fue seleccionado para conformar parte del flujo sistema en su rol de detección de placas vehiculares. La salida de este genera una o varias zonas de interés en la que se encuentra la placa vehicular identificada dentro de la imagen, dichas salidas se identifican en la Fig.6, donde se detectan las 2 placas presentes en la imagen de entrada.



Fig. 6. ROI generadas por el modelo de detección de placas (Elaboración propia).

Sin embargo, durante las etapas de pruebas y validación con el modelo de placas, se identificó un punto problemático a largo plazo, pues ciertos elementos viales que corresponden con características de placas internacionales levantan una detección falsa. Un ejemplo de esto se puede observar en la Fig. 7 en la que una señalización de tránsito en forma de rectángulo con la frase “4-WAY” es identificada como una placa vehicular.



Fig. 7. Detección de una señal de tránsito como una placa vehicular (Elaboración propia).

Esto se debe principalmente a que el dataset utilizado en el entrenamiento posee placas vehiculares internacionales, principalmente de países como Reino Unido y la India. Dichos países poseen matrículas con características menos diversas, pero con mayor cantidad de formatos, contrario a las placas de Costa Rica, las cuales son fácilmente identificables, debido a sus características propias y poseer variaciones dentro de las mismas. En consecuencia, ciertas señalizaciones de tránsito, carteles o letreros se tradujeron en un falso positivo, pues cumplen con las características de las placas de los vehículos presentes en el conjunto de datos de entrenamiento, siendo estas:

La presencia de un cuadrado o figura rectangular de algún color sólido.

- La presencia de letras y números.
- La presencia de un borde alrededor de las dos anteriores características.
- La presencia de figuras verticales, asemejándose a letras como “L”, “I”, “J”, o números como “7” o “1” encerradas en ángulos rectos.

Además, otros factores que influyeron en este tipo de detección son la cantidad de datos presentes durante el entrenamiento, las distintivas formas y colores de las placas internacionales. La confusión con letras del fondo que no se corresponden a zonas de interés en las que se ubique una placa vehicular, así como la muestra de marcas de agua, contribuyó también con la alerta de falsos positivos. Una muestra del dataset en la que se evidencian las características anteriormente descritas se representa en la Fig. 8.



Fig. 8. Muestra del dataset de entrenamiento utilizado (Elaboración propia).

Para abordar esta situación y como consecuencia de la falta de un dataset que permita realizar un entrenamiento exclusivamente basado en placas costarricenses, se decidió incluir en este punto un paso para centrar y dar mayor precisión a la búsqueda de placas vehiculares, lo que limita los datos que ingresan al modelo. Dicho proceso correspondió a la inclusión de un modelo de detección de vehículos como paso intermedio, como se sugirió en [22], esto permite primero ejecutar una búsqueda de zonas de interés con la presencia de vehículos, con ello, se reduce en gran medida la posibilidad de obtener detecciones no correspondientes a placas en el fondo. De igual forma, para este modelo de detección vehicular se optó por evaluar YOLOv5 y YOLOv8 igualmente en sus tamaños S. Los resultados de los mismos se detallan en la Tabla 3.

Tabla 3. Comparativa de modelos YOLOv5 y YOLOv8 para la detección de vehículos dentro de las imágenes (Elaboración propia).

| Modelo | YOLOv5 | YOLOv8 |
|-------------------------|---------------|---------------|
| Tamaño | S | S |
| Épocas | 10 | 10 |
| Confianza F1 | 0,72/0,294 | 0,58/0,309 |
| Precisión-Confidence | 1,00/0,993 | 1,00/0,998 |
| Precisión-Recall | 0,771 mAP@0,5 | 0,642 mAP@0,5 |
| Recall-Confidence Curve | 0,90/0,000 | 0,91/0,000 |

De acuerdo con estos resultados, v5 superó a v8 con un valor de 0.72 en comparación con 0.58, indicando que YOLOv5 logró un mejor equilibrio entre precisión y recall en términos de confianza F1. La precisión-confianza fue alta en ambos modelos, lo que implica que ambos fueron muy precisos al realizar detecciones cuando tienen confianza en sus predicciones.

En la métrica de precisión-recall (mAP@0.5), YOLOv5 demostró un rendimiento superior con un valor de 0.771 en de contra un 0.642 de YOLOv8. Esto sugirió que v5 se desempeñó mejor en la tarea de detección de objetos, siendo más preciso y recuperando más objetos relevantes. La curva de recall-confianza muestra que ambos modelos tuvieron valores de recall cercanos al 90 % incluso cuando la confianza fue baja (0,000), indicando que ambos modelos fueron capaces de identificar objetos con una alta tasa de recall incluso en situaciones de baja confianza.

De igual forma, los modelos YOLOv5 y YOLOv8 se representa en la Fig. 9 y Fig. 10, mediante una matriz de confusión que contempla las etiquetas presentes en el dataset vehicular usado durante el entrenamiento.




Fig. 9. Matriz de confusión vehículos con YOLOv5 (Elaboración propia).

La Fig. 9 presenta la matriz de confusión para la detección de vehículos utilizando el modelo YOLOv5, de la cual se obtuvieron los siguientes resultados: los automóviles se clasificaron correctamente el 76 % de las veces, las motocicletas el 79 %, mientras que los camiones mostraron una precisión más baja con solo un 37 % de predicciones acertadas. Por otro lado, los autobuses y las bicicletas presentaron altas precisiones, con un 89 % y 87 %, respectivamente. Sin embargo, se observó que el fondo se clasifica erróneamente como camiones en un 54 % de los casos.




Fig. 10. Matriz de confusión vehículos con YOLOv8 (Elaboración propia).

La Fig. 10 muestra la matriz de confusión generada por el modelo YOLOv8 para la detección de vehículos. Según los resultados, los automóviles se clasificaron correctamente en un 76 % de los casos, mientras que las motocicletas alcanzaron una precisión del 79 %. Los autobuses presentaron una alta precisión con un 89 %, y las bicicletas también tuvieron un desempeño destacable con un 62 %. Sin embargo, los camiones registraron una precisión considerablemente baja, con solo un 8 % de predicciones correctas. Además, se observó que el fondo se clasificó erróneamente como camiones en un 54 % de las ocasiones.

Tomando como base ambas matrices en la Fig. 9 y la Fig. 10, y los resultados obtenidos en la Tabla 3, YOLOv5 destacó en comparación con YOLOv8 al presentar una efectividad superior para la tarea de detección de objetos usando el mismo conjunto de datos, cubriendo también una mayor precisión con variedad de clases. Bajo estos criterios, terminó siendo seleccionado finalmente para formar parte del flujo de detecciones.

Es relevante destacar que los resultados obtenidos con los modelos YOLOv5 y YOLOv8, tanto para la detección de placas como para la detección vehicular, corresponden a hallazgos experimentales obtenidos bajo las condiciones específicas del

estudio, las cuales están detalladas en las Tablas 2 y 3. No se ha realizado un análisis exhaustivo de las diferencias estructurales entre YOLOv5 y YOLOv8 que explique por qué YOLOv5 mostró un mejor desempeño en estos casos específicos, más allá de las métricas de rendimiento observadas. Los resultados obtenidos fueron los factores determinantes para la selección del modelo más adecuado para las tareas específicas de este proyecto.

Con la implementación del modelo de detección vehicular seleccionado, las salidas del este se representan en la Figura 11, y corresponden a ROI con vehículos presentes, dichas zonas de interés se ingresan como entrada para el modelo de detección de placas vehiculares. Al utilizar estos datos, se evita alimentar con elementos que no sean vehículos, lo cual limita el ingreso de elementos similares a placas internacionales.



Fig. 11. Salidas del modelo de detección vehicular (Elaboración propia).

Adicionalmente, se limitó la salida del modelo para solo devolver ROI con vehículos con un ancho o altura mayor a 100px, esto con el fin de evitar que el modelo de placas analice vehículos muy lejanos cuya extracción de placa sea improbable dada su resolución. Con este enfoque, la corrección del falso positivo planteado anteriormente se demuestra en la Fig. 12, ignorando la señal de tránsito mal identificada previamente.



Fig. 12. Detección de una señal de tránsito como una placa vehicular corregida (Elaboración propia).

Mediante la librería OpenCV se recortaron las ROIs de las placas, ingresando una entrada mucho más limpia en el flujo de OCR. Siguiendo la tendencia provista por los autores referentes a sistemas ALPR, el uso de un OCR para la extracción de los caracteres alfanuméricos en las placas extraídas se presenta como una de las mejores y más eficientes opciones con este objetivo.

Inicialmente, se planteó agregar Pytesseract, una implementación en Python de Tesseract desarrollada por Google, como parte del flujo con OpenCV, igualmente se consideró KerasOCR, una biblioteca propia de Keras. Sin embargo, ambas herramientas se orientaban principalmente a la identificación de oraciones y párrafos de un texto. Por este motivo, se recurrió a EasyOCR, con el cual se aplican las funciones de preprocesamiento y se alimenta al OCR con la última imagen obtenida del flujo de detección y extracción. Previo a la lectura de caracteres, se transforma la imagen a escala de grises para descartar el uso de colores que puedan generar ruido en la entrada. Luego de esto, se aplicó, mediante el método Otsu, una operación de umbralización binaria sobre la imagen para obtener una versión binaria, agrupando los píxeles de la misma en blancos y negros. Después de esto, se aplican dos funciones con una matriz kernel 3x3. Primero, se realiza una dilatación de imagen para unir regiones de los caracteres que puedan estar separadas, posteriormente se hace una erosión de la imagen para eliminar ruido sobrante y refinar los caracteres. Por último, se aplica un desenfoque gaussiano para suavizar los bordes de los caracteres. El flujo consecuente de filtros se representa en la Fig. 13.



Fig. 13. Transformaciones y filtros aplicados a las placas (Elaboración propia).

Con el fin de probar la pertinencia del modelo de detección de placas al exponerse a matrículas vehiculares de Costa Rica, se recopiló un dataset compuesto por imágenes con vehículos costarricenses por medio de web scraping. Las imágenes fueron extraídas de sitios de compra y venta de vehículos. La cantidad de imágenes recopiladas fue de 638 imágenes, de las cuales se etiquetaron 729 placas en formato PASCAL VOC. Una muestra se evidencia en la Fig. 14.

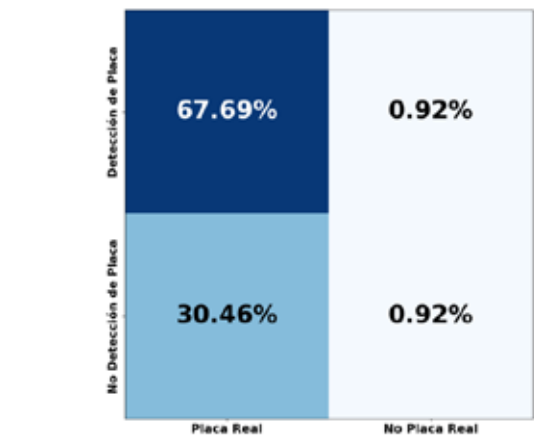


Fig. 14. Muestra de imágenes de vehículos costarricenses recopiladas mediante web scraping (Elaboración propia).

La Fig. 15 muestra la matriz de confusión del sistema de detección de placas vehiculares generada al realizar detecciones sobre el dataset de pruebas previamente descrito. Los resultados mostraron un 67,69 % de verdaderos positivos de placas cuando estas están presentes frente a un 30,46 % de falsos negativos, lo que indica que en estos casos el sistema no detectó la placa a pesar de que estaba presente. Sin embargo, los falsos positivos, es decir, las predicciones incorrectas de detección de placa cuando no había una placa real, representan solo un 0,92 %, al igual que los verdaderos negativos, donde el sistema acertó al no detectar una placa cuando efectivamente no la había. En este sentido, los resultados destacan la necesidad de mejorar la precisión del sistema, especialmente en la reducción de los falsos negativos.




Fig. 15. Matriz de confusión porcentual del desempeño del modelo con el dataset recopilado (Elaboración propia).

Para ilustrar esto, algunos de los ejemplos de detección más importantes, junto con sus porcentajes de confianza, se agregaron en la Fig.16.



Fig. 16. Resultados relevantes durante la prueba de detección (Elaboración propia).

En la imagen los casos 1, 4, 5, 6, 7, 8, 9 y 10 se corresponden a detecciones de placas completas en distintos ángulos, proximidad a la cámara o condiciones de luz. Por otro lado, las detecciones 2 y 3 representan placas que el modelo logró identificar a pesar de que están incompletas, tapadas o cortadas en la imagen. Por el contrario, las detecciones 11 y 12 corresponden a falsos positivos. Particularmente en el caso 11, este corresponde al logo de la marca del vehículo, contando con una estructura similar a la de placas internacionales presentes en el dataset de entrenamiento mostrado en la Fig. 8. Por otro lado, en el caso 12, la detección se dio en la esquina de la imagen, dado que se forma un ángulo de 90 grados y se cierra una forma cuadrada debido a la estructura de la cerca, da como resultado una semejanza a una placa con caracteres rectos como el número 1 o 7, lo que en consecuencia puede estar causando una detección errónea.

V. DISCUSIÓN Y CONCLUSIONES

El desarrollo del sistema ALPR descrito en este artículo representa un avance en cuanto a la seguridad vial en Costa Rica, dado que es posible reconocer placas vehiculares nacionales en entornos urbanos. Este enfoque es útil, puesto que permite identificar automáticamente las placas de los vehículos en imágenes o vídeos, lo que resulta beneficioso para la seguridad, el control de acceso y la gestión del tráfico.

No obstante, si bien es cierto que este método es funcional con placas costarricenses, los casos 11 y 12 presentes en la Fig. 15 evidencian que existen diversas limitaciones que abren la puerta a futuras mejoras, especialmente en lo que respecta a la precisión y eficiencia del sistema. Las principales limitaciones actuales del sistema se resumen en:

Impacto del dataset internacional en la detección de placas

El uso de un dataset con placas internacionales (principalmente de Reino Unido e India) generó la problemática en que elementos viales, señalizaciones de tránsito, carteles o letreros con características similares a las placas internacionales (forma rectangular, presencia de letras/números, borde, figuras verticales) a menudo fueron clasificados erróneamente como placas vehiculares, resultando en falsos positivos.

Necesidad de un modelo de detección vehicular auxiliar

Debido a los falsos positivos generados por el modelo de detección de placas al confundir elementos del fondo con placas internacionales, se incorporó un modelo de detección vehicular que limita el modelo de placas a solo las áreas donde se detectan vehículos. Si bien esto mejora la precisión, agrega un paso adicional al flujo de procesamiento, lo que podría impactar la eficiencia en ciertos escenarios.

Precisión mejorable con placas costarricenses:

Al probar el modelo de detección de placas entrenado con el dataset internacional con un dataset de pruebas recopilado con datos costarricenses, se obtuvieron resultados que, aunque funcionales, mostraron un margen de mejora. Específicamente, se registró un 67,69 % de verdaderos positivos y un 30,46 % de falsos negativos, lo que significa que en una proporción considerable de casos, el sistema no detectó la placa a pesar de estar presente.

Limitaciones en la corrección de perspectiva y ejes

La corrección de los ángulos de las placas para estandarizar las imágenes y facilitar la lectura mediante OCR no pudo implementarse debido a limitaciones técnicas de las herramientas utilizadas. Este proceso sería clave para mejorar la precisión en la lectura de placas en diferentes perspectivas.

Estas limitaciones destacan áreas clave donde el sistema actual enfrenta desafíos y donde se concentran las recomendaciones para futuros trabajos. Los hallazgos descritos y las limitaciones descritas con anterioridad tienen varias implicaciones importantes para futuras investigaciones en el área de reconocimiento de placas vehiculares en Costa Rica:

Necesidad de un dataset local exclusivo

La principal recomendación para futuras investigaciones es la creación de un dataset exclusivo para Costa Rica. El uso de un dataset local permitiría mejorar considerablemente el rendimiento y la precisión del modelo, eliminando los falsos positivos generados por placas extranjeras o elementos similares a estas. Además, un dataset costarricense adecuado podría eliminar la necesidad del paso intermedio de detección vehicular, lo que agilizaría el procesamiento de imágenes en tiempo real. Las placas costarricenses tienen características propias suficientes para distinguirlas directamente del fondo.

Validación de modelos en contextos locales

Aunque modelos avanzados como YOLOv5 y YOLOv8 han mostrado un buen desempeño en datasets internacionales, es fundamental validarlos en contextos locales. Comparar los resultados obtenidos con modelos entrenados en datos costarricenses permitirá determinar la efectividad de estos modelos y ajustar su rendimiento a las características locales.

Enfoque en optimización del flujo

Futuras iteraciones del trabajo deben centrarse en optimizar el flujo descrito o explorar arquitecturas de extremo a extremo que no requieran pasos intermedios, especialmente si se dispone de un dataset local adecuado. Esto no solo mejoraría la precisión, sino también la eficiencia del procesamiento.

Áreas de mejora técnica

Se identificaron varias áreas técnicas para mejorar, como la corrección de la perspectiva y los ejes de las placas, lo que facilitaría el preprocesamiento y mejoraría la calidad de los datos para el OCR. Aunque esta mejora no fue posible en este estudio, sigue siendo de suma importancia para futuras investigaciones.

Uso de recursos computacionales

El uso de GPU más avanzadas en futuras iteraciones del sistema podría facilitar el entrenamiento de modelos más complejos y la incorporación de datasets más grandes, eliminando la potencia computacional como un factor limitante. Esta mejora permitiría escalar el sistema y obtener mejores resultados con modelos más robustos.

RECOMENDACIONES

En la búsqueda de alcanzar un escenario técnico óptimo, los autores poseen interés en expandir el dataset a un conjunto de datos exclusivamente costarricenses. Todo esto con el objetivo de brindar continuidad y extender el trabajo desarrollado.

Finalmente, se considera la reiteración y la mejora continua de las distintas etapas del sistema como un proceso fundamental para el avance y la optimización del proyecto. Se invita a otros investigadores a participar en este campo, superando los resultados actuales y explorando nuevas posibilidades y aplicaciones del sistema ALPR propuesto, dando un énfasis especial al análisis de la relación entre sistemas ALPR y la expansión potencial de ciudades inteligentes en Costa Rica.

AGRADECIMIENTOS Y/O FINANCIAMIENTO

Este trabajo contó con el apoyo de la Universidad Cenfotec, patrocinando la investigación y formación de los autores dentro del marco de becas universitarias de excelencia. También se extiende un agradecimiento especialmente al doctor Robert Beck y al doctor Ulises Agüero.

REFERENCIAS

- [1] D. Solano Cambroner, “Anuario estadístico de accidentes de tránsito con víctimas en Costa Rica 2024,” Consejo de Seguridad Vial, 2024. [En línea]. Disponible en: <https://www.csv.go.cr/estad%C3%ADsticas>
- [2] Organismo de Investigación Judicial (OIJ), “El robo de vehículos se incrementa y usted puede salvar el suyo,” Sitio Oficial del Organismo de Investigación Judicial. [En línea]. Disponible en: <https://sitiooij.poder-judicial.go.cr/index.php/comunicacion/noticias/boletin-oij-actualidad-policial/item/22329-el-robo-de-vehiculos-se-incrementa-y-usted-puede-salvar-el-suyo>
- [3] L. N. Zeledón, “Investigación en Informática: el enfoque alternativo,” Technology Inside by CPIC, vol. 5, pp. 1–15, 2020.
- [4] J. Biolchini, P. G. Mian, A. C. C. Natali y G. H. Travassos, “Systematic review in software engineering,” System Engineering and Computer Science Department COPPE/UFRJ, Tech. Rep. ES-679.05, 2005.
- [5] P. Kulkarni, A. Khandebharad, D. Khope y P. U. Chavan, “License plate recognition: a review,” 2012 Fourth International Conference on Advanced Computing (ICoAC), pp. 1–8, dic. 2012.
- [6] S. Du, M. Ibrahim, M. Shehata y W. Badawy, “Automatic license plate recognition (ALPR): A state-of-the-art review,” IEEE Transactions on Circuits and Systems for Video Technology, vol. 23, no. 2, pp. 311–325, 2012.
- [7] T. Björklund, A. Fiandrotti, M. Annarumma, G. Francini y E. Magli, “Robust license plate recognition using neural networks trained on synthetic images,” Pattern Recognition, vol. 93, pp. 134–146, 2019.
- [8] W. Wang, J. Yang, M. Chen y P. Wang, “A light CNN for end-to-end car license plates detection and recognition,” IEEE Access, vol. 7, pp. 173875–173883, 2019.

- [9] R. Laroca, E. Severo, L. A. Zanlorensi, L. S. Oliveira, G. R. Gonçalves, W. R. Schwartz y D. Menotti, "A robust real-time automatic license plate recognition based on the YOLO detector," 2018 International Joint Conference on Neural Networks (IJCNN), pp. 1–10, jul. 2018.
- [10] B. Y. Amirgaliyev, C. A. Kenshimov, K. K. Kuvatov, M. Z. Kairanbay, Z. Y. Baibatyr y A. K. Jantassov, "License plate verification method for automatic license plate recognition systems," 2015 Twelfth International Conference on Electronics Computer and Computation (ICECCO), pp. 1–3, sep. 2015.
- [11] L. Xu, W. Shang, W. Lin y W. Huang, "License plate detection methods based on OpenCV," 2021 21st ACIS International Winter Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD-Winter), pp. 11–16, ene. 2021.
- [12] S. Yu, B. Li, Q. Zhang, C. Liu y M. Q. H. Meng, "A novel license plate location method based on wavelet transform and EMD analysis," *Pattern Recognition*, vol. 48, no. 1, pp. 114–125, 2015.
- [13] H. Lin, J. Zhao, S. Li y G. Qiu, "License plate location method based on edge detection and mathematical morphology," 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), vol. 1, pp. 853–857, jun. 2020.
- [14] I. Giannoukos, C. N. Anagnostopoulos, V. Loumos y E. Kayafas, "Operator context scanning to support high segmentation rates for real time license plate recognition," *Pattern Recognition*, vol. 43, no. 11, pp. 3866–3878, 2010.
- [15] C. S. Ahn, B. G. Lee, S. S. Yang y S. C. Park, "Design of car license plate area detection algorithm for enhanced recognition plate," 2017 4th International Conference on Computer Applications and Information Processing Technology (CAIPT), pp. 1–4, ago. 2017.
- [16] M. A. H. Bakhtan, M. Abdullah y A. Abd Rahman, "A review on license plate recognition system algorithms," 2016 International Conference on Information and Communication Technology (ICICTM), pp. 84–89, may. 2016.
- [17] M. F. Sadique y S. R. Haque, "A comparative study of license plate detection and recognition techniques," 2019 22nd International Conference on Computer and Information Technology (ICCIT), pp. 1–6, dic. 2019.
- [18] I. V. Pustokhina, D. A. Pustokhin, J. J. Rodrigues, D. Gupta, A. Khanna, K. Shankar et al., "Automatic vehicle license plate recognition using optimal K-means with convolutional neural network for intelligent transportation systems," *IEEE Access*, vol. 8, pp. 92907–92917, 2020.
- [19] D. Pu, N. Gu y X. Zhang, "A robust and real-time approach for license plate detection," 2018 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD), pp. 1–7, jul. 2018.
- [20] A. Menon y B. Omman, "Detection and recognition of multiple license plate from still images," 2018 International Conference on Circuits and Systems in Digital Enterprise Technology (ICCSDET), pp. 1–5, dic. 2018.
- [21] B. S. Shobha y R. Deepu, "A review on video based vehicle detection, recognition and tracking," 2018 3rd International Conference on Computational Systems and Information Technology for Sustainable Solutions (CSITSS), pp. 183–186, dic. 2018.
- [22] H. C. Kuo, J. S. Lee y S. T. Kao, "An autonomous license plate detection method," 2009 Fifth International Conference on Intelligent Information Hiding and Multimedia Signal Processing, pp. 110–113, sep. 2009.
- [23] A. P. Palanivel, T. Vigneshwaran, M. S. Arappadhan y R. Madhanraj, "Automatic number plate detection in vehicles using faster R-CNN," 2020 International Conference on System, Computation, Automation and Networking (ICSCAN), pp. 1–6, jul. 2020.
- [24] A. I. Mora Vargas, "Guía para elaborar una propuesta de investigación," *Revista Educación*, vol. 29, no. 2, pp. 77–97, 2012. [En línea]. DOI: <https://doi.org/10.15517/revedu.v29i2.2241>