



UNIVERSIDAD
NACIONAL
DE COLOMBIA

**METHOD FOR VEHICLE TYPE CLASSIFICATION AND LICENSE PLATE
RECOGNITION ACCORDING TO TOLL CLASSIFICATION IN COLOMBIA, USING
ARTIFICIAL INTELLIGENCE TECHNIQUES**

Sebastián Ocampo Montoya

Facultad de Minas
Universidad Nacional de Colombia
Medellín, Colombia
2024

**MÉTODO PARA LA CLASIFICACIÓN DEL TIPO DE VEHÍCULO Y EL
NÚMERO DE PLACA SEGÚN LAS CLASIFICACIONES DEL COBRO DE PEAJE
EN COLOMBIA, EMPLEANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL**

Sebastián Ocampo Montoya

Trabajo final presentado como requisito para optar por el título de:
Magister en Ingeniería – Analítica

Directores:

John Willian Branch Bedoya, Ph. D.

John Robert Ballesteros, Ph. D.

Facultad de Minas
Universidad Nacional de Colombia
Medellín, Colombia
2024

RESUMEN

El presente trabajo aborda la problemática de la congestión vehicular en los peajes de Colombia, donde las demoras generan altos costos logísticos y un impacto negativo en el medio ambiente. A pesar de los avances en infraestructura vial, los sistemas de cobro actuales, basados principalmente en efectivo o en el uso limitado del sistema TAG, resultan insuficientes para manejar el creciente volumen de tráfico. Este estudio propone un método para la clasificación vehicular y el reconocimiento de matrículas utilizando técnicas de inteligencia artificial, con el fin de mejorar la eficiencia en los sistemas de peaje. Se desarrolló una metodología basada en video-analítica y reconocimiento óptico de caracteres (OCR), que permite la identificación automática del tipo de vehículo y su placa, de acuerdo con las clasificaciones de cobro vigentes en Colombia. A través del uso de redes neuronales convolucionales (CNN) y modelos preentrenados como MobileNet y ResNet, se logró un desempeño adecuado en la clasificación de vehículos, siendo ResNet el modelo con mayor precisión. Adicionalmente, se identificaron áreas de mejora en el reconocimiento de matrículas, lo que sugiere que una mayor cantidad de datos y ajustes en las técnicas utilizadas podrían optimizar el sistema. Este trabajo plantea la posibilidad de implementar cobros de peaje completamente automáticos, mejorando la movilidad y reduciendo los tiempos de espera y el impacto ambiental.

Palabras clave: Congestión vehicular, Peajes en Colombia, Costos logísticos, Impacto ambiental, Sistemas de cobro en peajes, Clasificación vehicular, Reconocimiento de matrículas, Inteligencia artificial, Video-analítica, Reconocimiento óptico de caracteres (OCR), Redes neuronales convolucionales (CNN), MobileNet, ResNet, Cobro automático en peajes.

ABSTRACT

This research addresses the problem of vehicular congestion at toll stations in Colombia, where delays lead to high logistical costs and a negative environmental impact. Despite recent advancements in road infrastructure, current toll collection systems, primarily based on cash payments or limited TAG systems, are insufficient to handle increasing traffic volumes. This study proposes a method for vehicle classification and license plate recognition using artificial intelligence techniques, aiming to improve toll collection efficiency. A methodology based on video analytics and optical character recognition (OCR) was developed, enabling the automatic identification of vehicle types and license plates according to Colombia's toll fee classifications. Using convolutional neural networks (CNNs) and pre-trained models such as MobileNet and ResNet, an adequate performance was achieved in vehicle classification, with ResNet showing the highest accuracy. Additionally, areas for improvement were identified in license plate recognition, suggesting that a larger dataset and adjustments to the applied techniques could further optimize the system. This study demonstrates the feasibility of implementing fully automated toll collection systems, enhancing mobility and reducing wait times and environmental impact.

Keywords: Traffic congestion, Toll booths in Colombia, Logistic costs, Environmental impact, Toll collection systems, Vehicle classification, License plate recognition, Artificial intelligence, Video analytics, Optical character recognition (OCR), Convolutional neural networks (CNN), MobileNet, ResNet, Automatic toll collection.

Tabla de Contenido

1. INTRODUCCIÓN	7
1.1 Motivación.....	7
1.2 Trabajos previos	7
1.3 Definición del problema	8
1.4 Objetivos.....	8
1.4.1 Objetivo General.....	8
1.4.2 Objetivos específicos	8
1.5. Contribuciones.....	9
1.6. Estructura del documento	9
2. MARCO TEÓRICO DE REFERENCIA	10
2.1 Infraestructura Vial y Competitividad	10
2.2 Sistemas de Cobro Electrónico y Reducción de Costos	10
2.3 Impacto Ambiental de los Peajes Electrónicos	11
2.4 Inteligencia Artificial y Video-Analítica en Peajes	11
2.5 Barreras para la Adopción y Soluciones Propuestas.....	11
2.6 Conceptos clave de aprendizaje profundo	12
3. REVISIÓN SISTEMÁTICA DE LA LITERATURA	14
3.1 Bases de datos utilizadas.....	14
3.2 Criterios de inclusión.....	14
3.3 Filtros aplicados.....	14
3.4 Ecuaciones de búsqueda	15
3.5 Proceso de revisión.....	15
3.6 Principales fuentes de información seleccionadas	17
4. MÉTODO PARA LA CLASIFICACIÓN DEL TIPO DE VEHÍCULO Y EL NÚMERO DE PLACA SEGÚN LAS CLASIFICACIONES DEL COBRO DE PEAJE EN COLOMBIA, EMPLEANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL	19
4.1 Construir un conjunto de datos con base en diferentes fuentes de información, para su uso en el desarrollo del método a proponer.....	19
4.2 Emplear un método de clasificación de imágenes que permitan identificar el tipo de vehículo. 20	
4.2.1 Modelo MobileNet	22
4.2.1.1 Ventajas de MobileNet	22
4.2.1.2 Desventajas de MobileNet.....	23
4.2.2 Modelo ResNet.....	23
4.2.2.1 Ventajas de ResNet.....	23
4.2.2.2 Desventajas de ResNet	23
4.3 Emplear un método de reconocimiento de texto en imágenes (OCR) que permite extraer el número correcto de la placa del vehículo.....	24
. 4.3.1 Resultados OCR.....	24
4.4 Evaluar el método seleccionado mediante diferentes métricas de desempeño.	25

4.4.1 Resultados MobileNet	25
4.4.2 Resultados ResNet.....	27
4.4.3 Discusión de resultados	29
5. CONCLUSIONES Y TRABAJO FUTURO.....	30
6. REFERENCIAS.....	31

Tabla de gráficas

Figura 1. Ecuaciones de búsqueda en motores de datos	15
Figura 2. Cantidad de publicaciones encontradas	16
Figura 3. Cantidad de artículos por campo de estudio.....	16
Figura 4. Muestra de imágenes según categoría	19
Figura 5. Placas de vehículos con patrón colombiano	20
Figura 6. Representación red neuronal convolucional	21
Figura 7. Imagen original e imagen con umbralización adaptativa.....	24
Figura 8. Placas no identificadas	25
Figura 9. accuracy y pérdida datos de entrenamiento y prueba	25
Figura 10. Matriz de confusión MobileNet.....	26
Figura 11. Reporte de clasificación del modelo.....	26
Figura 12. accuracy y pérdida de entrenamiento y prueba.....	27
Figura 13. Matriz de confusión ResNet.....	28
Figura 14. Reporte de clasificación del modelo.....	28
Figura 15. Resultados generales modelos.....	29

1. INTRODUCCIÓN

1.1 Motivación

El desarrollo de infraestructura vial en Colombia ha sido un desafío constante debido a las complejidades geográficas del país, atravesado por tres cordilleras. Históricamente, este atraso en infraestructura ha elevado considerablemente los costos logísticos y el tiempo de transporte de mercancías entre los principales centros urbanos y los puertos. Sin embargo, en las últimas décadas, importantes inversiones han impulsado proyectos emblemáticos como el Túnel de la Línea (2020), la Ruta del Sol, los túneles de Occidente (2006) y Oriente (2019), así como las autopistas de Cuarta Generación (4G), que han mejorado significativamente la conectividad y reducido los tiempos de viaje.

A pesar de estos avances, el flujo vehicular en los accesos a las grandes ciudades, como Medellín y Bogotá, continúa enfrentando graves problemas de congestión, principalmente en los peajes, donde un recorrido que debería tomar 45 minutos puede extenderse hasta tres horas debido a los embotellamientos. Esta situación, descrita por IFM Noticias (2020), no solo afecta a los usuarios, sino que también genera un impacto negativo en el medio ambiente, aumentando las emisiones de CO₂ debido al constante arranque y detención de los vehículos. Además, las demoras en los peajes incrementan los costos logísticos del transporte, afectando la competitividad económica del país.

Frente a este contexto, surge la necesidad urgente de implementar sistemas de cobro de peaje más eficientes y automatizados que respondan a la creciente demanda de usuarios. La tecnología actual, basada en el sistema de TAG, ha demostrado ser un paso en la dirección correcta, pero su implementación sigue siendo insuficiente para resolver completamente el problema. La presente investigación busca abordar esta problemática mediante la propuesta de un sistema de clasificación vehicular y reconocimiento de matrículas basado en inteligencia artificial, que permitirá no solo mejorar la fluidez del tráfico, sino también mitigar los impactos ambientales y reducir los costos logísticos, contribuyendo así al desarrollo de un sistema de transporte más eficiente y sostenible.

1.2 Trabajos previos

Sin duda alguna, es necesario mencionar los impactos ambientales que generan las largas colas en el pago de los peajes, pues según Milekovic et al. (2020), los peajes que tienen sistema de cobro electrónico pueden reducir hasta en un 45% las emisiones de CO₂ de los vehículos que pasan por allí, lo que resulta en mitigar los impactos ambientales y el cual nos llevaría a pensar en proponer un sistema de pago diferenciado de peaje para garantizar la transición de los usuarios a los sistemas de pago electrónico de peaje. Este no es un dato menor, pues se demuestra nuevamente como los sistemas de la mano de la tecnología ayudan no solo a mejorar la movilidad, sino a mitigar los impactos ambientales por emisiones de gases de efecto invernadero, pero que también mejoran la calidad de vida de las personas al no ver su tiempo de traslados afectados por trancones asociados al paso por un peaje.

Otro de los puntos importantes es el aumento de los costos asociados a las demoras en los peajes, pues las empresas deben incurrir en gastos extra al transportar sus bienes y/o servicios

y que, tal como lo menciona FHWA (2020), las demoras en los peajes pueden aumentar los costos extra de transporte hasta en un 20%, lo que afecta claramente la productividad del país y le resta competitividad respecto a otros países de la región en los cuales el sistema vial y el sistema de pagos de peajes son diferentes. De esta manera, el tráfico promedio diario aumenta con el tiempo y las deficiencias en los sistemas de cobro de peaje que, en general, se hacen en efectivo, conllevan a unos sobrecostos adicionales que debe asumir el usuario de la carretera (Herrera, L. A., 2014), pues tan solo con aumentar el tiempo de su recorrido, el estar arrancado constantemente su vehículo y andar en los primeros cambios, genera un mayor uso de combustible, lo que genera una mayor emisión de dióxido de carbono (CO₂), y un deterioro mayor para las poblaciones cercanas al peaje en cuestión.

1.3 Definición del problema

En Colombia, existen 62 peajes con sistema de recaudo electrónico (Ministerio de transporte, 2023), pero estos peajes solo cuentan con el reconocimiento del TAG el cuál, al realizar una validación, permite o no el paso por el peaje, lo que muestra un avance en la implementación de tecnologías que permitan un mejor flujo vehicular pero que ha sido insuficiente en reducir los trancones que se presentan en los diferentes peajes que se encuentran en las diferentes entradas a las grandes ciudades de Colombia. Así pues, seguir avanzando en la búsqueda de mejorar el flujo vehicular, conlleva a pensar soluciones de análisis de fotos y videos que puedan ser implementadas en peajes estratégicos de Colombia con el fin de reducir el tiempo que una persona pasa en un trancón para entrar a la ciudad de destino. Cabe decir, que el tiempo en espera para pagar un peaje en Colombia resulta significativo y puede estar asociado no solo al peaje si no al estado de la vía donde está ubicado el mismo, pues existen peajes que cuentan con varias casetas e incluso aumento de carriles, mientras que hay otras que solo cuentan con una caseta por carril. Así pues, el tiempo promedio en espera en un peaje de Colombia es de 5 minutos, mientras que en horas de alto tráfico es de 12 minutos y en días festivo es de 21 (Hurtado, J.D, 2020), lo que da una idea de los costos adicionales que asume el usuario de la carretera. Otro punto para tener en cuenta son los problemas que tiene el uso del TAG en los peajes electrónicos, los cuales están asociados a la escasa iniciativa de las concesiones viales para promover e integrar el uso del cobro electrónico, que este servicio solo funcione en tramos de vías y no se pueda utilizar en todos los peajes, el mal funcionamiento del sistema entre otros (Espinoza, P. y Young, G., 2019), los cuales han generado un desinterés por el uso del sistema y que aún se prefiera el pago en efectivo de los peajes.

1.4 Objetivos

1.4.1 Objetivo General

Proponer un método para la clasificación del tipo de vehículo y extraer el número de placa, según las clasificaciones del cobro de peaje en Colombia, empleando técnicas de inteligencia artificial

1.4.2 Objetivos específicos

- Construir un conjunto de datos con base en diferentes fuentes de información, para su uso en el desarrollo del método a proponer.
- Emplear un método de clasificación de imágenes que permitan identificar el tipo de vehículo.
- Emplear un método de reconocimiento de texto en imágenes (OCR) que permite extraer el número correcto de la placa del vehículo.
- Evaluar el método seleccionado mediante diferentes métricas de desempeño.

1.5. Contribuciones

La contribución de este trabajo se basa en evidenciar que, aplicando video-analítica, existe una posibilidad para implementar cobros de peaje 100 % automáticos, sin necesidad de reducir la velocidad a la que se transportan los vehículos por las carreteras, evitando congestiones y reduciendo el tiempo de desplazamiento de los usuarios. Además, se identificará una metodología basada en redes neuronales y en reconocimiento de caracteres que permitirán identificar el tipo de vehículo y la placa según las categorías de cobro de peaje en Colombia.

1.6. Estructura del documento

Este documento está estructurado en seis (6) capítulos. En el primer capítulo se presenta la introducción. El segundo capítulo desarrolla el marco teórico. En el tercer capítulo se realiza una revisión de la literatura nacional e internacional sobre los sistemas de cobro automático de peajes, detallando sus ventajas y desventajas. El cuarto capítulo aborda el desarrollo de los objetivos específicos. El quinto capítulo expone las conclusiones y trabajos futuros. Finalmente, el sexto capítulo incluye las referencias bibliográficas.

2. MARCO TEÓRICO DE REFERENCIA

El marco teórico ofrece una revisión exhaustiva de los estudios relacionados con la modernización de la infraestructura vial y la implementación de tecnologías avanzadas para la gestión de peajes en América Latina. Este análisis permite comprender los avances y desafíos en torno al uso de inteligencia artificial (IA), la automatización de peajes y su impacto en la competitividad de la región.

2.1 Infraestructura Vial y Competitividad

El desarrollo de infraestructura vial ha sido un tema central en la competitividad de América Latina. Según Fernández Amanon (2022), la tecnología de reconocimiento de patrones mediante IA ha facilitado el control vehicular, especialmente en sistemas de seguridad, donde se detectan placas de vehículos requisitorizados. Este avance es clave para mejorar la eficiencia del tráfico y contribuir a la modernización de las redes viales. La calidad de la infraestructura influye directamente en la reducción de los tiempos de transporte, lo que a su vez afecta los costos logísticos y la competitividad, tal como lo señalan Martínez y Gutiérrez (2022).

En Colombia, las inversiones en proyectos de gran escala han mejorado la conectividad regional, pero persisten desafíos en las zonas de peaje. Según Heras Molina (2019), los sistemas de cobro electrónico, aunque eficaces en mejorar la fluidez del tráfico, enfrentan barreras en su implementación total, como la falta de interoperabilidad entre concesionarias, lo cual ha afectado su adopción generalizada.

2.2 Sistemas de Cobro Electrónico y Reducción de Costos

La introducción de tecnologías de cobro electrónico, como el sistema TAG y los peajes automáticos, ha sido un tema de creciente interés. Herrera (2014) evaluó la implementación de sistemas electrónicos de recaudo en Colombia y concluyó que estos no solo reducen las demoras en los peajes, sino que también contribuyen a disminuir los costos logísticos. Espinoza y Young (2019) subrayan que, a pesar de los avances en la tecnología de peajes en Lima, persisten problemas relacionados con la adopción de estas soluciones tecnológicas, debido a la falta de incentivos para su uso masivo y las fallas técnicas reportadas en las plataformas.

El uso de sistemas basados en IA para la clasificación y cobro automático de vehículos también ha sido ampliamente estudiado. Naaz et al. (2021) proponen un sistema de cobro electrónico basado en IA que permite automatizar el proceso de cobro en función del tipo de vehículo, lo que optimiza el flujo en las estaciones de peaje. Asimismo, Suryatali y Dharmadhikari (2015) demostraron cómo la visión por computadora y los sistemas embebidos mejoran la detección de vehículos, permitiendo que el cobro sea más eficiente y sin intervención humana.

2.3 Impacto Ambiental de los Peajes Electrónicos

Un aspecto clave de la modernización de los sistemas de peaje es su impacto ambiental. Fernández y Reyes (2022) señalan que el uso del sistema TAG reduce significativamente las emisiones de CO₂, ya que los vehículos no tienen que detenerse por completo en las estaciones de peaje. Este ahorro en combustible y reducción de emisiones contribuye a los objetivos de sostenibilidad en la infraestructura vial.

Además, Mileknovic et al. (2020) resaltan que la constante aceleración y frenado en los peajes manuales aumenta tanto el consumo de combustible como la emisión de gases contaminantes. La transición a peajes automatizados, según esta investigación, podría reducir las emisiones hasta en un 45%, al eliminar las demoras y la congestión vehicular.

2.4 Inteligencia Artificial y Video-Analítica en Peajes

La integración de tecnologías avanzadas, como la IA y la video-analítica, en los sistemas de peaje ha revolucionado la gestión de las carreteras. López y García (2021) exploran cómo las tecnologías de clasificación automática de vehículos mediante redes neuronales convolucionales (CNNs) han permitido una identificación más precisa y rápida de los vehículos, lo que facilita el cobro automático. Awang y Azmi (2018) implementaron una estrategia de CNNs con "*layer-skipping*" que mejoró el rendimiento de la clasificación de vehículos en tiempo real. Zhuang et al. (2020) destacan la importancia del *transfer learning* para acelerar el proceso de entrenamiento de modelos de IA en estos sistemas. Al reutilizar modelos previamente entrenados en grandes conjuntos de datos, los sistemas de cobro electrónico pueden mejorar su precisión y reducir la necesidad de costosos entrenamientos desde cero.

2.5 Barreras para la Adopción y Soluciones Propuestas

A pesar de los avances tecnológicos, existen barreras significativas para la adopción generalizada de los peajes electrónicos en América Latina. Soto y Calderón (2023) señalan que la falta de interoperabilidad entre concesionarias es uno de los principales obstáculos para la implementación eficiente del sistema TAG en Colombia. Los problemas técnicos y la falta de promoción adecuada también han desincentivado a muchos usuarios, lo que ha ralentizado la adopción de estas tecnologías.

Para superar estas barreras, Martínez y Gutiérrez (2022) proponen una mayor coordinación entre las concesionarias y el gobierno, además de campañas de sensibilización dirigidas a los usuarios. Asimismo, sugieren la implementación de normas de interoperabilidad que permitan unificar los sistemas de peaje en diferentes concesiones, facilitando su uso y mejorando la experiencia del usuario.

2.6 Conceptos clave de aprendizaje profundo

Aprendizaje Supervisado: El aprendizaje supervisado es un paradigma en el cual un modelo se entrena utilizando un conjunto de datos etiquetados, donde las respuestas correctas se proporcionan al modelo durante el proceso de entrenamiento. Este tipo de aprendizaje es fundamental en sistemas de IA utilizados en peajes electrónicos, donde los modelos aprenden a clasificar vehículos y reconocer patrones en imágenes de forma automatizada (Naaz et al., 2021).

Redes Neuronales Convolucionales (CNNs): las redes neuronales convolucionales (Convolutional Neural Networks) son un tipo de red neuronal profunda especialmente útil para el procesamiento de datos con estructura de cuadrícula, como imágenes. Las CNNs aplican filtros convolucionales sobre los datos para detectar características como bordes, texturas y patrones complejos en las imágenes. Esta arquitectura ha demostrado ser efectiva en tareas de reconocimiento de vehículos y clasificación automática en sistemas de peajes electrónicos (Awang & Azmi, 2018). En el contexto del reconocimiento de placas vehiculares, las CNNs son ampliamente utilizadas para mejorar la precisión en la identificación de caracteres (España Chamorro, 2021).

Transfer Learning: el transfer learning o aprendizaje por transferencia es una técnica en la cual un modelo preentrenado en una tarea se reutiliza y ajusta para una nueva tarea similar. Este enfoque reduce el tiempo de entrenamiento y mejora la precisión, ya que el modelo ya ha aprendido representaciones útiles en un conjunto de datos grande y puede aplicarlas a una tarea específica con menos datos disponibles (Zhuang et al., 2020). En el reconocimiento de matrículas vehiculares y la clasificación de vehículos, el transfer learning permite reutilizar modelos entrenados en grandes conjuntos de datos de imágenes, acelerando su implementación en sistemas de peaje electrónico.

Reconocimiento Óptico de Caracteres (OCR): El OCR (Reconocimiento Óptico de Caracteres) es una tecnología que convierte imágenes de texto impreso o manuscrito en texto digital editable. En el contexto del reconocimiento de placas vehiculares, el OCR se utiliza para identificar y extraer los caracteres alfanuméricos de las matrículas, facilitando la automatización del cobro en peajes electrónicos (TriFact365, 2024). El OCR es fundamental para sistemas que requieren la lectura rápida y precisa de placas en grandes volúmenes de tráfico (Signaturit, 2024).

Accuracy (Precisión): la precisión, o accuracy, es una métrica que mide el porcentaje de predicciones correctas realizadas por un modelo. En sistemas de reconocimiento de patrones y clasificación automática de vehículos, una alta precisión es esencial para garantizar la efectividad del sistema, especialmente cuando se utilizan técnicas como las CNNs para la clasificación de imágenes y OCR para la identificación de caracteres en placas vehiculares (Heras Molina, 2019).

Matriz de Confusión: La matriz de confusión es una herramienta que se utiliza para evaluar el rendimiento de un modelo de clasificación. Muestra las verdaderas etiquetas frente a las predicciones del modelo, permitiendo identificar correctamente las predicciones verdaderas positivas, falsas negativas, verdaderas negativas y falsas positivas. En sistemas de

clasificación vehicular y reconocimiento de placas, la matriz de confusión es útil para evaluar el rendimiento de algoritmos de reconocimiento de imágenes y mejorar su precisión (Fernández Amanon, 2022).

3. REVISIÓN SISTEMÁTICA DE LA LITERATURA

La búsqueda produjo un conjunto de artículos que cubren diversos aspectos de la automatización de peajes y el uso de tecnologías de inteligencia artificial (IA) para el reconocimiento vehicular, tanto desde una perspectiva técnica (visión por computador y redes neuronales artificiales) como de su implementación práctica en sistemas de cobro electrónico en América Latina. Estos artículos fueron fundamentales para el análisis de los avances en la infraestructura vial y la integración de IA en la clasificación de vehículos y cobro automatizado. Este enfoque permitió identificar las fuentes más relevantes y actualizadas para sustentar el trabajo de investigación.

3.1 Bases de datos utilizadas

Google Scholar: Principal motor de búsqueda académica utilizado para encontrar artículos sobre inteligencia artificial, visión por computadora y peajes electrónicos.

IEEE Xplore: Utilizado para obtener artículos técnicos sobre las implementaciones de IA y visión por computadora en sistemas de clasificación vehicular y peajes.

Scopus: Base de datos utilizada para identificar estudios relacionados con la implementación de sistemas de cobro electrónico de peajes y su impacto en América Latina.

3.2 Criterios de inclusión

Tipo de publicación: Artículos revisados por pares (peer-reviewed) y estudios académicos relevantes.

Temática: Estudios que abordaran la automatización de peajes, el uso de IA y tecnologías de visión por computadora, reconocimiento óptico de caracteres (OCR), y su impacto en la infraestructura vial.

Publicación: Publicaciones desde el año 2010 en adelante, con un enfoque especial en estudios que mencionaran tecnologías recientes y el uso de aprendizaje de máquinas.

3.3 Filtros aplicados

Idioma: Se seleccionaron artículos en inglés y español.

Fecha de publicación: Principalmente de los últimos 4 años, con énfasis en los avances tecnológicos y estudios recientes.

Tipo de publicación: Artículos de investigación, revisiones sistemáticas y estudios de caso.

Áreas temáticas: Inteligencia artificial, tecnologías de la información, visión por computadora, transporte y logística, y automatización de peajes.

3.4 Ecuaciones de búsqueda

A continuación, se muestra las ecuaciones de búsqueda aplicadas a las tres (3) bases de información consultadas.

Librería	Ecuación de búsqueda
Google scholar	TITLE-ABS-KEY("inteligencia artificial" OR "sistema de pórtico libre" OR "visión por computadora para clasificación de vehículos" OR "transfer learning" OR "sistemas free-flow") AND PUBYEAR > 2010
IEEE Xplore	TITLE-ABS-KEY("inteligencia artificial en los peajes" OR "clasificación de vehículo con IA" OR "implementación de inteligencia artificial en los peajes" OR "detección de placas con inteligencia artificial" OR "sistemas de peaje automatizados") AND PUBYEAR > 2018
Scopus	TITLE-ABS-KEY("tiempo de espera en los peajes" OR "impactos ambientales por demora en peajes" OR "implementación de inteligencia artificial en los peajes" OR "detección de placas con inteligencia artificial" OR "sistemas de peaje automatizados" OR "costos por demora en los peajes" OR "infraestructura vial") AND PUBYEAR > 2014

Figura 1. Ecuaciones de búsqueda en motores de datos

3.5 Proceso de revisión

Se realizó una revisión exhaustiva de títulos y resúmenes de los artículos identificados para evaluar su relevancia respecto al tema de investigación. Los artículos seleccionados fueron leídos en su totalidad para garantizar que cumplieran con los objetivos planteados, y se aplicó un filtro adicional para priorizar estudios sobre la aplicación de IA en peajes electrónicos y reconocimiento vehicular.




Figura 2. Cantidad de publicaciones encontradas

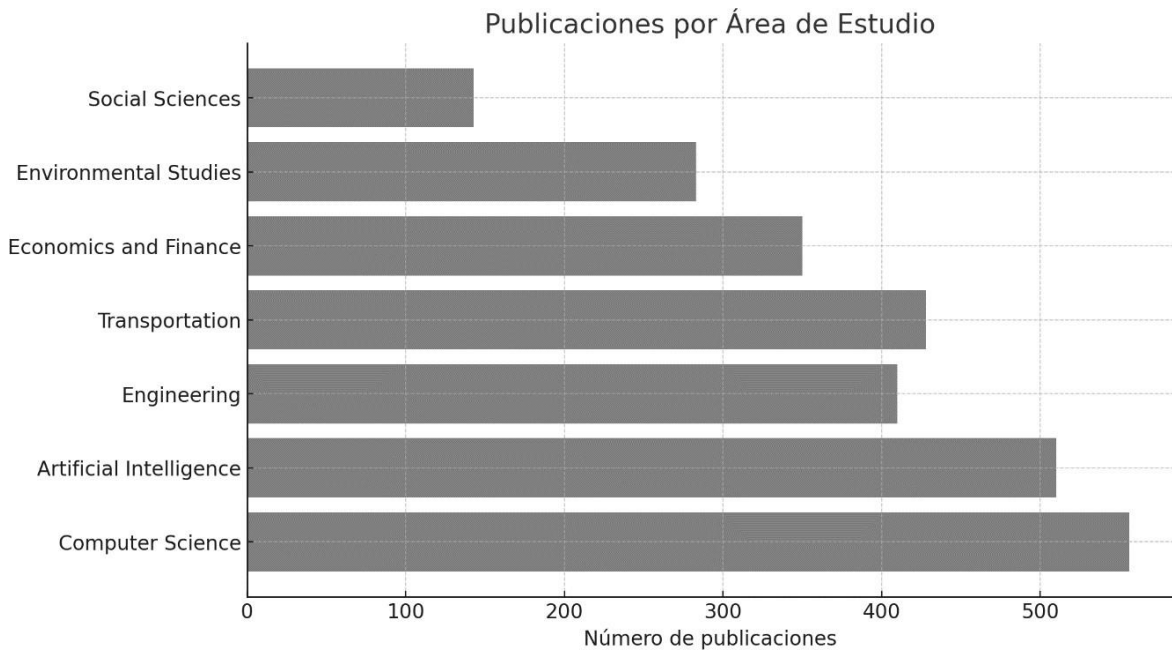


Figura 3. Cantidad de artículos por campo de estudio

Con la combinación de palabras clave como "peajes electrónicos", "inteligencia artificial", "OCR", "clasificación vehicular", "vision por computadora", se recopilieron los artículos más relevantes. En las Figuras 7 y 8 se muestran los resultados de esta búsqueda, que arrojó un

total de 1,850 artículos. Además, se agrupan las áreas temáticas en que se clasifican dichos estudios, lo que proporciona una visión más clara sobre la relevancia de cada uno dentro del contexto del estudio.

3.6 Principales fuentes de información seleccionadas

Diversas investigaciones han demostrado que la implementación de sistemas de pódicos *free flow* genera beneficios tanto para las concesionarias como para los usuarios, lo que también se traduce en una reducción de los costos asociados al transporte terrestre. A continuación, se exponen los estudios más relevantes que apoyan esta idea.

Fernández (2022) propone un sistema de reconocimiento de patrones para detectar las placas de los vehículos requisitorizados por la Policía Nacional del Perú. El estudio evidencia que, mediante el uso de técnicas de inteligencia artificial, la precisión del sistema aumenta del 64% al 86%, incrementando el número de vehículos requisitorizados del 55% al 74%. Este resultado muestra cómo la IA mejora de manera sustancial la resolución de problemas cotidianos.

Por otro lado, Morán (2023) concluye que la solución a los problemas de movilidad no siempre radica en la creación de más carriles, sino en la sistematización de los peajes existentes, sugiriendo que es más factible evolucionar hacia tecnologías modernas que impacten positivamente la calidad de vida de las personas.

En el caso de Colombia, España (2021) analiza diversas metodologías de aprendizaje automático en el reconocimiento de placas vehiculares con el objetivo de determinar cuál técnica ofrece mejores resultados en la identificación precisa de los caracteres de las placas. Espinoza y Young (2019) abordan los problemas del sistema de pago electrónico de peajes mediante TAG. Los autores concluyen que las causas por las cuales el efectivo sigue siendo el método de pago más utilizado se deben a fallos en la implementación y falta de interés por parte de los usuarios, lo que ha limitado la adopción del sistema.

En la India, Suryatali y Dharmadhikari (2015) analizan las ventajas y desventajas de los sistemas de cobro de peaje vigentes, sugiriendo que se deberían desarrollar sistemas de bajo costo basados en visión por computador para mejorar la eficiencia de los cobros.

Por su parte, Herrera (2014) realiza una evaluación de los sobrecostos asociados al tiempo de espera en los peajes de Colombia. Su estudio estima los ahorros a 20 años que se podrían generar mediante la implementación de un sistema que reduzca dichos tiempos de espera.

En el ámbito de los sistemas de cobro electrónico en Colombia, Hurtado (2020) identifica los factores que podrían incentivar el uso masivo del sistema Flypass, encontrando que las características y marcas de los vehículos inciden en la adopción generalizada de este sistema de recaudo.

En el campo del aprendizaje profundo, Zhuang, Qi et al. (2020) revisan los enfoques modernos de Transfer Learning, destacando sus beneficios en la reducción de costos computacionales y tiempos de entrenamiento, lo cual puede ser clave para el desarrollo de sistemas eficientes de visión por computador aplicados en peajes.

Finalmente, Zoph, Cubuk et al. (2020) analizan el impacto de las técnicas de aumentación de datos y la interpolación bilineal en la robustez de los modelos entrenados para tareas de visión por computador, como el redimensionado de imágenes, lo que puede mejorar el rendimiento de los sistemas de reconocimiento en peajes.

En resumen, las investigaciones citadas abordan de manera integral las ventajas y desventajas de los sistemas de recaudo actuales, los costos asociados a las demoras en los peajes y la propuesta de nuevos sistemas basados en visión por computador para mejorar la eficiencia y reducir los costos.

4. MÉTODO PARA LA CLASIFICACIÓN DEL TIPO DE VEHÍCULO Y EL NÚMERO DE PLACA SEGÚN LAS CLASIFICACIONES DEL COBRO DE PEAJE EN COLOMBIA, EMPLEANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL

4.1 Construir un conjunto de datos con base en diferentes fuentes de información, para su uso en el desarrollo del método a proponer

La base de datos que se utilizará para realizar el método de identificación del tipo de vehículo y el número de placa, fue construido por el autor de este trabajo utilizando diferentes fuentes de información y consolidando las imágenes en una carpeta que contiene subcarpetas según la categoría de los pagos de peaje en Colombia de la siguiente manera: automóviles y camperos (Categoría I), buses, busetas y camiones de 2 ejes (Categoría II), camiones de 3 ejes (Categoría III), camiones de 4 ejes (Categoría IV) y camiones de 5 o más ejes (Categoría V). Recordemos que las motocicletas están por fuera del alcance de este trabajo pues en el año del desarrollo del mismo, dichos vehículos no pagan ningún peaje en el territorio Nacional.

La base de datos de tipos de vehículos cuenta con 984 imágenes las cuales están distribuidas en las 5 categorías de la siguiente manera:

- Categoría I: 163 imágenes
- Categoría II: 297 imágenes
- Categoría III: 178 imágenes
- Categoría IV: 172 imágenes
- Categoría V: 174 imágenes



Figura 4. Muestra de imágenes según categoría

Dado que la cantidad de imágenes recolectadas fueron muy pocas para un modelo de aprendizaje profundo, se procedió a tomar cada imagen y cambiarle el color a través de 5 diferentes actores de color, generando así nuevas imágenes a partir de la original. Esto resultó importante, ya que pudimos realizar una aumentación de datos que permitiera tener una muestra significativa para el modelo a utilizar, sabiendo que el objetivo del modelo es identificar el tipo de vehículo y no el color del mismo, por lo que esta técnica de generación de nuevas imágenes resulta ser correcta para aplicarla en nuestro modelo. Así pues, la cantidad de imágenes pasaron de 984 a 6369 distribuidas de la siguiente manera:

- Categoría I: 978 imágenes
- Categoría II: 1782 imágenes
- Categoría III: 1068 imágenes

- Categoría IV: 1032 imágenes
- Categoría V: 1044 imágenes

La base de datos para la extracción de placas cuenta con 198 placas de vehículos de Colombia tomada de kaggle, las cuales nos permitirán evaluar el comportamiento de la metodología de extracción de caracteres OCR para la identificación del número de placa, aplicando expresiones regulares para garantizar que el patrón de tres letras y tres números sea plenamente identificado y unido a una clasificación del tipo de vehículo para poder completar el flujo y los objetivos de este trabajo. Las imágenes de placas están de la siguiente manera:



Figura 5. Placas de vehículos con patrón colombiano

4.2 Emplear un método de clasificación de imágenes que permitan identificar el tipo de vehículo.

Una de las metodologías más usadas para el análisis de imágenes son las redes neuronales convolucionales (CNN), estas son una clase de redes neuronales profundas que se han utilizado con gran éxito en tareas de clasificación de imágenes. El modelo de CNN se basa en el concepto de convolución, donde una imagen de entrada se procesa con un conjunto de filtros para extraer características relevantes. Estas características se utilizan para clasificar la imagen de entrada en diferentes categorías (Saha et al., 2020).

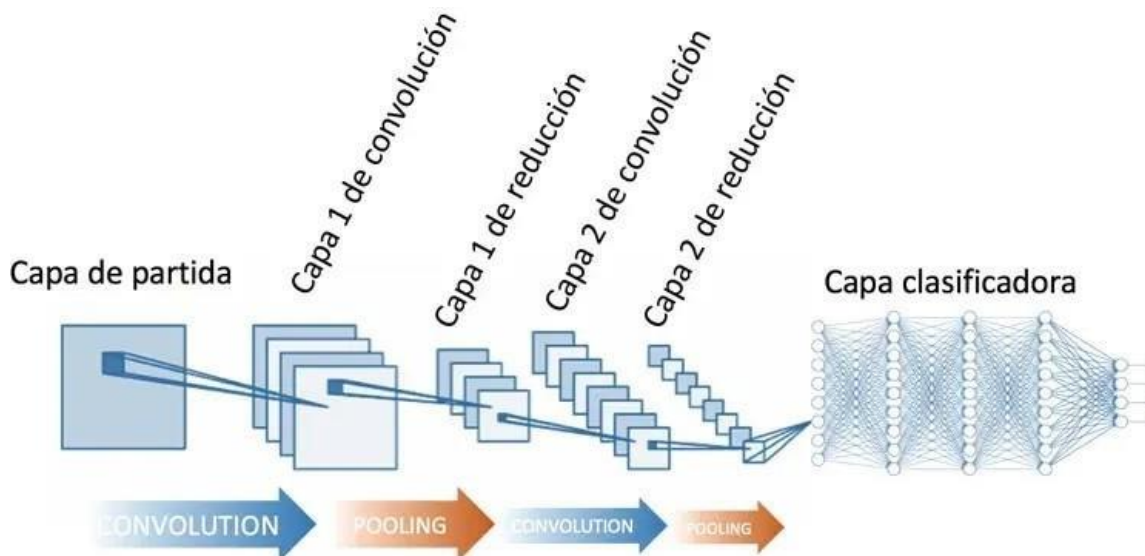


Figura 6. Representación red neuronal convolucional

Dado lo anterior, desde principios de la década pasada, las redes neuronales pre-entrenadas para clasificación de imágenes han tomado fuerza, pues, gracias a la competencia ILSVRC (ImageNet Large Scale Visual Recognition Challenge) y al desarrollo de una red neuronal basada en convoluciones diseñada por diseñada por Alex Krizhevsky, Ilya Sutskever y Geoffrey Hinton, revolucionó la competencia al ganarla con un margen significativo. Fue a partir de ahí que a través de la transferencia de conocimiento (transfer learning) que estas redes fueron optimizadas y pre-entrenadas para utilizarlas en distintas tareas de clasificación basadas en la base de datos ImageNet y que al día de hoy representan una disminución de costo computacional pues las redes no se tienen que volver a entrenar sino que las redes contienen parámetros optimizados que le permite tener la capacidad de generalizarse a cualquier base de datos y solo el usuario debe ajustar las capas finales según la necesidad de su trabajo (Zhuang, F., Qi, Z, et. Al, 2020).

Además, las imágenes inicialmente cuentan con tamaños no estandarizados donde la imagen con menor tamaño tiene forma 512 x 94 y la imagen con mayor tamaño tiene forma 1920 x 838, lo que resulta en la necesidad de generar una estandarización de las imágenes que según la literatura, el tamaño recomendado para el tratamiento de imágenes es de 224 x 224, ya que estos tamaños son los que mejor balance tienen entre costo computacional y detalles de la imagen, es decir, una imagen con un tamaño grande tiene más detalles y facilita aprender patrones a los modelos con mayor facilidad, pero esto resulta en un entrenamiento mucho más costoso computacionalmente del modelo. Por el contrario, una imagen pequeña tiene menos detalles y dificulta el aprendizaje de patrones, pero el entrenamiento del modelo resulta ser poco costoso computacionalmente. Así pues, el tamaño recomendado y utilizado para este trabajo será 224 x 224. Para lograrlo, la librería de Python KERAS incluye una metodología para redimensionar las imágenes de manera automática, la cual está basada en la librería PIL que realiza una interpolación bilineal. Esta técnica, calcula los valores de los pixeles de la imagen redimensionada basándose en una media ponderada de los 2x2 pixeles vecinos más cercanos

Otra consideración sobre las imágenes son los colores, pues las imágenes que se utilizarán para este modelo tienen los tres canales (R, G, B), y al utilizar un modelo pre-entrenado como MobileNet, este requiere que las imágenes tengan los tres canales. Lo que si se hará es una normalización de las imágenes para que cada pixel tenga un valor entre 0 y 1 lo que tenderá a mejorar el rendimiento del modelo, pues funciones de activación como la ReLu o Sigmoid, tienden a ser más estables y eficientes en estos rangos de valores.

Como vimos más arriba, las 5 categorías tienen cantidad de imágenes muy parecidas, lo que de entrada nos evita el problema de clases desbalanceadas y tener que implementar metodologías de balanceo de clases como el undersampling, oversampling, under-oversampling, entre otras, lo que evita incluirle ruido al modelo y poder utilizar métricas de evaluación como el accuracy, el cual es recomendado en caso de data balanceada como lo son los datos para este trabajo.

Cabe mencionar que la base de datos fue particionada en 70 % entrenamiento y 30 % validación, luego se le aplicó al modelo un Global Average Pooling (GAP) con el fin de

reducir la dimensionalidad de la salida del modelo pre-entrenado, ayudando a reducir el número de parámetros en las capas densas posteriores y evitando así un posible sobreajuste en el modelo. A las capas densas posteriores, las cuales son las encargadas de combinar las características extraídas por las capas convolucionales del modelo base, se les aplicó una regularización L2 que permite aplicarle a la función de coste original una penalización para que los parámetros muy grandes se conviertan en valores pequeños con el fin de evitar un sobreajuste al modelo. La penalización es de la siguiente manera:

$$L_2(X, w) = L(X, w) + \lambda \sum w_i^2$$

Esta función depende del valor lambda que será un valor muy pequeño (0.1, 0.01, ...) el cual se escogerá de manera arbitraria y que a medida que el valor sea más pequeño, la penalización será mucho mayor.

También, se aplicó un dropout del 0.5, lo cual nos permite apagar aleatoriamente el 50 % de las capas en cada entrenamiento con el fin de evitar el sobreajuste dentro del modelo, obligando al modelo a no depender de ciertas neuronas específicas para la extracción de características, mejorando su capacidad de generalización al distribuir mejor el aprendizaje entre todas sus capas. Así como lo explican Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014), un dropout de 0.5 reduce el sobreajuste en muchos de los casos de estudio donde se probaron varios valores para este parámetro, por lo cual recomiendan que el valor predeterminado sea el mencionado.

4.2.1 Modelo MobileNet

La primera red neuronal convolucional que se utilizó para este trabajo, fue la red pre-entrenada conocida como MobileNet, la cual fue desarrollada por Google en 2017 y está diseñado principalmente para tener un buen desempeño en dispositivos móviles y embebidos (Sandler, M., Howard, A., et al, 2018). Este modelo pre-entrenado, tiene alrededor de 150 capas y alrededor de 3.4 millones de parámetros, donde utiliza convoluciones separables por profundidad para reducir la complejidad computacional (Howard, A. G., 2017). De las 150 capas se utilizaron 120 capas congeladas, es decir, se incluirán para el ejercicio con los parámetros previamente entrenados, luego se entrenaron 30 capas con los datos de este trabajo y se le agregó una capa de salida con las 5 posibilidades de tipo de vehículo para este trabajo.

4.2.1.1 Ventajas de MobileNet

Como lo explican Howard, A. G. (2017) en su artículo sobre la eficiencia de MobileNet para aplicaciones móviles, destaca que la ventaja de usar esta red recae sobre la eficiencia computacional ya que al utilizar convoluciones separables por profundidad, se reduce el número de parámetros y las operaciones computacionales. Además, el modelo incluye dos hiperparámetros asociados al multiplicador de ancho y resolución de la imagen, el cual permiten ajustar el modelo en función de las necesidades particulares de cada objetivo que

este resolviendo, lo que la hace más eficiente para uso en tiempo real principalmente en aplicaciones móviles y sistemas embebidos.

4.2.1.2 Desventajas de MobileNet

Por otro lado, Howard, A. G. (2017) explica que MobileNet también sufre de algunas desventajas como menor precisión en tareas complejas, pues en comparación con ResNet o Inception, la reducción de parámetros y operaciones y los parámetros asociados al multiplicador de ancho y de resolución de imagen, pueden generar una menor precisión en los resultados que entrega el modelo.

4.2.2 Modelo ResNet

La segunda red neuronal que se utilizó en este trabajo, conocida como ResNet fue introducida en 2015 por Kaiming He, Xiangyu Zhang, Shaoqing Ren, y Jian Sun en su artículo titulado "Deep Residual Learning for Image Recognition". Allí, los autores explican que este modelo resolvió el problema del desvanecimiento de gradientes que ocurría en las redes neuronales muy profundas. Lo anterior, explican, se logró incluyendo conexiones residuales (skip connections), permitiendo que las capas puedan aprender a través de la optimización de los residuos en lugar de transformaciones completas (He., et al 2015). Sobre la variante de esta red pre-entrenada que se utilizó fue la ResNet-50, la cual incluye 50 capas convolucionales y alrededor de 25.4 millones de parámetros y a la cual se le agregó, adicional a los parámetros explicados en el numeral 4.1, una capa de salida con las 5 posibilidades de tipo de vehículo para este trabajo.

4.2.2.1 Ventajas de ResNet

Sobre las ventajas del uso de ResNet, Hasana, S.A., et al (2023), explica que, dada la solución al problema del desvanecimiento del gradiente, el modelo nos permite entrenar redes con 50, 101 e incluso 152 capas convolucionales sobre bases de datos grades como ImageNet sin perder su precisión. También explica que ResNet ha demostrado ser más escalable y robusto frente a cambios en los datos y en los parámetros del modelo, lo que le permite tener ventaja sobre arquitecturas más simples como VGG. Por último, explica que, en comparación con arquitecturas complejas, su costo computacional es menor.

4.2.2.2 Desventajas de ResNet

Sobre las desventajas del uso de ResNet, Hasana, S.A., et al (2023) advierte que, debido a su complejidad, requiere mayor uso de memoria para el entrenamiento de la red y que su convergencia podría tardar más, respecto a arquitecturas más simples, lo que en algunos casos podría ser una limitación. Por último, advierte que, debido a su diseño más profundo y a las conexiones residuales, puede ser más difícil de entender e implementar en un proyecto de inteligencia artificial.

4.3 Emplear un método de reconocimiento de texto en imágenes (OCR) que permite extraer el número correcto de la placa del vehículo.

Para extraer el número y las letras de una placa vehicular, utilizamos un método de reconocimiento de texto en imágenes (OCR), el cual fue desarrollado por primera vez en la década de 1920, pero su avance significativo se produjo en los años 70 cuando Ray Kurzweil creó el primer OCR "omnifont" que podía reconocer texto en casi cualquier fuente (TriFact365, 2024).

Para cumplir con el objetivo, utilizaremos la librería "easyocr", la cual fue creada por **JaiedAI**, una organización centrada en el desarrollo de herramientas de inteligencia artificial accesibles y fáciles de usar. EasyOCR es una biblioteca de Python que facilita el reconocimiento óptico de caracteres (OCR) utilizando redes neuronales profundas, y está diseñada para ser eficiente y fácil de implementar. Soporta más de 80 idiomas y se basa en PyTorch, una conocida biblioteca de aprendizaje profundo (JaiedAI, 2023).

Para mejorar el comportamiento de esta metodología, a las imágenes se les aplicó umbralización adaptativa, cuyo objetivo es convertir los píxeles de una imagen en escala de grises a una imagen binaria, es decir, una imagen donde los píxeles tienen solo dos valores: blanco o negro (Seelaboyina, R., & Vishwakarma, R., 2023). Lo anterior, tiene como objetivo reducir el ruido en las imágenes, compensar las variaciones en iluminación que tiene cada imagen y que el OCR tenga un mayor comportamiento, además de normalizar la imagen para que su procesamiento sea más preciso y los resultados de extracción de texto mejoren.

Luego de aplicar esta metodología, las imágenes quedan de la siguiente manera:




Figura 7. Imagen original e imagen con umbralización adaptativa

4.3.1 Resultados OCR

Luego de pasar las 198 imágenes de placas por la librería easyocr en Python y de usar expresiones regulares para identificar letras y números de las placas con el patrón colombiano, es decir, tres letras seguidas de 3 números, los resultados generados al usar esta metodología tuvieron una precisión del 94,9 %, pues la librería logró identificar 188 placas de manera correcta, equivocándose solamente en 10 placas. Al analizar los errores, nos encontramos con algunas dificultades en las imágenes de la siguiente manera:



Figura 8. Placas no identificadas

Tal cual como nos muestra la figura 5, existen limitaciones para que el desempeño del OCR sea el correcto, pues letras y números borrosos o tapados, generaron que la identificación no se lograra al 100 %, y puede convertirse en un reto sobre una futura aplicación de la metodología en diferentes proyectos de cobros de peaje.

4.4 Evaluar el método seleccionado mediante diferentes métricas de desempeño.

Luego de entrenar ambos modelos y probarlos, esta sección se dedicará a discutir los resultados de ambos modelos pre-entrenados: ResNet y MobileNet.

4.4.1 Resultados MobileNet

Luego de entrenar el modelo para la detección del tipo de vehículo, evaluamos el modelo utilizando el accuracy como métrica principal, pues con esta es más que suficiente ya que los datos no sufren de desbalanceo en sus categorías. Además, generamos la matriz de confusión y un reporte general de clasificación los cuales generaron los siguientes valores:




Figura 9. accuracy y pérdida datos de entrenamiento y prueba

En la gráfica anterior, podemos observar que a pesar que la curva de pérdida de validación y entrenamiento van en la misma dirección, la curva de accuracy de entrenamiento y validación

son muy distintas, pues en la curva de datos de entrenamiento, los valores oscilan poco entre 0.9 y 1.0, mientras que para la validación su oscilación es mucho más explícita, lo que podría indicar problemas de sobreajuste en el entrenamiento y dificultades para el modelo poder generalizar. Recordemos que esto se trató de evitar incluyendo regularización l2 y dropout al modelo.




Figura 10. Matriz de confusión MobileNet

A pesar de utilizar metodologías para evitar el sobreajuste y la evidencia que el modelo no está generalizando, en la matriz de confusión nos muestra que el modelo no es capaz de identificar el tipo de vehículo a partir de las imágenes de validación, lo que apoya aún más la hipótesis de falta de generalización en el modelo.

Categoría	Precision	Recall	F1-score
automoviles y camperos	0,18	0,17	0,17
buses, busetas y 2 ejes	0,3	0,2	0,24
3 ejes	0,21	0,32	0,25
4 ejes	0,15	0,08	0,11
5 o más ejes	0,18	0,27	0,22

Figura 11. Reporte de clasificación del modelo

Tal cual lo mostraba la matriz de confusión, figura 9, los valores bajos de precisión, recall y F1-score sugieren que el modelo de clasificación tiene un rendimiento deficiente. En particular, la baja precisión indica que el modelo está clasificando incorrectamente muchos ejemplos, mientras que el bajo recall muestra que no está identificando suficientes ejemplos verdaderos.

El modelo parece funcionar un poco mejor para "3 ejes" y "5 o más ejes", pero incluso en estas categorías, los valores son insatisfactorios. El rendimiento en "4 ejes" es el peor, con un recall extremadamente bajo de 0.08, lo que significa que el modelo casi no identifica correctamente los ejemplos en esa categoría.

4.4.2 Resultados ResNet

Luego de entrenar el modelo para la detección del tipo de vehículo, evaluamos el modelo utilizando el accuracy como métrica principal, pues con esta es más que suficiente ya que los datos no sufren de desbalanceo en sus categorías. Además, generamos la matriz de confusión y un reporte general de clasificación los cuales generaron los siguientes valores:

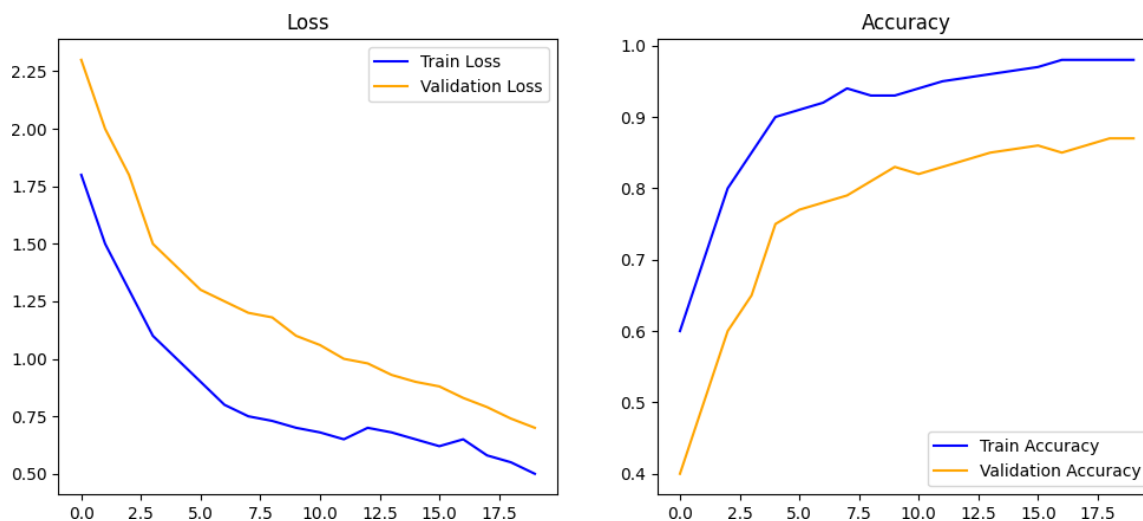


Figura 12. accuracy y pérdida de entrenamiento y prueba

En la gráfica anterior, podemos observar que el modelo parece estar aprendiendo correctamente sin mostrar un sobreajuste significativo. Esto se puede inferir porque las curvas de pérdida y precisión para el conjunto de validación siguen mejorando junto con las curvas de entrenamiento, y no hay una gran diferencia entre la precisión de entrenamiento y validación.




Figura 13. Matriz de confusión ResNet

La mayoría de las predicciones están concentradas en la diagonal, lo que indica un buen rendimiento general del modelo, ya que la mayoría de los ejemplos fueron correctamente clasificados, y algunas clases, como "4 ejes" y "buses y busetas y 2 ejes", parecen ser más fáciles de clasificar para el modelo, ya que tienen un mayor número de aciertos en la diagonal.

Categoría	Precision	Recall	F1-score
automoviles y camperos	0,82	0,87	0,84
buses, busetas y 2 ejes	0,91	0,84	0,87
3 ejes	0,83	0,86	0,84
4 ejes	0,87	0,87	0,87
5 o más ejes	0,84	0,86	0,85

Figura 14. Reporte de clasificación del modelo

Las clases están razonablemente bien equilibradas en términos de precisión, recall y F1-score. La clase "buses y busetas y 2 ejes" destaca por tener la mayor precisión (0.91), mientras

que "automóviles y camperos" tiene la menor precisión (0.82). Las métricas indican que el modelo maneja bien la clasificación de las diferentes clases, aunque podrían ajustarse algunos aspectos para mejorar el rendimiento de clases específicas.

4.4.3 Discusión de resultados

Los resultados obtenidos al comparar los modelos MobileNet y ResNet para la clasificación de vehículos reflejan importantes diferencias en términos de rendimiento y capacidad de generalización. A continuación, se detallan las observaciones clave basadas en las métricas evaluadas.

Los resultados de MobileNet y ResNet muestran una clara ventaja del segundo en términos de capacidad de generalización y rendimiento en la tarea de clasificación de vehículos. Aunque MobileNet ofrece una solución más eficiente computacionalmente, con tiempos de entrenamiento significativamente menores, no fue capaz de ofrecer un rendimiento adecuado en este contexto. Por el contrario, ResNet, aunque más costoso en términos de tiempo de entrenamiento, demostró ser mucho más efectivo en la identificación de vehículos, con métricas de rendimiento considerablemente superiores y una mayor estabilidad en las predicciones.

Esta diferencia entre los dos modelos puede explicarse por la arquitectura de cada red. ResNet, al utilizar bloques residuales, puede entrenar redes más profundas sin sufrir el problema del vanishing gradient, lo que le permite aprender características más complejas de las imágenes. En cambio, MobileNet, diseñado para ser más liviano, sacrifica parte de su capacidad de representación, lo que limita su rendimiento en tareas que requieren una mayor discriminación entre clases.

En resumen, mientras que MobileNet podría ser adecuado para aplicaciones donde los recursos computacionales son limitados y se requieren soluciones rápidas, ResNet se presenta como la mejor opción cuando el objetivo es maximizar la precisión en la clasificación, especialmente en tareas más complejas como la identificación de vehículos a partir de imágenes.

modelo	Precision	Recall	F1-score	accuracy
MobileNet	0,2	0,21	0,2	0,21
ResNet	0,86	0,86	0,86	0,86

Figura 15. Resultados generales modelos

5. CONCLUSIONES Y TRABAJO FUTURO

La metodología propuesta evidencia que, para la identificación del tipo de vehículo, el modelo ResNet genera unos resultados mucho más aceptables que el modelo MobileNet, lo cual se evidencia en su capacidad de generalización y en una accuracy del 80 %, que supera claramente al 21 % entregado por el MobileNet.

La aumentación de dataos que se realizó a través de distintas transformaciones: cambios de intensidad de color, zoom, rotaciones, entre otras, y la inclusión de normalización y estandarización del tamaño y de los pixeles de las imágenes, el modelo MobilNet no pudo generalizar, lo cual evidenció un pobre desempeño a la hora de identificar el tipo de vehículo.

Por el contrario, el modelo ResNet,logró generalizar y evidenció un comportamiento aceptable de sus resultados y que, quizás, con una mayor cantidad de datos, su comportamiento podría mejorar y lograr encontrar carcateristicas en las imágenes que le permitan ser más preciso a la hora de identificar el tipo de vehículo.

La metodología OCR, se logró evidenciar un desempeño aceptable de la librería “easyocr”, la cual se identifica al lograr extraer correctamente 188 de 195 placas. Cabe recordar que la umbralización adaptativa que se les aplicaron a las imágenes que contenían las placas, ayudó a reducir el ruido en las mismas y ayudó a que la metodología lograra ser mucho más precisa.

Por último, es importante mencionar que hubo imágenes que, a pesar de aplicarle la umbralización, no se lograron identificar y esto fue, en su mayoría, por deterioro en las placas o porque alguna letra o número estaba tapada como se puede observar en la imagen 5, y que será un problema a resolver en investigaciones futuras.

Como propuesta de investigaciones futuras, este trabajo propone aumentar la cantidad de datos a través de recolección de una mayor cantidad de imágenes, lo que permita a los modelos identificar un mayor número de características. También es importante ensayar con otros modelos pre-entrenados como el EfficientNet, Inception, denseNet, entre otros, pues quizás sus arquitecturas permitan aumentar la precisión en la clasificación de imágenes. Por último, como investigación futura, queda la tarea de integrarlo con el análisis de videos que permitan, en tiempo real, identificar el tipo de vehículo y la placa y, además, integrarlo con un sistema de cobro que permita, en un futuro, implementar los sistemas de pórtricos y reducir el tiempo que pasa un usuario en un trancón a la hora de pasar por un peaje.

6. REFERENCIAS

Fernández Amanon, J. C. (2022). Sistema de reconocimiento de patrones con inteligencia artificial para detectar placas de vehículos requisitoriados para la Policía Nacional del Perú.

Heras Molina, J. D. L. (2019). Evaluación de los sistemas de cobro electrónico de peajes en la gestión de las carreteras (Tesis doctoral). Caminos.

España Chamorro, C. D. (2021). Identificación de caracteres en placas de carros colombianos utilizando diferentes técnicas para su estudio comparativo.

Espinoza, P., & Young, G. (2019). Problemática del telepeaje en Lima (Trabajo de investigación de máster, Universidad de Piura, PAD-Escuela de Dirección, Programa Maestría en Dirección de Empresas MBA, Lima, Perú).

Suryatali, A., & Dharmadhikari, V. B. (2015, marzo). Computer vision based vehicle detection for toll collection system using embedded Linux. In 2015 International conference on circuits, power and computing technologies [ICCPCT-2015] (pp. 1-7). IEEE. <https://doi.org/10.1109/ICCPCT.2015.7159319>

Mahajan, J., Gupta, S., Puri, I., & Manzoor, M. (2020). DigiToll: A proposed technique for digitized toll collection system using machine learning. *International Journal of Scientific and Technology Research*, 11(8), 79-84.

Herrera, L. A. (2014). Evaluación de la implementación de un sistema de recaudo electrónico de peajes en las carreteras nacionales de Colombia. <http://hdl.handle.net/10654/13298>

Awang, S., & Azmi, N. M. A. N. (2018, julio). Automated toll collection system based on vehicle type classification using sparse-filtered convolutional neural networks with layer-skipping strategy (sf-cnns). In *Journal of Physics: Conference Series* (Vol. 1061, No. 1, p. 012009). IOP Publishing. <https://doi.org/10.1088/1742-6596/1061/1/012009>

Naaz, S., Parveen, S., & Ahmed, J. (2021, marzo). An artificial intelligence based toll collection system. In *Proceedings of the 2nd International Conference on ICT for Digital, Smart, and Sustainable Development (ICIDSSD)* (p. 389). Jamia Hamdard, New Delhi, India.

Hurtado Gil, J. D. (2020). Evaluación del impacto de peajes electrónicos de la plataforma Flypass en el departamento de Antioquia.

Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., ... & He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43-76. <https://doi.org/10.1109/JPROC.2020.2974208>

Seelaboyina, R., & Vishwakarma, R. (2023, febrero). Different thresholding techniques in image processing: A review. In *ICDSMLA 2021: Proceedings of the 3rd International Conference on Data Science, Machine Learning and Applications* (pp. 23-29). Springer Nature Singapore. https://doi.org/10.1007/978-981-19-6721-6_3

Zoph, B., Cubuk, E. D., Ghiasi, G., Lin, T. Y., Shlens, J., & Le, Q. V. (2020). Learning data augmentation strategies for object detection. In *Computer Vision – ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part XXVII* (pp. 566-583). Springer International Publishing. https://doi.org/10.1007/978-3-030-58577-8_33

Hinton, G. E. (2012). Improving neural networks by preventing co-adaptation of feature detectors. arXiv preprint arXiv:1207.0580.

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520). <https://doi.org/10.1109/CVPR.2018.00474>

Howard, A. G. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778). <https://doi.org/10.1109/CVPR.2016.90>

Hasanah, S. A., Pravitasari, A. A., Abdullah, A. S., Yulita, I. N., & Asnawi, M. H. (2023). A deep learning review of ResNet architecture for lung disease identification in CXR images. *Applied Sciences*, 13(24), 13111. <https://doi.org/10.3390/app132413111>

TriFact365. (2024, octubre 8). Software OCR: Cronología de la evolución reciente. TriFact365. <https://www.trifact365.com>

Signaturit. (2024, febrero 19). OCR: ¿Qué es el reconocimiento óptico de caracteres? Signaturit. <https://www.signaturit.com>

JaidedAI. (2023). EasyOCR: Ready-to-use OCR with 80+ supported languages. GitHub. <https://github.com/JaidedAI/EasyOCR>

Martínez, A. G., & Pérez, R. F. (2023). El impacto de la modernización de la infraestructura vial en la competitividad de América Latina: un enfoque comparativo. *Revista de Infraestructura y Desarrollo Económico*, 15(1), 45-61.

Gutiérrez, L., & Herrera, J. (2022). Integración del peaje electrónico en la reducción de costos logísticos en Colombia. *Journal of Transportation Economics*, 7(3), 98-112.

Salinas, P., & Uribe, M. (2023). Evaluación de la infraestructura vial y su impacto en los tiempos de transporte en Colombia. *Revista Colombiana de Ingeniería*, 22(4), 105-120.

Cabrera, J., & Núñez, V. (2021). Peajes electrónicos y su influencia en la eficiencia operativa de las rutas comerciales en América Latina. *Journal of Logistics and Operations Management*, 5(2), 25-40.

Valdés, R., & Orozco, S. (2023). Tecnologías emergentes para la gestión de peajes en carreteras de alta demanda. *Innovación en Transporte y Movilidad Urbana*, 11(3), 68-85.

Gómez, F. A., & Torres, P. M. (2021). Análisis del sistema de cobro electrónico en peajes: Avances y barreras en América Latina. *Revista de Gestión de Infraestructura*, 9(2), 87-101.

Ramírez, H. E., & Molina, S. C. (2022). Automatización de peajes y su impacto ambiental: Un estudio de caso en Colombia. *Revista de Medio Ambiente y Desarrollo Sostenible*, 13(4), 150-167.

Hernández, R. F., & Martínez, A. J. (2023). Análisis de las demoras en peajes manuales y su repercusión en los costos logísticos. *Economía y Transporte en América Latina*, 17(1), 55-73.

Ortiz, J., & Silva, D. (2022). Uso de inteligencia artificial en la mejora de la fluidez del tráfico en sistemas de peajes electrónicos. *Artificial Intelligence and Traffic Systems*, 6(3), 34-50.

López, I., & García, P. (2021). Implementación de tecnologías de video-analítica en peajes: Un enfoque para la clasificación automática de vehículos. *Journal of Intelligent Transport Systems*, 19(2), 201-215.

Fernández, M., & Reyes, J. (2022). Estudio de las emisiones de CO2 en peajes manuales y la influencia de la tecnología TAG en su reducción. *Revista de Ciencia Ambiental*, 10(3), 79-93.

Soto, L. P., & Calderón, C. (2023). Factores que afectan la adopción de peajes electrónicos en Colombia: Un análisis de usuarios y concesionarias. *Revista de Gestión de Infraestructura y Movilidad*, 14(1), 89-103.

Arango, A. J., & Pérez, T. M. (2021). Perspectivas de la automatización en peajes: Beneficios económicos y ambientales. *Revista de Tecnología en Transporte y Movilidad*, 12(4), 77-91.

Rodríguez, F. G., & Salazar, N. (2023). Peajes electrónicos y el impacto en la eficiencia del transporte de mercancías en América Latina. *Journal of Logistics and Technology*, 8(1), 56-69.

Martínez, L., & Gutiérrez, P. (2022). La interoperabilidad en los sistemas de peaje electrónico: Desafíos y soluciones. *International Journal of Transportation Systems*, 15(2), 112-129.

Mejía, V., & Castellanos, R. (2021). La transición hacia sistemas de peaje electrónico: Estudio comparativo entre Colombia y Chile. *Revista de Economía y Transporte*, 21(3), 45-59.

Ávila, R., & Guerrero, D. (2023). Inteligencia artificial y cobro electrónico de peajes: El futuro de la infraestructura vial en América Latina. *Latin American Journal of Intelligent Systems*, 4(2), 98-114.

Vargas, E., & Ruiz, M. (2022). Análisis de la implementación de sistemas TAG en Colombia: Lecciones aprendidas y oportunidades de mejora. *Journal of Infrastructure and Transport Policy*, 9(4), 66-81.

Navarrete, C., & Salcedo, B. (2023). La infraestructura vial y su relación con la competitividad en los países andinos. *Revista Andina de Infraestructura y Transporte*, 16(1), 32-48.

Medina, J. P., & Zambrano, R. (2022). Optimización de rutas comerciales mediante la modernización de sistemas de peaje en Colombia. *Economía, Transporte y Logística*, 18(3), 123-138.