

# Detección de Vehículos en el Tráfico Urbano: Una Revisión Sistemática de la Literatura

## Vehicle Detection in Urban Traffic: A Systematic Literature Review

**Luz Elena Torres Talaverano**

<https://orcid.org/0000-0001-6465-0430>

[luzelena.torres@unmsm.edu.pe](mailto:luzelena.torres@unmsm.edu.pe)

Universidad Nacional Mayor de San Marcos,  
Facultad de Ingeniería de Sistemas e  
Informática, Lima, Perú

**Ciro Rodriguez Rodriguez**

<https://orcid.org/0000-0003-2112-1349>

[crodriguezro@unmsm.edu.pe](mailto:crodriguezro@unmsm.edu.pe)

Universidad Nacional Mayor de San Marcos,  
Facultad de Ingeniería de Sistemas e  
Informática, Lima, Perú

**Pedro Martin Lezama Gonzales**

<https://orcid.org/0000-0001-9693-0138>

[plezama@unmsm.edu.pe](mailto:plezama@unmsm.edu.pe)

Universidad Nacional Mayor de San Marcos,  
Facultad de Ingeniería de Sistemas e  
Informática, Lima, Perú

**Ivan Carlo Petrlik Azabache**

<https://orcid.org/0000-0002-1201-2143>

[ipetrlika@unmsm.edu.pe](mailto:ipetrlika@unmsm.edu.pe)

Universidad Nacional Mayor de San Marcos,  
Facultad de Ingeniería de Sistemas e  
Informática, Lima, Perú

RECIBIDO: 15/11/2024 - ACEPTADO: 09/11/2024 - PUBLICADO: 31/12/2024

### RESUMEN

La seguridad vial es un tema de gran relevancia debido a la alta incidencia de accidentes de tráfico y sus consecuencias. El objetivo principal de este artículo de revisión es proporcionar una visión integral y actualizada de los avances en la detección de vehículos en el tráfico urbano respecto a los algoritmos, el procesamiento de datos y las métricas de validación utilizadas en este campo. Se realizaron búsquedas exhaustivas en Google Académico, PubMed y IEEE Xplore, en las que se escogieron estudios publicados entre los años 2019 y 2024. Los resultados revelaron 34 investigaciones seleccionadas, siendo Google Académico como el motor de búsqueda con mayor cantidad de estudios, representando el 47% del total. El año 2022 registró la mayor tendencia en publicaciones, con un total de 5 estudios. Los algoritmos más utilizados fueron YOLOv5, Faster R-CNN, representando cada uno, 6 investigaciones. Además, se observó el uso de conjuntos de datos propios y técnicas avanzadas para el procesamiento en entornos complejos de tráfico urbano. La métrica de validación más utilizada fue la precisión, presente en 16 investigaciones. En conclusión, esta revisión sistemática tiene un impacto significativo y establece una base sólida para futuras investigaciones en el ámbito de la seguridad vial, contribuyendo de manera efectiva al desarrollo de este campo.

**Palabras claves:** Detección de vehículos, tráfico urbano, revisión sistemática de literatura, inteligencia artificial, visión artificial.

## ABSTRACT

Road safety is a highly relevant topic due to the high incidence of traffic accidents and their consequences. The main objective of this review article is to provide a comprehensive and updated overview of the advances in vehicle detection in urban traffic regarding the algorithms, data processing, and validation metrics used in this field. Exhaustive searches were carried out in Google Scholar, PubMed, and IEEE Xplore, in which studies published between 2019 and 2024 were chosen. The results revealed 34 selected investigations, with Google Scholar being the search engine with the largest number of studies, representing 47% of the total. The year 2022 registered the highest trend in publications, with a total of 5 studies. The most used algorithms were YOLOv5, Faster R-CNN, each representing 6 investigations. In addition, the use of proprietary data sets and advanced techniques for processing in complex urban traffic environments was observed. The most commonly used validation metric was accuracy, present in 16 investigations. In conclusion, this systematic review has a significant impact and establishes a solid foundation for future research in the field of road safety, effectively contributing to the development of this field.

**Keywords:** Vehicle detection, urban traffic, systematic literature review, artificial intelligence, computer vision.

## I. INTRODUCCIÓN

La seguridad vial representa una problemática global de salud pública la cual requiere de una atención inmediata. Según Ahmed et al. (2023), anualmente, cerca de 1.35 millones de personas fallecen y tienen discapacidades, y el 94% de las muertes se relacionan con accidentes viales de aquellos países con ingresos bajos y medianos. Adicionalmente, se indica que, por el año 2030, los fallecimientos viales se convertirán en la séptima causa global, lo que hace necesario adoptar nuevas medidas preventivas con la finalidad de reducir los choques y generar un entorno vial seguro. Ameratunga et al. (2006) destacan los accidentes de tráfico afectan especialmente a los usuarios vulnerables como los motociclistas y peatones. En concordancia con Wegman (2017) señala que, para enfrentar esta problemática, las Naciones Unidas han creado varias iniciativas como la “Década de Acción para la Seguridad Vial 2011-2020”, con la finalidad de reducir las tasas de accidentes mortales, sin embargo, a pesar de ello, se espera que las muertes por accidentes de tráfico aumenten a casi 2 millones por año en las próximas décadas, lo que demuestra que las medidas son insuficientes. Por otra parte, Goniewicz et al. (2016) indican que, a nivel mundial las principales causas de los accidentes de tráfico lo conforman el exceso de velocidad, la conducción bajo los efectos del alcohol y la falta de una infraestructura adecuada. Por ende, estos factores destacan la importancia de disponer un enfoque integral que combine esfuerzos de políticas públicas, infraestructura mejorada y tecnologías emergentes para disminuir tanto las tasas de accidentes fatales como las lesiones graves. De forma similar, Sleet y Branche (2004) enfatizan que más de 1 millón de personas fallecieron anualmente en las carreteras del mundo, y que aquellas muertes podrían evitarse mediante la implementación de estrategias preventivas que sean eficaces y programas de concienciación.

Además de las vidas perdidas, los accidentes de tráfico conllevan una carga financiera significativa en la sociedad. A pesar de que la población mundial aumentó en 1 mil millones de personas entre el año 2010 hasta el 2021, y que tanto el parque automotor como la infraestructura vial se expandieron, las muertes por accidentes de tráfico no experimentaron una reducción, manteniéndose en 1.25 millones en el año 2021. Si bien se han logrado algunos avances en la seguridad vial, aún se consideran insuficientes para alcanzar los objetivos establecidos en el Decenio de Acción para la Seguridad Vial 2021-2030 de las Naciones Unidas (World Health Organization, 2023). De acuerdo con Gorea (2016), describe que el impacto económico de estos accidentes es considerable, tanto para las víctimas y sus familias como para los sistemas de salud y las economías nacionales. Adicionalmente, el desafío de la seguridad vial también tiene gran relevancia en América Latina y el Caribe. Según Martínez et al. (2018) mencionan que, en estas localidades, la tasa de mortalidad por accidentes de tráfico es el doble en los países de ingresos altos. En el sudeste asiático, un estudio realizado por Klinjun et al. (2021) identifican que los factores influyentes en la incidencia y gravedad de los accidentes de tráfico en el sur de Tailandia son el error humano, las condiciones de los vehículos y el entorno vial. Asimismo, Kucherwar et al. (2012), al analizar respecto sobre los accidentes de tráfico en Aurangabad en la India, mencionan que mejorar la concienciación pública sobre la seguridad vial es esencial para minimizar las tasas de mortalidad por accidentes. Por lo que es importante adoptar un enfoque multidimensional en la prevención de accidentes que considere tanto los factores humanos como los tecnológicos. A nivel nacional, Quistberg et al. (2014) analizan las deficiencias en la gestión de la seguridad vial en Lima, donde describen la falta de un sistema de estadísticas fiable y la ineficacia del Consejo Nacional de Seguridad Vial, donde estas limitaciones

se ven agravadas por la falta de responsabilidad de las autoridades en la implementación del Plan Nacional de Seguridad Vial. Finalmente, Berhanu et al. (2023) realizan la comparación de diversas técnicas de predicción de accidentes y congestión vial, dando como resultado que el uso de tecnologías avanzadas como los algoritmos de Inteligencia Artificial es fundamental para mejorar la seguridad vial y reducir la congestión en áreas urbanas.

A partir de todo lo mencionado, se observa una falta de eficiencia, fluidez y calidad de vida debido al problema del tráfico vehicular y la falta de seguridad vial en las zonas urbanas. Por lo tanto, la detección de vehículos en el tráfico urbano es un área de investigación relevante, con un gran potencial para abordar estos desafíos. Dado al crecimiento de la tecnología y la necesidad urgente de soluciones, es fundamental realizar una revisión sistemática de la literatura existente que explore los algoritmos utilizados, los métodos de procesamiento de datos y las métricas de validación utilizados en este campo.

### A. Investigación Previa

En este estudio se ha explorado el uso de diversas técnicas para la aplicación de detección de vehículos, las cuales han propuesto enfoques basados en visión artificial, algoritmos de aprendizaje profundo (deep learning), inteligencia artificial (IA) y videografía, entre otros.

En la investigación de Cueva y Muñoz (2017) desarrollaron un algoritmo basado en visión artificial para la detección y monitoreo del tráfico vehicular utilizando la sustracción de fondo como método eficiente de detección y lograron realizar el conteo vehicular reduciendo costos mediante el uso de software libre. Por otro lado, Peña (2017) propuso un algoritmo de conteo vehicular en tiempo real mediante el uso de la visión artificial. Por lo que aplicaron técnicas de segmentación y detección de objetos en secuencias de video, obteniendo una alta precisión en la detección y conteo de vehículos. Asimismo, Pérez (2019) implementó un sistema de visión artificial para el análisis del tráfico vehicular, evaluando algoritmos de detección y seguimiento de objetos. Los resultados demostraron la viabilidad del sistema y su capacidad para resolver desafíos en tiempo real. Además, Mandal (2019) presentó un sistema de monitoreo automático del tráfico basado en algoritmos de aprendizaje profundo, como Máscara R-CNN, YOLO y R-CNN optimizado. A pesar de enfrentar desafíos tales como la calidad de imagen y efectos de deslumbramiento, los algoritmos demostraron ser efectivos en la detección de

colas de tráfico. De forma similar, Pan (2021) aplicó la inteligencia artificial y videografía para detectar y rastrear automáticamente diferentes elementos en entornos urbanos y autopistas. Para ello, aplicaron técnicas de detección de objetos utilizando YOLO v5 y rastreo de ubicaciones mediante Deep Sorting, obteniendo una alta precisión en la detección y mediciones precisas de flujos, densidades y velocidades de tráfico. Finalmente, en el estudio de Coanqui et al. (2022), se comparó la precisión de dos métodos tecnológicos en la obtención de datos de aforo vehicular; uno basado en la inteligencia artificial utilizando redes neuronales convoluciones y otro, en visión artificial. En este caso, realizaron un conteo manual en campo utilizando una videografía real de flujo vehicular que consideraba seis clases de vehículos, resultando un 95.6% de precisión en el conteo y clasificación de microbuses con inteligencia artificial, mientras que el método de visión artificial alcanzó un 97.8% de precisión.

### B. Planificación de la Revisión

El objetivo del estudio es desarrollar una revisión sistemática a la literatura con respecto a la Detección de Vehículos en el Tráfico Urbano, de las cuales se formuló preguntas técnicas con la finalidad de guiar la investigación en el alineamiento del tema de estudio, las cuales se visualiza en la Tabla I.

**Tabla I**

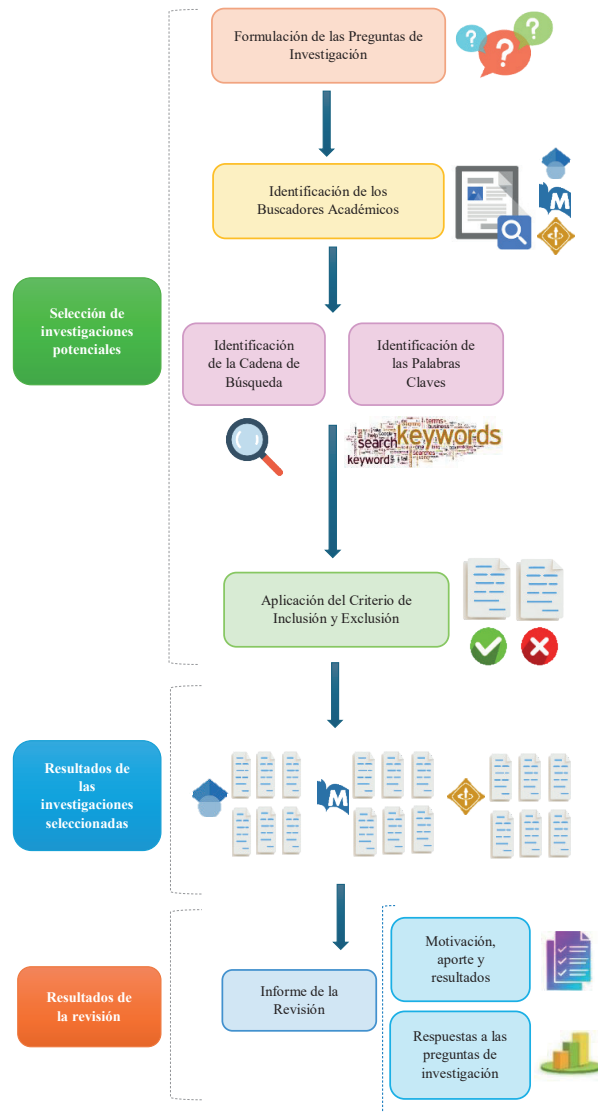
*Formulación de las preguntas de la investigación*

| ID | Pregunta de Investigación                                                               |
|----|-----------------------------------------------------------------------------------------|
| P1 | ¿Qué algoritmos se usan para la detección de vehículos?                                 |
| P2 | ¿Cómo se realiza el procesamiento del conjunto de datos para la detección de vehículos? |
| P3 | ¿Qué métricas de validación se utilizan en la detección de vehículos?                   |

## II. METODOLOGÍA

La revisión sistemática propuesta sigue el procedimiento, según Kitchenham et al. (2009), el cual constituye en la formulación de tres preguntas centrales relacionados al tema, las cuales orientan el proceso de selección. Luego, se identifica los buscadores académicos para encontrar las posibles investigaciones usando la cadena de búsqueda y palabras claves. Después, se aplica el criterio de inclusión y exclusión para seleccionar los estudios de cada fuente. Seguidamente, se procede a realizar un informe de revisión donde se especifica la motivación, aporte y resultados de cada estudio; y respuestas a las preguntas de investigación establecidas. A continuación, según la Figura I, se presenta

**Figura I**  
*Metodología de la revisión sistemática de la literatura*



Fuente: Elaboración Propia

la metodología de la presente revisión sistemática a la literatura.

### III. DESARROLLO DE LA METODOLOGÍA

#### A. Selección de investigaciones potenciales

En primer lugar, se procede a realizar las búsquedas en tres fuentes académicas las cuales son Google Académico, PubMed e IEEE Xplore mencionadas en la Tabla II. Estas fuentes ofrecen una amplia variedad de publicaciones académicas y científicas, lo que permite acceder a investigaciones importantes del tema.

**Tabla II**  
*Identificación de los Buscadores Académicos*

| Fuente           | Enlace (URL)                                                                                                                                       |
|------------------|----------------------------------------------------------------------------------------------------------------------------------------------------|
| Google Académico | <a href="https://scholar.google.com/">https://scholar.google.com/</a><br>(fecha de acceso: 7 de setiembre del 2024)                                |
| PubMed           | <a href="https://pubmed.ncbi.nlm.nih.gov/">https://pubmed.ncbi.nlm.nih.gov/</a><br>(fecha de acceso: 15 de setiembre del 2024)                     |
| IEEE Xplore      | <a href="http://ieeexplore.ieee.org/Xplore/home.jsp">http://ieeexplore.ieee.org/Xplore/home.jsp</a><br>(fecha de acceso: 10 de setiembre del 2024) |

De acuerdo con la Tabla III se visualiza que este artículo de revisión utiliza cadena de búsqueda de acuerdo a cada fuente con la finalidad de encontrar

investigaciones relevantes en revistas o motores de búsquedas pertinentes. Dado que la búsqueda se realizó a inicios de setiembre del año 2024, se asume que se consideraron artículos más recientes o anteriores que pueden ser útiles para las preguntas centrales de la investigación. Además, la consulta se limitó a busca específicamente en los títulos de los artículos, resúmenes y palabras claves descritos en la Tabla IV para garantizar la relevancia de los estudios seleccionados.

Una vez obtenidos los resultados de la búsqueda, se aplica el proceso de inclusión y selección mostrados en la Tabla V para determinar qué artículos son más destacados para la revisión sistemática. Para ello, se tuvieron en cuenta aspectos como el tipo de documento, año de investigaciones, idioma, así como el procesamiento del conjunto de datos y métricas de validación.

**Tabla III**

*Identificación de la Cadena de Búsqueda*

| Fuente           | Cadena de Búsqueda                                                                                                                                                                                                                                                                                                               |
|------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Google Académico | Intervalo específico: 2019-2024, Ordenar por relevancia, Cualquier idioma, Cualquier tipo, Incluir citas, Buscar: ("detection" OR "vehicle detection" OR "vehicle classification") AND ("vehicle traffic" OR "urban traffic") AND (("deep Learning" OR "machine learning") OR ("artificial intelligence" OR "computer vision")). |
| PubMed           | Resultados por año: 2019 – 2024, Disponibilidad de Texto: Texto completo gratuito, Buscar: ("detection" OR "vehicle detection") OR ("vehicle traffic" OR "urban traffic") AND (("deep Learning" OR "machine learning") OR ("artificial intelligence" OR "computer vision")), Fecha de Publicación: 5 años.                       |
| IEEE Xplore      | Mostrar: Solo acceso abierto, Año: Rango (2019-2024), Buscar: ("vehicle detection" OR "vehicle classification") AND ("vehicle traffic" OR "urban traffic") AND (("deep Learning" OR "machine learning") OR ("artificial intelligence" OR "computer vision")).                                                                    |

**Tabla IV**

*Identificación de las Palabras Claves*

| Fuente           | Palabras Claves                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                               |
|------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Google Académico | ACmix, Accident severity classification, Artificial intelligence, Autonomous vehicle, Autonomous vehicles, Background subtraction, Cascade classifiers, CCTV, Computer vision, Convolutional neural networks, Convolution neural network, Convolution neural network, Haar cascade algorithm, Deep learning, Deep SORT framework, DeepSORT tracking, Default box, Detection and classification system, Flip-Mosaic algorithm, FCW system, Feature concatenation, Haar cascade, Heterogeneous traffic flow, Image processing, Image processing, Shadow removal, Intelligent transportation system, Machine learning, Modified residual block, Object detection, Object tracking, OpenCV, Pavement maintenance, Postcollision vehicle fire detection, Python, Real-time, Remote sensing, Remote sensing data, Road crack, Road defect detection, Road inspection, RFLA, Smart cities, Super-resolution, Thermal classification, Traffic dataset collection, Traffic monitoring, Traffic surveillance, Transportation, Unmanned aerial vehicle, Vehicle classification, Vehicle counting, Vehicle detection, Vehicle detection, ACmix, RFLA, YOLOv7, Vehicle detection, feature concatenation, Vehicle detection, YOLO v5, Vehicle detection, vehicle speed estimation, Vehicle movement, Vehicle speed, Vision-based ADAS, YOLO v4, YOLOv7, You Only Look Once. |
| PubMed           | Artificial neural network (ANN), Benchmark, Blind spot collision detection for buses, Blind spot vehicle detection, Collision detection system, Computer vision, Deep CNN architecture, Deep learning, Deep learning model, Deep learning, Game-day traffic, Geospatial data, Hazard scenarios, Heavy vehicle safety, Histogram of gradient (HoG), Image detection, Intelligent transportation systems, Intelligent traffic light, Intersection turning, IoT, Leave-one-subject-out (LOSO), Monitoring visual data, Multiple deep learning, Non-motorized transportation, PSPNet algorithm, Road safety, Seed points spreading, Street view images, Traffic prediction, Traffic volume, Vehicular traffic flow classification, Vehicular traffic flow congestion, Vehicular traffic flow detection, Video classification.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                     |
| IEEE Xplore      | Attention mechanism, Close-circuit television, Computer vision, Convolutional neural networks, Deep learning, eXtreme gradient boost algorithm, EfficientDet, Feature fusion, Fiber Bragg gratings, Fuzzy neural network, Intelligent transportation system, Intelligent vehicle system, Internet of Things, Machine learning, Mask RCNN, Motion features, Moving object tracking, Object classification, Object detection, Region-based convolutional neural network (R-CNN), Static appearance features, Traffic-monitoring system, Vehicle classification, Vehicle detection, Vehicle model identification, Video-based, YOLO.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                             |

**Tabla V**

*Criterio de Inclusión y Exclusión*

| Criterio de Inclusión                                                                                                                                                                                                                                                                                                                                                                                                                                    | Criterio de Exclusión                                                                                                                                                                               |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <ul style="list-style-type: none"> <li>Documentos que describan los algoritmos, métodos/conjunto de datos/ técnicas y/o métricas de validación para la detección de vehículos.</li> <li>Documentos de tipo artículos de investigación o revistas.</li> <li>Investigaciones que se encuentran en el periodo 2019 al 2024.</li> <li>Lenguaje: Todos los idiomas.</li> <li>Área de Investigación: Inteligencia Artificial y/o Visión Artificial.</li> </ul> | <ul style="list-style-type: none"> <li>Revisiones anteriores del periodo 2019.</li> <li>Documentos de tipo artículos de revisión o libros.</li> <li>Revisiones que no tengan DOI o ISSN.</li> </ul> |

## B. Resultados de las investigaciones seleccionadas

Se realiza la selección de los resultados obtenidos en la búsqueda, empleando los criterios de inclusión y exclusión. Al realizar este procedimiento, la mayoría de los artículos fueron descartados debido a la falta de relación con el tema de investigación, tipo de documento, así como la falta de conexión con las áreas de investigación obteniendo los resultados que se visualizan en la Figura II.


Se observa en la Figura II, los resultados de las búsquedas muestran un total de 1345 trabajos, entre artículos y revistas, de las cuales se seleccionaron 34 que cumplen con los criterios establecidos

con anterioridad, excluyendo un total de 1317 de trabajos que no están acorde con lo establecido a los criterios, mencionados en la Tabla V.

Seguidamente, en la Tabla VI se visualiza la cantidad de documentos que fueron potencialmente elegibles y documentos seleccionados clasificado por la fuente de procedencia tales como Google Académico, PubMed e IEEE Xplore.

Se observa en la Tabla VI, un total de 18 investigaciones relevantes a través de Google Académico para esta revisión, Además, en el año 2022 fue el que presentó la mayor cantidad de investigaciones en PubMed, como se muestra en la Figura III.

**Figura II**  
Proceso de revisión sistemática de la literatura



Fuente: Elaboración Propia

**Tabla VI**  
Estudios potencialmente elegibles y seleccionados por fuente

| Fuente           | Estudios potencialmente elegibles | Estudios seleccionados |
|------------------|-----------------------------------|------------------------|
| Google Académico | 1320                              | 16                     |
| PubMed           | 14                                | 9                      |
| IEEE Xplore      | 11                                | 9                      |

Fuente: Elaboración Propia

En la Figura IV se observa un mayor porcentaje de publicaciones seleccionadas en Google Académico (47%), lo cual representa una cerca de la mitad de las investigaciones en el campo de la detección de vehículos, además de sus recientes avances y contribuciones.

A continuación, se visualiza en la Tabla VII, los trabajos resultantes del proceso de selección para la investigación sobre la detección de vehículos en el tráfico urbano.

## C. Resultados de la revisión

### 1. Informe de la Revisión

En la Tabla VIII se presenta un análisis detallado de cada investigación, destacando la motivación, el aporte y los resultados obtenidos.


En la Tabla IX se describe las respuestas de acuerdo a cada pregunta formulada presente en la Tabla I.

En la Figura V se visualizan los algoritmos aplicados en las investigaciones para la detección de vehículos, en las cuales se destacan YOLOv5 y Faster R-CNN, cada uno aplicados en 6 estudios, lo que evidencia una preferencia debido a su efectividad en la detección de objetos.

Por otra parte, en la Figura VI se presentan las métricas de validación utilizados en las investigaciones para la detección de vehículos, en donde la precisión es la más común, ya que fue empleada en 16 estudios, lo que refleja un enfoque en reducir los falsos positivos y garantizar que las predicciones del algoritmo sean confiables.

**Figura III**


*Tendencias de las publicaciones seleccionadas sobre detección de vehículos durante los años 2019 al 2024.*



Fuente: Elaboración Propia

**Figura IV**

*Porcentaje de acuerdo con las publicaciones seleccionadas sobre detección de vehículos en los buscadores académicos.*



Fuente: Elaboración Propia

**Tabla VII***Lista de trabajos resultado del proceso de selección.*

| ID  | Título                                                                                                                                                                                                                      | Autor                       | Publicación   |
|-----|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------|---------------|
| A1  | Vehicle Detection in Urban Traffic Surveillance Images Based on Convolutional Neural Networks with Feature Concatenation.                                                                                                   | Zhang y Yang (2019)         | MDPI          |
| A2  | Fast Vehicle and Pedestrian Detection Using Improved Mask R-CNN.                                                                                                                                                            | Xu et al. (2020)            | Hindawi       |
| A3  | A Real-Time System for Vehicle Detection with Shadow Removal and Vehicle Classification Based on Vehicle Features at Urban Roads.                                                                                           | Atouf et al. (2020)         | IJPEDS        |
| A4  | Sistem Deteksi Kecepatan Kendaraan Menggunakan Metode Haar Cascade untuk Keamanan Berkendara.                                                                                                                               | Mustaqim et al. (2021)      | Edu ElektriKa |
| A5  | An Infrared Video Detection and Categorization System Based on Machine Learning.                                                                                                                                            | Švorc et al. (2021)         | NMW           |
| A6  | Multiscale Feature Learning Based on Enhanced Feature Pyramid for Vehicle Detection.                                                                                                                                        | Nguyen (2021)               | Hindawi       |
| A7  | Real-Time Vehicle Detection Based on Improved YOLOv5.                                                                                                                                                                       | Zhang et al. (2022)         | MDPI          |
| A8  | YOLOv5-Based Vehicle Detection Method for High-Resolution UAV Images.                                                                                                                                                       | Chen et al. (2022)          | Hindawi       |
| A9  | SRODNet: Object Detection Network Based on Super Resolution for Autonomous Vehicles.                                                                                                                                        | Musunuri et al. (2022)      | MDPI          |
| A10 | A Real-Time Computer Vision Based Approach to Detection and Classification of Traffic Incidents.                                                                                                                            | Ahmed et al. (2023)         | MDPI          |
| A11 | Heterogeneous Traffic Condition Dataset Collection for Creating Road Capacity Value.                                                                                                                                        | Nasution et al. (2023)      | MDPI          |
| A12 | A Secure Traffic Police Remote Sensing Approach via a Deep Learning-Based Low-Altitude Vehicle Speed Detector through UAVs in Smart Cities: Algorithm, Implementation and Evaluation.                                       | Moshayedi et al. (2023)     | MDPI          |
| A13 | YOLOv7-RAR for Urban Vehicle Detection.                                                                                                                                                                                     | Zhang et al. (2023)         | MDPI          |
| A14 | Efficacy Evaluation of You Only Learn One Representation (YOLOR) Algorithm in Detecting, Tracking, and Counting Vehicular Traffic in Real-World Scenarios, the Case of Morelia México: An Artificial Intelligence Approach. | Guzmán-Torres et al. (2024) | MDPI          |
| A15 | Real-Time Vehicle Detection with Advanced Machine Learning Algorithms.                                                                                                                                                      | Kazmi et al. (2024)         | JCBI          |
| A16 | Assessing the Performance of YOLOv5, YOLOv6, and YOLOv7 in Road Defect Detection and Classification: A Comparative Study.                                                                                                   | Yusof et al. (2024)         | BEEI          |
| A17 | Vehicular Traffic Congestion Classification by Visual Features and Deep Learning Approaches: A Comparison.                                                                                                                  | Impedovo et al. (2019)      | MDPI          |
| A18 | Lightweight PVIDNet: A Priority Vehicles Detection Network Model Based on Deep Learning for Intelligent Traffic Lights.                                                                                                     | Carvalho et al. (2020)      | MDPI          |
| A19 | Towards an End-to-End Framework of CCTV-Based Urban Traffic Volume Detection and Prediction.                                                                                                                                | Peppia et al. (2021)        | MDPI          |
| A20 | Blind-Spot Collision Detection System for Commercial Vehicles Using Multi Deep CNN Architecture.                                                                                                                            | Muzammel et al. (2022)      | MDPI          |
| A21 | An Effective Approach of Vehicle Detection Using Deep Learning.                                                                                                                                                             | Chen y Li (2022)            | Hindawi       |
| A22 | Vehicle Image Detection Method Using Deep Learning in UAV Video.                                                                                                                                                            | Wang (2022)                 | Hindawi       |
| A23 | Visual Recognition for Urban Traffic Data Retrieval and Analysis in Major Events Using Convolutional Neural Networks.                                                                                                       | Pi et al. (2022)            | Springer      |
| A24 | Identification and Improvement of Hazard Scenarios in Non-Motorized Transportation Using Multiple Deep Learning and Street View Images.                                                                                     | Wang et al. (2022)          | MDPI          |
| A25 | Vehicle Detection and Recognition Approach in Multi-Scale Traffic Monitoring System via Graph-Based Data Optimization.                                                                                                      | Wieczorek et al. (2023)     | MDPI          |
| A26 | Car Detection Using Cascade Classifier on Embedded Platform.                                                                                                                                                                | Zulkhairi et al. (2019)     | IEEE Access   |
| A27 | A Video-Based Method with Strong-Robustness for Vehicle Detection and Classification Based on Static Appearance Features and Motion Features.                                                                               | Chen y Hu (2021)            | IEEE Access   |
| A28 | Vehicle Detection through Instance Segmentation using Mask R-CNN for Intelligent Vehicle System.                                                                                                                            | Ojha et al. (2021)          | ICICCS        |
| A29 | Vehicle Detection and Tracking using YOLO and DeepSORT.                                                                                                                                                                     | Zuraimi y Zaman (2021)      | IEEE Access   |
| A30 | Vehicle Classification and Tracking Based on Deep Learning.                                                                                                                                                                 | Ahn y Lee (2022)            | JWE           |
| A31 | Intelligent Traffic-Monitoring System Based on YOLO and Convolutional Fuzzy Neural Networks.                                                                                                                                | Lin y Jhang (2022)          | IEEE Access   |
| A32 | Improved Vision-Based Vehicle Detection and Classification by Optimized YOLOv4.                                                                                                                                             | Zhao et al. (2022)          | IEEE Access   |
| A33 | Neural-Network-Optimized Vehicle Classification Using Clustered Image and Fiber-Sensor Datasets.                                                                                                                            | Kamencay et al. (2023)      | IEEE Access   |
| A34 | Real-Time Classification of Vehicles Using Machine Learning Algorithm on the Extensive Dataset.                                                                                                                             | Pemila et al. (2024)        | IEEE Access   |

**Tabla VIII**

*Motivación, aporte y resultados de cada investigación relacionado a la detección de vehículos.*

| ID | Motivación                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                   | Aporte                                                                                                                                                                                                                                                                                                                                                                     | Resultados                                                                                                                                                                                                                                                                                                                                                                                                           |
|----|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| A1 | El estudio se enfoca en la detección de vehículos en entornos urbanos utilizando imágenes de vigilancia de tráfico. El problema principal es la localización precisa de vehículos pequeños en escenas complejas y la necesidad de detección en tiempo real para mejorar la gestión del tráfico y reducir infracciones.                                                                                                                                                                                                       | Mejora del modelo SSD convencional, denominado DP-SSD, que utiliza concatenación de características para optimizar las tareas de localización y clasificación. El DP-SSD mejora la precisión y velocidad en la detección de vehículos pequeños mediante la combinación de deconvolución y pooling en diferentes capas de la red neuronal.                                  | El modelo DP-SSD logró una precisión media (mAP) del 75.43% y 50.47 FPS en el conjunto de datos UA-DETRAC con un tamaño de entrada de 300x300 píxeles, y un mAP del 77.94% a 25.12 FPS con un tamaño de entrada de 512x512. Estos resultados demuestran que el enfoque propuesto es comparable y, en algunos casos, superior a otros modelos de vanguardia, como SSD y YOLOv3, en términos de precisión y velocidad. |
| A2 | El artículo especifica la necesidad de detectar vehículos y peatones de manera rápida y precisa en escenarios urbanos complejos, donde la identificación en tiempo real es esencial para sistemas de advertencia de colisiones en la conducción inteligente. Se centra en mejorar tanto la precisión como la velocidad de detección mediante el uso de una versión mejorada de Mask R-CNN, combinada con un nuevo enfoque de fusión de características.                                                                      | Aporta un algoritmo mejorado, Side Fusion FPN, junto con la implementación de una nueva arquitectura de red ResNet-86 que reduce la carga de cálculo. Estas mejoras logran una detección más rápida y precisa de vehículos y peatones, aumentando el valor de mAP en comparación con Mask R-CNN convencional y otros algoritmos.                                           | Los resultados muestran un aumento de 17.53 puntos en la precisión media (mAP) y una mejora en la velocidad de detección del 7.94%. Además, el algoritmo Side Fusion FPN no incrementa significativamente la complejidad computacional, pero mejora tanto la precisión como la velocidad de procesamiento.                                                                                                           |
| A3 | El estudio propone un sistema de detección y clasificación de vehículos en intersecciones de carreteras urbanas, donde el tráfico es complejo y presenta retos como las sombras de los vehículos que afectan la precisión de la clasificación. El objetivo es mejorar la precisión en tiempo real para la detección y clasificación de vehículos en escenas de tráfico utilizando cámaras estáticas.                                                                                                                         | Introduce un algoritmo basado en la sustracción de fondo con una mejora significativa en la eliminación de sombras, permitiendo una detección más precisa. El sistema clasifica vehículos en tres categorías (coches, motocicletas y camiones) basado en sus dimensiones, proporcionando una solución eficiente para la gestión del tráfico en intersecciones.             | El sistema propuesto demostró ser robusto y preciso, con una precisión promedio del 96.78% en diferentes escenarios de tráfico urbano. Las pruebas en dos escenas mostraron una alta exactitud en la detección y clasificación de vehículos, permitiendo además su conteo para ajustar la densidad de tráfico.                                                                                                       |
| A4 | El artículo aborda la necesidad de monitorear y detectar la velocidad de los vehículos para aumentar la seguridad en las carreteras. El exceso de velocidad es una de las principales causas de accidentes de tráfico, y este estudio busca desarrollar un sistema que pueda detectar la velocidad de los vehículos en tiempo real utilizando el método Haar Cascade.                                                                                                                                                        | Propone un sistema que utiliza la técnica de detección de objetos Haar Cascade y un cálculo de velocidad basado en la distancia y el tiempo. El sistema procesa las imágenes capturadas por cámaras y calcula la velocidad de los vehículos detectados, brindando una solución eficiente y de bajo costo para mejorar la seguridad en las carreteras.                      | El sistema desarrollado obtuvo una tasa de éxito del 70.6% en la detección de velocidad de los vehículos en un entorno de prueba. Si bien se identificaron algunos problemas con la detección de múltiples objetos, los resultados fueron satisfactorios en cuanto a la precisión de la detección y cálculo de velocidad en tiempo real.                                                                             |
| A5 | La investigación aborda la necesidad de desarrollar sistemas de detección y clasificación de vehículos, tanto eléctricos como convencionales, utilizando cámaras de video infrarrojas y técnicas de aprendizaje automático. La motivación principal es mejorar la detección de vehículos en diversas condiciones climáticas y de iluminación, donde los sistemas convencionales fallan.                                                                                                                                      | Introduce un sistema que utiliza un clasificador Haar Cascade para la detección de vehículos, complementado con una red neuronal convolucional (CNN) para la categorización de los vehículos en tres tipos: coche, furgoneta y autobús. Además, destaca la capacidad de diferenciar entre vehículos eléctricos y convencionales basándose en las características térmicas. | El sistema propuesto logra una precisión promedio del 98% en la clasificación de vehículos en imágenes térmicas. Los resultados muestran que el sistema puede funcionar de manera confiable bajo diversas condiciones de temperatura y luz, con una precisión del 99% para coches, 95% para furgonetas, y 100% para autobuses.                                                                                       |
| A6 | El estudio describe el desafío de detectar vehículos en sistemas de conducción autónoma y control de tráfico en condiciones difíciles, como variaciones en la escala y oclusión. Los métodos tradicionales de detección basados en pirámides de características presentan limitaciones para aprovechar por completo las características multiescala. Además, busca mejorar la discriminación de las características en los mapas de características y reducir el costo computacional mediante una nueva arquitectura de red. | Utiliza una red basada en Faster R-CNN con un enfoque mejorado en la propuesta de regiones (RPN) y el uso de un módulo de mejora multicapa para generar mapas de características más discriminativos. También presenta un módulo de pooling adaptativo de Rol que mejora el rendimiento en la detección de vehículos, particularmente para vehículos pequeños y ocluidos.  | El método propuesto mejora significativamente el rendimiento de detección en el conjunto de datos KITTI, con un aumento del AP (precisión promedio) del 8.12% en el nivel más difícil (hard). Además, en el conjunto de datos PASCAL VOC 2007, logró un AP del 78.84%, superando a otros métodos de vanguardia.                                                                                                      |
| A7 | La investigación detalla la necesidad de mejorar la precisión en la detección de vehículos en tiempo real, particularmente en escenarios de tráfico donde se presentan problemas como la oclusión y la detección de vehículos pequeños. El objetivo principal es desarrollar un sistema que reduzca la tasa de detección falsa en diferentes condiciones climáticas y de tráfico utilizando el algoritmo YOLO v5 mejorado.                                                                                                   | Propone una versión mejorada del algoritmo YOLO v5, utilizando el algoritmo Flip-Mosaic para aumentar la capacidad del modelo de detectar objetos pequeños y reducir las falsas detecciones. Además, se creó un nuevo conjunto de datos de vehículos bajo diferentes condiciones climáticas y escenarios de tráfico.                                                       | El algoritmo mejorado de YOLO v5 con Flip-Mosaic logró una mejora en la precisión de detección de vehículos pequeños, reduciendo la tasa de falsas detecciones. Los resultados experimentales mostraron una mejora significativa en el mAP50 y mAP50:95 comparado con la versión original de YOLO v5.                                                                                                                |
| A8 | El estudio aborda la problemática de la pérdida de características en imágenes de alta resolución capturadas por UAVs durante la normalización. Se busca mejorar la detección de vehículos pequeños en imágenes aéreas de alta resolución utilizando un algoritmo de corte adaptativo y el algoritmo YOLOv5 para solucionar estos desafíos.                                                                                                                                                                                  | El principal aporte es el desarrollo de un algoritmo de corte adaptativo combinado con YOLOv5, que permite la detección de vehículos pequeños en imágenes de alta resolución capturadas por UAVs. El método aumenta la precisión y la capacidad de detección en comparación con las versiones originales de YOLOv5 y otros métodos.                                        | El algoritmo mejorado con corte adaptativo alcanzó una precisión (mAP@0.5) del 89.6% y una mejora significativa en recall del 82.5%, superando la precisión del YOLOv5 original (mAP@0.5 de 47.9%).                                                                                                                                                                                                                  |

| ID  | Motivación                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                    | Aporte                                                                                                                                                                                                                                                                                                                                                                                                                                                           | Resultados                                                                                                                                                                                                                                                                                                                                                                                                          |
|-----|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| A9  | El artículo detalla la problemática de la baja precisión en la detección de vehículos en imágenes de baja resolución (LR) capturadas desde vehículos autónomos o imágenes aéreas. El objetivo es mejorar la calidad perceptual de las imágenes y la precisión de la detección de objetos pequeños utilizando una red de detección de objetos con superresolución.                                                                                                                                             | El principal aporte es la introducción de SRODNet, una red que combina la superresolución (SR) y la detección de objetos (OD) en una única arquitectura optimizada. SRODNet utiliza bloques residuales modificados (MRB) y conexiones densas para mejorar la calidad de las imágenes y lograr una detección precisa de vehículos en imágenes de baja resolución.                                                                                                 | El modelo propuesto fue evaluado en conjuntos de datos como VEDAI-VISIBLE, VEDAI-IR, DOTA, y KoHT, obteniendo mejoras significativas en la precisión media (mAP) y la puntuación F1. Los resultados experimentales mostraron una precisión media de hasta 93.02% y un F1-score de 0.928 en el conjunto de datos KoHT, superando a modelos convencionales.                                                           |
| A10 | La investigación detalla la necesidad de detectar incidentes de tráfico en tiempo real para mejorar las medidas de seguridad vial, particularmente en Arabia Saudita, donde las tasas de mortalidad por accidentes de tráfico han aumentado significativamente. El objetivo es desarrollar un sistema de detección de incidentes basado en visión por computadora para reducir el tiempo de respuesta de los equipos de emergencia y así minimizar las lesiones y muertes causadas por accidentes de tráfico. | Propone un sistema en tiempo real que integra tres modelos; uno para la detección y seguimiento de vehículos utilizando YOLOv5 y DeepSORT, otro para la clasificación de la gravedad de los accidentes usando YOLOv5, y un modelo adicional para la detección de incendios postcolisión con ResNet152. Este sistema envía alertas automáticas a los centros de emergencia en caso de accidentes graves o incendios postcolisión.                                 | El modelo de detección y seguimiento de vehículos alcanzó un mAP del 99.2%, mientras que el modelo de clasificación de accidentes logró un mAP del 83.3%. El modelo de detección de incendios postcolisión alcanzó una precisión del 98.9%. Estos resultados demuestran la eficacia del sistema propuesto en la mejora de la detección y respuesta ante accidentes en tiempo real.                                  |
| A11 | La investigación busca desarrollar un conjunto de datos sobre condiciones de tráfico heterogéneas en Indonesia, donde el flujo de tráfico incluye una alta proporción de motocicletas. La motivación radica en la necesidad de medir y predecir con precisión la capacidad de las carreteras y las condiciones de tráfico para mejorar la planificación del tráfico y la infraestructura vial en entornos urbanos.                                                                                            | Recopila datos sobre el tráfico utilizando cámaras CCTV y mapas digitales TomTom para medir el grado de saturación del tráfico en diferentes segmentos de carreteras. El conjunto de datos resultante permite una mejor predicción del flujo de tráfico futuro y ofrece una base sólida para investigaciones adicionales sobre la congestión en áreas urbanas de tráfico heterogéneo.                                                                            | Los resultados muestran que el método de detección de objetos basado en YOLOv3 utilizado para contar vehículos, junto con los datos de velocidad de TomTom, proporcionó una medición precisa del flujo de tráfico en 265 segmentos de carretera en Bandung, Indonesia. Los errores de detección se limitaron a 0-2 coches y 2-3 motocicletas, con un alto grado de precisión en la estimación de la capacidad vial. |
| A12 | El estudio presenta la necesidad de mejorar la seguridad del tráfico y la estimación de la velocidad de vehículos mediante drones de baja altitud, proporcionando una alternativa a los sistemas de cámaras fijas y minimizando los riesgos para los agentes de tránsito en áreas de difícil acceso.                                                                                                                                                                                                          | Propone un sistema basado en drones de baja altitud equipado con el modelo MobileNet-SSD para detectar la velocidad de los vehículos en tiempo real. El sistema incluye un diseño de interfaz gráfica de usuario (GUI) y se configura en un entorno de ciudad inteligente, mejorando la precisión en intersecciones de carreteras y zonas de tráfico denso, como escuelas y hospitales.                                                                          | El sistema demostró un rendimiento superior en comparación con otros estudios, con una precisión del 92% en la estimación de la velocidad de los vehículos en situaciones dinámicas y congestionadas. Los experimentos mostraron que el sistema es altamente efectivo en carreteras concurridas y en áreas con vehículos que varían mucho en velocidad.                                                             |
| A13 | El artículo detalla el desafío de mejorar la detección de vehículos en entornos urbanos congestionados, donde la alta tasa de errores en la detección de pequeños objetivos y la percepción débil del algoritmo original de YOLOv7 plantean problemas. Se busca mejorar la capacidad de detección de vehículos, especialmente en condiciones de tráfico pesado y bajo diversas condiciones climáticas.                                                                                                        | Propone un nuevo algoritmo llamado YOLOv7-RAR, que mejora el YOLOv7 mediante la incorporación de un módulo de atención híbrida (ACmix), una estructura mejorada de fusión de características no lineales (Res3Unit), y un esquema de campo receptivo basado en Gauss (RFLAGauss). Estos componentes mejoran la precisión y la velocidad de detección de vehículos pequeños y distantes en entornos urbanos.                                                      | El modelo YOLOv7-RAR obtuvo una precisión promedio (mAP) del 95.1%, con un aumento del 2.4% en comparación con el YOLOv7 estándar. La métrica AP50:90 mostró una mejora del 12.6%, y el modelo alcanzó una velocidad de detección de 96 FPS, cumpliendo los requisitos de detección en tiempo real para tráfico urbano.                                                                                             |
| A14 | La investigación explica la necesidad de un sistema eficiente para la detección, seguimiento y conteo de vehículos en tiempo real, especialmente en ciudades en desarrollo como Morelia, México, donde la infraestructura vial no ha crecido al ritmo del número de vehículos. Este estudio busca aplicar algoritmos avanzados de inteligencia artificial para optimizar el monitoreo del tráfico y mejorar la planificación de infraestructuras.                                                             | Propone el uso del algoritmo YOLOR en combinación con DeepSORT para la detección y clasificación en tiempo real de vehículos en diversas condiciones de tráfico, iluminación y clima. Ofrece un enfoque escalable y preciso para la gestión inteligente del tráfico en ciudades en crecimiento, mejorando la eficiencia de los sistemas de monitoreo urbano.                                                                                                     | Los resultados muestran que la combinación de YOLOR y DeepSORT ofrece un alto grado de precisión en la clasificación de múltiples tipos de vehículos. Se observó una precisión del 99.2% en la detección de vehículos y una precisión del 83.3% en la clasificación de la gravedad de accidentes, mostrando su eficacia en la gestión del tráfico en tiempo real.                                                   |
| A15 | El artículo explica la importancia de la detección en tiempo real de vehículos para mejorar la seguridad vial, regular el flujo de tráfico y mejorar los sistemas inteligentes de transporte. El enfoque se centra en desarrollar un modelo basado en redes neuronales convolucionales (CNN) que pueda identificar vehículos con alta precisión en entornos complejos y en tiempo real, superando los desafíos de precisión presentes en estudios anteriores.                                                 | El principal aporte es el desarrollo de un modelo de detección de vehículos basado en redes neuronales convolucionales (CNN) de 23 capas, optimizado con 14.7 millones de parámetros. Se implementa un proceso de ajuste de hiperparámetros utilizando Adamax y una tasa de aprendizaje ajustada. El modelo logra una precisión superior al 99%, mejorando significativamente el rendimiento en comparación con estudios previos que alcanzaban entre 85% y 88%. | El modelo propuesto alcanzó una precisión de 99.4% en el conjunto de entrenamiento, 99.3% en validación, y 99.4% en pruebas. Además, las métricas de precisión y recall también alcanzaron valores de 99.3% y 99.4%, respectivamente. Estos resultados indican un rendimiento muy robusto para la detección de vehículos en tiempo real.                                                                            |
| A16 | El estudio describe la importancia de detectar y clasificar defectos en carreteras, como grietas y baches, de manera precisa y rápida para mejorar la infraestructura vial y reducir el riesgo de accidentes. El estudio tiene como objetivo comparar el rendimiento de los algoritmos YOLOv5, YOLOv6 y YOLOv7 en la detección de estos defectos.                                                                                                                                                             | Compara los algoritmos YOLOv5, YOLOv6, y YOLOv7 en la detección de defectos en carreteras, evaluando sus rendimientos en términos de precisión (mAP), velocidad de inferencia, y uso de recursos. Proporciona una evaluación detallada sobre cuál modelo es más efectivo para detectar defectos en diversas condiciones de tráfico y clima, contribuyendo al campo del mantenimiento vial.                                                                       | El modelo YOLOv7 obtuvo el mejor rendimiento general con un mAP@0.5 de 79.0% y una velocidad de inferencia de 0.47 minutos para 255 imágenes. YOLOv5-l tuvo un rendimiento similar con un mAP de 78.9%, pero con una velocidad de inferencia más lenta de 0.97 minutos. Por otro lado, YOLOv6-l registró un mAP de 72.32%.                                                                                          |

| ID  | Motivación                                                                                                                                                                                                                                                                                                                                                                                                                                                          | Aporte                                                                                                                                                                                                                                                                                                                                                                                                                                                             | Resultados                                                                                                                                                                                                                                                                                                                                                    |
|-----|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| A17 | El artículo tiene como objetivo desarrollar un sistema de clasificación de tráfico vehicular congestionado en tiempo real, utilizando características visuales extraídas de videos de tráfico y comparando enfoques basados en aprendizaje automático y aprendizaje profundo. La motivación principal es proporcionar una herramienta eficiente para estimar el estado del tráfico y ayudar a la gestión del tráfico urbano.                                        | Ofrece una comparación exhaustiva entre detectores de objetos y clasificadores visuales para la detección de vehículos y la clasificación del estado del tráfico. Se comparan los enfoques clásicos de aprendizaje automático con métodos de aprendizaje profundo, demostrando que los modelos de aprendizaje profundo alcanzan una mayor precisión en la clasificación del estado del tráfico, con un rendimiento de hasta el 99.9% en la clasificación binaria.  | El enfoque de aprendizaje profundo alcanzó una precisión del 99.9% para la clasificación binaria (congestionado/no congestionado) y un 98.6% en la clasificación multiclase (leve, medio y severo). Los clasificadores tradicionales, como Random Forest, alcanzaron una precisión del 84% usando características visuales extraídas.                         |
| A18 | El artículo se enfoca en mejorar los tiempos de respuesta de vehículos prioritarios como ambulancias, carros de bomberos y patrullas policiales en intersecciones urbanas controladas por semáforos inteligentes. La motivación surge de la necesidad de optimizar el flujo de tráfico para reducir la congestión y mejorar los tiempos de espera en situaciones de emergencia.                                                                                     | Presenta el modelo PVIDNet, una red de detección de vehículos basada en YOLOv3 mejorado, que detecta vehículos prioritarios y regula los semáforos de manera inteligente, reduciendo el tiempo de espera de estos vehículos en hasta un 50%. Además, el artículo introduce un algoritmo ligero que permite reducir el tiempo de procesamiento sin afectar la precisión.                                                                                            | El modelo PVIDNet alcanzó una precisión superior al 95% en la clasificación de vehículos, y la reducción del tiempo de espera en semáforos fue de 50% para vehículos prioritarios y 5% para transporte público, sin afectar negativamente a los automóviles regulares.                                                                                        |
| A19 | La investigación presenta un marco integral para la detección y predicción del volumen de tráfico urbano utilizando imágenes de CCTV en tiempo real. La motivación principal es mejorar la gestión del tráfico mediante una herramienta de predicción confiable y automatizada, especialmente en entornos urbanos donde las cámaras de CCTV están ampliamente disponibles.                                                                                          | Propone un marco de trabajo que utiliza Faster R-CNN para la detección de vehículos y combina modelos estadísticos y de aprendizaje profundo (SARIMAX, Random Forest y LSTM) para predecir el volumen de tráfico en diferentes escenarios. Se enfatiza en la capacidad del sistema para rellenar lagunas de datos en situaciones climáticas adversas y proporcionar información en tiempo real para la toma de decisiones.                                         | Los modelos Random Forest (RF) y LSTM demostraron ser los más precisos, siendo RF más eficiente en términos de tiempo. El marco fue capaz de predecir el volumen de tráfico con un alto grado de precisión, incluso con datos faltantes en las imágenes de CCTV.                                                                                              |
| A20 | El estudio aborda la necesidad de mejorar la detección de colisiones en los puntos ciegos de vehículos comerciales, como autobuses y camiones, que tienen más puntos ciegos en comparación con otros vehículos. La motivación principal es reducir el número de accidentes graves causados por vehículos pesados al mejorar los sistemas de detección de objetos en áreas de puntos ciegos mediante una arquitectura de redes neuronales convolucionales profundas. | Realiza un sistema de detección de colisiones en puntos ciegos basado en una arquitectura de multi-CNN integrada con Faster R-CNN. La innovación radica en la fusión de dos redes CNN preentrenadas, ResNet-50 y ResNet-101, para mejorar la precisión en la detección de vehículos en puntos ciegos. El sistema fue probado con un conjunto de datos de vehículos comerciales y en condiciones de tráfico denso.                                                  | El sistema logró una tasa de detección positiva (TPR) del 98.72% y una tasa de falsos positivos (FDR) del 3.05% para el conjunto de datos grabado en situaciones reales. Estos resultados lo hacen adecuado para aplicaciones en tiempo real en vehículos pesados.                                                                                            |
| A21 | La investigación se enfoca en el uso de algoritmos de aprendizaje profundo para la detección de vehículos en entornos complejos, como carreteras con tráfico denso. La motivación principal es mejorar la eficiencia de los sistemas de detección de vehículos en aplicaciones como la conducción autónoma y el transporte inteligente, utilizando los algoritmos YOLOv3 y SSD.                                                                                     | Propone una comparación entre los algoritmos de detección de objetos YOLOv3 y SSD aplicados a un conjunto de datos de vehículos. Los autores realizan un análisis exhaustivo de los resultados obtenidos con ambos modelos, identificando las ventajas de YOLOv3 en la detección de objetos pequeños y su capacidad para realizar detecciones en tiempo real, lo que lo hace adecuado para aplicaciones de conducción autónoma.                                    | El algoritmo YOLOv3 superó a SSD en la precisión de detección, con una mAP del 76.1%, en comparación con el 74.3% de SSD. Además, YOLOv3 tuvo una mayor velocidad de procesamiento con 50 FPS, lo que lo hace ideal para sistemas que requieren detección en tiempo real.                                                                                     |
| A22 | El artículo aborda el desafío de la detección de vehículos en videos tomados por drones (UAV), donde los métodos tradicionales son susceptibles a la calidad del video y las condiciones climáticas. La motivación principal es mejorar la precisión y robustez de los sistemas de detección en videos de tráfico capturados desde drones, para que puedan ser utilizados en sistemas de transporte inteligente.                                                    | Propone una metodología de detección de vehículos utilizando aprendizaje profundo en videos de drones, con la inclusión de una transformación de brillo espacial y la optimización de la arquitectura de Single Shot MultiBox Detector (SSD) mediante la adición de Focus Loss para mejorar la extracción de características y la precisión. El sistema se enfoca en la capacidad de adaptarse a diversas condiciones de luz y aumentar la diversidad de muestras. | El algoritmo de detección de vehículos propuesto alcanzó una tasa de detección del 96.49% en los videos de drones. El sistema demostró ser capaz de detectar vehículos de manera precisa, incluso en condiciones desafiantes como variaciones de iluminación y ángulos de grabación diferentes.                                                               |
| A23 | El estudio busca proporcionar un método eficiente y de bajo costo para la recolección y análisis de datos de tráfico en eventos importantes mediante técnicas de visión por computadora, específicamente redes neuronales convolucionales (CNN), como alternativa a los métodos tradicionales que son costosos y requieren infraestructura física.                                                                                                                  | Presenta un marco que utiliza un modelo CNN junto con un algoritmo de seguimiento de objetos para detectar y rastrear vehículos en grabaciones de video. Además, se implementa una proyección homográfica para mapear la información espacial y temporal de los vehículos en un mapa real a escala, lo que permite calcular el volumen de tráfico y los patrones de giro en intersecciones. Este enfoque logra una precisión del 96.91% en el conteo de vehículos. | El sistema alcanzó un 96.91% de precisión en la cuenta del volumen de tráfico. Se identificaron factores que influyen en el rendimiento, como el tamaño de los píxeles de detección y el ángulo de la cámara. Se sugiere colocar cámaras con un tamaño de píxeles de detección superior a 2343 y un ángulo de visión inferior a 22° para una mayor precisión. |

| ID  | Motivación                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                   | Aporte                                                                                                                                                                                                                                                                                                                                                                                                                                                                        | Resultados                                                                                                                                                                                                                                                                                                                                                                                   |
|-----|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| A24 | La investigación aborda la necesidad urgente de mejorar la seguridad para los usuarios del transporte no motorizado (peatones y ciclistas), quienes enfrentan riesgos debido a la infraestructura vial centrada en vehículos motorizados. La motivación principal es desarrollar un enfoque basado en deep learning para identificar y clasificar los escenarios de peligro relacionados con el transporte no motorizado, utilizando imágenes de vista de calle.                                                                                             | Brinda un método que combina algoritmos de segmentación semántica (PSPNet) y modelos de clasificación (SENet) para identificar automáticamente los escenarios de peligro. Utilizando imágenes de vista de calle y análisis espacial, el enfoque permite cuantificar los riesgos para los peatones y ciclistas en diversas condiciones urbanas, proporcionando recomendaciones de mejora basadas en los resultados.                                                            | El sistema alcanzó una precisión del 96.71% en la clasificación de escenarios peligrosos, mostrando un alto rendimiento en la identificación de áreas de peligro en segmentos viales del distrito de Gulou, Nanjing. Se identificaron múltiples factores de riesgo, como la interrupción de las aceras y la mezcla de peatones y vehículos, con sugerencias para mejorar la infraestructura. |
| A25 | El artículo se enfoca en mejorar la detección y reconocimiento de vehículos en sistemas de monitoreo de tráfico de múltiples escalas. La motivación principal es abordar las limitaciones actuales en la precisión y eficiencia de estos sistemas, especialmente en entornos de tráfico denso y condiciones visuales extremas, como iluminación difícil y cambios climáticos.                                                                                                                                                                                | Propone un método basado en la optimización de datos mediante minería de grafos, combinado con características de energía y flujo óptico denso. Se aplica un enfoque basado en redes neuronales artificiales (ANN) para la detección y el reconocimiento de vehículos. El sistema mejora el reconocimiento de vehículos en condiciones extremas y en tráfico denso, y fue probado con éxito en los conjuntos de datos LISA y KITTI.                                           | El sistema logró una tasa de reconocimiento promedio del 93.75% en el conjunto de datos LISA y una precisión del 82.85% en el conjunto de datos KITTI. La optimización mediante minería de grafos permitió mejorar la selección de características y aumentar la eficiencia en la detección de vehículos en entornos de tráfico denso.                                                       |
| A26 | El estudio explica la necesidad de desarrollar sistemas avanzados de asistencia al conductor (ADAS) para reducir los accidentes de tráfico causados por errores humanos. El enfoque principal es la detección de vehículos mediante cámaras en tiempo real para sistemas de advertencia de colisiones frontales (FCWS), con un objetivo de implementar el sistema en una plataforma empotrada de bajo costo.                                                                                                                                                 | Presenta el desarrollo de un sistema de detección de vehículos utilizando el método de clasificadores en cascada, implementado en una plataforma empotrada. El sistema utiliza características de LBP y Haar para entrenar los clasificadores, y se demuestra que LBP es el más eficiente en términos de velocidad y precisión para este proyecto. El algoritmo fue probado en un conjunto de datos de carreteras en Malasia.                                                 | El sistema alcanzó una precisión de 88.3% en la detección de vehículos con imágenes de resolución de 340x135 píxeles. En una plataforma empotrada, el sistema logró procesar 13 cuadros por segundo con entrada de archivo de video y 15 cuadros por segundo con entrada de cámara.                                                                                                          |
| A27 | La investigación detalla el problema de la detección y clasificación de vehículos en sistemas de transporte inteligente, utilizando características tanto estáticas como de movimiento. La motivación principal es mejorar la robustez y la aplicabilidad de los sistemas de monitoreo de tráfico basados en video, especialmente en entornos viales diversos y condiciones cambiantes.                                                                                                                                                                      | Propone un enfoque que combina características de apariencia estática y de movimiento para mejorar la detección y clasificación de vehículos. Se entrenaron cuatro detectores distintos basados en redes neuronales profundas con pequeños conjuntos de datos de entrenamiento. Además, se diseñaron algoritmos para la selección y reorganización de objetos detectados, optimizando los resultados.                                                                         | El método propuesto logró una precisión superior al 95% en diferentes entornos de tráfico. Los experimentos demostraron que el enfoque es robusto, con capacidad para adaptarse a diversos escenarios viales, utilizando videos de vigilancia de tráfico. El uso combinado de características estáticas y de movimiento mejoró tanto la precisión como la flexibilidad del sistema.          |
| A28 | El artículo describe la necesidad de mejorar los sistemas de detección de vehículos en entornos de tráfico urbano densos. Los sistemas tradicionales de detección de objetos enfrentan desafíos en situaciones de tráfico complejo, especialmente con vehículos parcialmente ocultos o pequeños. La motivación principal es implementar la segmentación por instancias para mejorar la precisión de la detección de vehículos en estos entornos, brindando mejores resultados en comparación con los métodos tradicionales basados en cuadros delimitadores. | Implementa el método Mask R-CNN para la detección de vehículos a través de la segmentación por instancias, proporcionando tanto un cuadro delimitador como una máscara del objeto de interés. El enfoque permite una mejor detección en escenas complejas, con vehículos pequeños o parcialmente ocultos, utilizando aprendizaje por transferencia en conjuntos de datos como KITTI y BDD100K.                                                                                | El enfoque de segmentación por instancias logró una alta precisión, alcanzando una mAP de 90.27% y una mAR de 92.38%. Además, se observó que la técnica supera a otros métodos en la precisión y la capacidad de manejar vehículos pequeños y ocultos en escenas densas de tráfico.                                                                                                          |
| A29 | El estudio especifica la creciente necesidad de sistemas de gestión de tráfico inteligentes, dada la rápida expansión del número de vehículos en países como Malasia. La motivación principal es mejorar la precisión y velocidad en la detección y seguimiento de vehículos en carreteras congestionadas, utilizando YOLOv4 y DeepSORT para detección en tiempo real, lo que beneficia la gestión del tráfico y la planificación urbana.                                                                                                                    | Propone el uso de YOLOv4 combinado con el algoritmo de seguimiento DeepSORT para detectar vehículos en tiempo real con alta precisión y velocidad. El sistema puede detectar diferentes tipos de vehículos (coches, motocicletas, autobuses y camiones) y realizar un seguimiento de ellos, lo que permite contar el número de vehículos que pasan por ciertas áreas. El uso de DeepSORT mejora la capacidad del sistema para rastrear vehículos en escenas de tráfico denso. | El modelo YOLOv4 alcanzó un mAP del 82.08% utilizando un conjunto de datos personalizado, con una velocidad de procesamiento de 14 FPS en una GPU GTX 1660ti. El modelo también mostró mejores resultados en comparación con YOLOv3 y versiones anteriores, tanto en términos de precisión como de velocidad.                                                                                |
| A30 | La investigación detalla el creciente problema del aumento del volumen de tráfico y los accidentes en áreas urbanas, debido al incremento de la población y la concentración de vehículos. El objetivo principal es desarrollar un sistema eficiente de clasificación y seguimiento de vehículos utilizando un modelo basado en deep learning, que pueda operar en entornos complejos y diversos, proporcionando información valiosa para la gestión del tráfico y la prevención de accidentes.                                                              | Brinda un esquema de clasificación y seguimiento de vehículos utilizando YOLO como modelo principal de deep learning. El sistema es capaz de clasificar y rastrear vehículos en diversas condiciones ambientales, superando las limitaciones de los métodos tradicionales. Se presenta una comparación entre K-NN, Faster R-CNN y YOLO, mostrando que YOLO ofrece mejores resultados en términos de precisión y rapidez.                                                      | El modelo YOLO alcanzó una precisión promedio del 90.32%, superando a otros métodos como Faster R-CNN (88.10%) y K-NN (82.12%). El sistema también mostró una capacidad robusta para clasificar y seguir vehículos en diferentes entornos, demostrando su aplicabilidad para sistemas de monitoreo de tráfico.                                                                               |

| ID  | Motivación                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                  | Aporte                                                                                                                                                                                                                                                                                                                                                                                                                                                                                        | Resultados                                                                                                                                                                                                                                                                                                                                                        |
|-----|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| A31 | El artículo aborda los problemas de tráfico urbano, como los embotellamientos y el aumento del número de vehículos. La motivación principal es mejorar la detección y clasificación de vehículos en tiempo real utilizando un sistema de monitoreo inteligente basado en YOLO y redes neuronales convolucionales difusas (CFNN). Este enfoque busca mejorar tanto la velocidad como la precisión de los sistemas actuales de monitoreo de tráfico.                                                                          | Presenta un modelo de monitoreo de tráfico basado en mYOLOv4-tiny combinado con CFNN para la clasificación de vehículos. Además, introduce un método de fusión de características que mejora la precisión de la clasificación y reduce el número de parámetros en el modelo. El sistema se implementa en la plataforma empujada NVIDIA AGX Xavier para permitir la detección, seguimiento y conteo en tiempo real de vehículos en las carreteras.                                             | El sistema propuesto logró una precisión promedio del 99% en la clasificación de vehículos utilizando los conjuntos de datos públicos BIT-Vehicle y GRAM-RTM. Además, demostró ser capaz de mantener una velocidad de procesamiento de más de 30 FPS en la plataforma NVIDIA AGX Xavier, lo que lo hace adecuado para aplicaciones en tiempo real.                |
| A32 | El estudio describe la necesidad de sistemas de transporte inteligentes (ITS) que puedan detectar y clasificar vehículos de manera rápida y precisa, especialmente en condiciones complejas como tráfico denso o interferencias en imágenes. El objetivo es mejorar el rendimiento del modelo YOLOv4 mediante la optimización de su red y la introducción de un mecanismo de atención.                                                                                                                                      | Propone una versión mejorada de YOLOv4, denominada YOLOv4_AF, que incorpora un módulo de atención de bloques convolucionales (CBAM) para mejorar la detección de vehículos en entornos complejos. Además, modifica la red de pirámide de características (FPN) del modelo original, lo que permite una mejor detección y clasificación de vehículos, con resultados superiores en términos de precisión y F1 score en comparación con otros modelos como Faster R-CNN y EfficientDet.         | El modelo YOLOv4_AF logró una mAP del 83.45% en el conjunto de datos BIT-Vehicle y un F1-score de 0.816, superando a modelos como Faster R-CNN y EfficientDet. También mostró resultados sólidos en el conjunto de datos UA-DETRAC, con una mAP del 77.08% y un F1 score de 0.808.                                                                                |
| A33 | La investigación explica la necesidad de mejorar los sistemas de clasificación de vehículos en carreteras utilizando tecnologías modernas de sensores y redes neuronales. La motivación principal es superar las limitaciones de los sistemas actuales de clasificación de vehículos que dependen exclusivamente de plataformas tecnológicas singulares, integrando datos de imágenes de CCTV y sensores ópticos de fibra Bragg (FBG) para mejorar la precisión de clasificación.                                           | Brinda un sistema híbrido que combina un conjunto de datos de imágenes de CCTV con un conjunto de datos de sensores FBG, optimizado mediante redes neuronales convolucionales (CNN). Esta solución híbrida mejora la precisión de la clasificación de vehículos, alcanzando entre 90% y 97% de precisión en la clasificación de diferentes tipos de vehículos. Además, el sistema incluye una verificación interna de respaldo para compensar las limitaciones de cada tecnología individual. | El sistema propuesto alcanzó una precisión de clasificación del 90% al 97%, lo que demuestra una mejora significativa en comparación con los sistemas basados en una sola tecnología. La integración de los datos de sensores y de imágenes proporciona una mayor robustez y fiabilidad en la clasificación de vehículos en condiciones de tráfico denso.         |
| A34 | El artículo aborda la necesidad de clasificar vehículos en tiempo real de manera precisa y robusta, dado el alto volumen de tráfico en las carreteras y la importancia de identificar y clasificar correctamente los vehículos para reducir accidentes y mejorar la gestión del tráfico. La motivación principal es superar los desafíos de los sistemas manuales y automatizados existentes, que suelen ser inexactos en diversas condiciones climáticas y de iluminación, mediante un enfoque basado en machine learning. | Presenta un sistema de clasificación de vehículos basado en la técnica XGBoost y combina varias técnicas de preprocesamiento, como la transformada random y wavelet, así como segmentación basada en bordes y regiones para la extracción de características. El sistema logra clasificar vehículos con una precisión del 98.81%, superando a los modelos tradicionales de clasificación de vehículos y logrando tiempos de procesamiento extremadamente rápidos (0.16 ns por imagen).        | El sistema propuesto alcanzó una precisión del 98.81%, lo que lo posiciona por encima de otros modelos de machine learning existentes. Además, puede clasificar imágenes en tiempo real, mostrando gran robustez en diversas condiciones climáticas y de iluminación, usando el conjunto de datos SRM2KTR que contiene más de un millón de imágenes de vehículos. |

**Tabla IX**

*Respuestas de las preguntas de investigación formuladas en la planificación de la revisión.*

| ID | P1                                                                                                                                                                    | P2                                                                                                                                                                                                                                                                                               | P3                                                                                                                                                                                                                                   |
|----|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| A1 | El algoritmo principal es <b>DP-SSD</b> , una versión mejorada de SSD. También se mencionan YOLOv3 y Faster R-CNN como referencia comparativa.                        | Se utiliza los conjuntos de datos <b>UA-DETRAC</b> y <b>KITTI</b> . Se aplican <b>técnicas de aumento de datos</b> como ajuste de brillo, contraste, saturación, y volteo horizontal. Se incluyen vehículos de diferentes tamaños y condiciones climáticas.                                      | Las métricas utilizadas son la <b>precisión media (mAP)</b> y los <b>cuadros por segundo (FPS)</b> . DP-SSD alcanzó un mAP de 75.43% con 50.47 FPS en 300x300 píxeles, y 77.94% con 25.12 FPS en 512x512 píxeles.                    |
| A2 | Se utiliza una versión mejorada de Mask R-CNN, llamada <b>Side Fusion FPN</b> , con la red <b>ResNet-86</b> como espina dorsal para la extracción de características. | Se usa el conjunto de datos <b>COCO</b> , que fue modificado y etiquetado específicamente para las clases de vehículos, autobuses y peatones, utilizando la herramienta de anotación <b>VIA</b> . Se crearon 1000 imágenes de entrenamiento, 100 imágenes de validación y 50 imágenes de prueba. | Las métricas de validación utilizadas incluyen la <b>precisión media (mAP)</b> y <b>FLOPs</b> . El nuevo modelo SF-FPN combinado con ResNet-86 alcanzó un mAP de 76.82 para las clases de vehículos y un mAP de 79.62 para peatones. |
| A3 | Se utiliza el algoritmo <b>Mixture of Gaussians (MoGs)</b> para la sustracción de fondo y un algoritmo de eliminación de sombras basado en la detección de bordes.    | Los datos provienen de <b>videos obtenidos por cámaras estáticas</b> en la ciudad de Casablanca. Se utilizan <b>técnicas</b> como la sustracción de fondo y la eliminación de sombras para mejorar la precisión de la detección.                                                                 | La precisión de detección se mide mediante la exactitud del conteo de vehículos, con una <b>precisión promedio</b> de 96.78% en las dos escenas probadas.                                                                            |
| A4 | Se utiliza el algoritmo <b>Haar Cascade</b> para la detección de vehículos.                                                                                           | El procesamiento se realiza utilizando <b>videos de tráfico grabados por una cámara externa</b> . El algoritmo Haar Cascade detecta los vehículos y calcula la velocidad basada en la distancia recorrida y el tiempo transcurrido.                                                              | Se utiliza la <b>tasa de éxito</b> en la detección, que fue del 70.6%, como métrica principal para evaluar el rendimiento del sistema.                                                                                               |
| A5 | Se utilizan el <b>Haar Cascade</b> para la detección y una <b>red neuronal convolucional (CNN)</b> para la clasificación de vehículos.                                | Se utilizan <b>imágenes térmicas de una cámara FLIR E5</b> para crear una base de datos. Las imágenes incluyen tres categorías de vehículos: coche, furgoneta y autobús.                                                                                                                         | La <b>precisión promedio</b> fue del 98%: 99% en la clasificación de coches, 95% para furgonetas y 100% para autobuses.                                                                                                              |


| ID  | P1                                                                                                                                                                                                     | P2                                                                                                                                                                                                                                                                                                                     | P3                                                                                                                                                                                                                                                                                                     |
|-----|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| A6  | Se utiliza <b>Faster R-CNN</b> con una arquitectura de pirámide de características mejorada (FPN) y un módulo de mejora multicapa.                                                                     | Los datos provienen de los conjuntos de datos <b>KITTI</b> y <b>PASCAL VOC 2007</b> , que contienen imágenes de vehículos en diferentes tamaños y condiciones. Se emplea el método de <b>non-maximum suppression (NMS)</b> para filtrar las propuestas de regiones superpuestas.                                       | Las métricas principales son la <b>precisión promedio (AP)</b> y el <b>tiempo de inferencia</b> . En KITTI, el AP mejoró hasta un 81.32% en la categoría difícil, mientras que en PASCAL VOC 2007 se logró un AP del 78.84%.                                                                           |
| A7  | El algoritmo utilizado es <b>YOLO v5</b> mejorado, con el uso del <b>Flip-Mosaic</b> para el aumento de datos.                                                                                         | Se creó un conjunto de <b>datos de vehículos extraído de videos de monitoreo de autopistas</b> en China, que incluye diversos tipos de vehículos bajo distintas condiciones climáticas. El algoritmo Flip-Mosaic mejoró la diversidad de los datos mediante la combinación de imágenes.                                | Las métricas principales son <b>precisión promedio (mAP50)</b> y <b>mAP50:95</b> . El modelo mejorado logró un incremento en ambas métricas, especialmente en la detección de vehículos pequeños y en escenarios con oclusión.                                                                         |
| A8  | Se utiliza <b>YOLOv5</b> con un algoritmo de corte adaptativo para mejorar la detección de vehículos pequeños en imágenes de alta resolución.                                                          | El conjunto de datos se genera a partir de imágenes de UAVs con alta resolución (5760x3240 píxeles) del dataset <b>VisDrone</b> . Las imágenes se cortan adaptativamente para mantener detalles de los vehículos antes del entrenamiento.                                                                              | Se utilizan <b>mAP@0.5</b> y <b>recall</b> . El algoritmo logró un mAP@0.5 de 89.6% y un recall del 82.5%.                                                                                                                                                                                             |
| A9  | Se utiliza el modelo <b>SRODNet</b> , que combina superresolución y detección de objetos. El componente de detección de objetos utiliza <b>YOLOv5</b> integrado en la arquitectura de superresolución. | Se utilizan los conjuntos de datos <b>VEDAI-VISIBL</b> , <b>VEDAI-IR</b> , <b>DOTA</b> , y <b>KoHT</b> . Las imágenes de baja resolución son mejoradas mediante superresolución antes de la detección de objetos.                                                                                                      | Se utilizan <b>mAP@0.5</b> y <b>F1-score</b> . El modelo alcanzó un mAP@0.5 del 93.02% y un F1-score de 0.928 en el conjunto de datos KoHT.                                                                                                                                                            |
| A10 | Se utiliza <b>YOLOv5</b> en combinación con el algoritmo de seguimiento <b>DeepSORT</b> .                                                                                                              | El conjunto de datos utilizado incluye <b>imágenes extraídas de videos de vigilancia</b> de tráfico CCTV. Se realizaron anotaciones manuales para los incidentes de tráfico y vehículos detectados. Se utiliza un esquema de división 80/10/10 para entrenamiento, validación y pruebas.                               | Las métricas de validación incluyen <b>precisión media (mAP)</b> , con un mAP de 99.2% para la detección de vehículos y un mAP de 83.3% para la clasificación de la gravedad de accidentes.                                                                                                            |
| A11 | Se utiliza <b>YOLOv3</b> para la detección de vehículos en transmisiones de CCTV públicas.                                                                                                             | Se recopilan <b>datos de tráfico utilizando CCTV público</b> y <b>TomTom Digital Maps</b> , con cálculos basados en el grado de saturación y el número de vehículos detectados.                                                                                                                                        | Se utiliza el <b>error medio absoluto (MAE)</b> para validar los resultados, con errores que van de 0 a 2 coches, y de 2 a 3 motocicletas en la mayoría de los segmentos.                                                                                                                              |
| A12 | Se utiliza el modelo <b>MobileNet-SSD</b> para la detección de vehículos en combinación con un dron equipado con una cámara Raspberry Pi.                                                              | Se utiliza un conjunto de datos de <b>videos en tiempo real capturados por un dron de baja altitud equipado con una cámara Raspberry Pi</b> . El procesamiento incluye la normalización de bandas de color y la detección de vehículos a través de la conversión de imágenes en OpenCV.                                | Las métricas principales incluyen la <b>precisión</b> de detección y la velocidad de cálculo de velocidad de vehículos. Se alcanzó una precisión del 92% en la estimación de velocidad.                                                                                                                |
| A13 | Se utiliza una versión mejorada de YOLOv7 llamada <b>YOLOv7-RAR</b> , que incorpora los módulos Res3Unit, ACmix, y RFLAGauss.                                                                          | Se utiliza el conjunto de datos <b>UA-DETRAC</b> , que incluye 140,000 imágenes de vehículos tomadas desde pasos elevados en las ciudades de Beijing y Tianjin, etiquetadas manualmente con más de 1.2 millones de objetos objetivo.                                                                                   | Las métricas utilizadas son <b>mAP</b> (95.1%), <b>AP50:90</b> (86.1%), y la velocidad de procesamiento fue de 96 FPS.                                                                                                                                                                                 |
| A14 | Se utilizan los algoritmos <b>YOLOR</b> y <b>DeepSORT</b> para la detección y seguimiento de vehículos en tiempo real.                                                                                 | El conjunto de datos se recopiló de estaciones de monitoreo de tráfico en Morelia, utilizando <b>videos de alta resolución</b> grabados en 6 puntos de la ciudad, procesados con YOLOR para la clasificación y conteo de vehículos.                                                                                    | Las métricas principales incluyen la <b>precisión</b> (99.2%) para la detección y el <b>mAP</b> (83.3%) para la clasificación de la gravedad de accidentes.                                                                                                                                            |
| A15 | Se utiliza un modelo de detección basado en <b>redes neuronales convolucionales (CNN)</b> de 23 capas.                                                                                                 | Se utiliza un conjunto de datos que incluye 14,208 imágenes de entrenamiento, 1,776 imágenes de validación y 1,776 imágenes de prueba, con un total de 20,000 vehículos anotados mediante cuadros delimitadores. Las <b>imágenes</b> tienen una resolución de 1024x1024 píxeles.                                       | Se utilizan <b>precisión</b> , <b>recall</b> , y <b>accuracy</b> . El modelo logró una precisión de 99.3%, un recall de 99.4%, y una exactitud de 99.4% en las pruebas.                                                                                                                                |
| A16 | Se utilizan los algoritmos <b>YOLOv5</b> , <b>YOLOv6</b> , y <b>YOLOv7</b> para la detección de defectos en la carretera.                                                                              | El conjunto de datos se creó utilizando una <b>cámara GoPro Hero 8</b> montada en un vehículo, con <b>imágenes extraídas de videos grabados a 1920x1080 píxeles</b> y 24 fps. El dataset contiene imágenes de cuatro clases: grietas de cocodrilo, grietas longitudinales, grietas transversales, y baches.            | Las métricas utilizadas incluyen <b>mAP@0.5</b> y <b>precisión</b> . El mejor rendimiento fue alcanzado por YOLOv7 con un mAP@0.5 del 79.0% y una precisión del 87.16%.                                                                                                                                |
| A17 | Se utilizaron los algoritmos <b>Haar Cascade</b> , <b>YOLOv3</b> , <b>SSD</b> , y <b>Mask R-CNN</b> para la detección de vehículos. YOLOv3 y Haar Cascade fueron los algoritmos más precisos.          | Se utilizaron dos conjuntos de datos: <b>GRAM RTM (videos etiquetados con cuadros delimitadores)</b> y <b>Trafficdb (videos clasificados en tráfico leve, medio y severo)</b> . Las <b>características visuales</b> incluyeron número de vehículos, velocidad, flujo de tráfico, ocupación de la carretera, y textura. | Las métricas utilizadas incluyen <b>Jaccard Index (Intersection over Union)</b> para la detección de vehículos y <b>precisión</b> para la clasificación. Los modelos basados en aprendizaje profundo alcanzaron hasta 99.9% de precisión en clasificación binaria y 98.6% en clasificación multiclase. |

| ID  | P1                                                                                                                                                                                                                  | P2                                                                                                                                                                                                                                                                                                                                       | P3                                                                                                                                                                                                                                         |
|-----|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| A18 | Se utiliza una versión mejorada de YOLOv3, denominada <b>PVIDNet</b> .                                                                                                                                              | El conjunto de datos incluye <b>imágenes de cinco tipos de vehículos</b> (ambulancias, camiones de bomberos, patrullas, autobuses y autos regulares), capturadas desde tres ángulos diferentes. Las imágenes fueron etiquetadas y procesadas con el uso de herramientas como <b>Matlab Image Labeler</b> para su entrenamiento y prueba. | Las métricas incluyen <b>precisión</b> (95%), <b>recall</b> , y <b>F-Measure</b> . Para la validación de video, se usaron las mismas métricas, logrando resultados similares.                                                              |
| A19 | Se utiliza <b>Faster R-CNN</b> para la detección de vehículos en las imágenes de CCTV.                                                                                                                              | Se utiliza un conjunto de datos de <b>imágenes de vehículos capturadas desde tres ángulos</b> (derecha, izquierda, y frente). Las imágenes incluyen ambulancias, camiones de bomberos, patrullas, autobuses y autos regulares. Las imágenes son ajustadas a un tamaño de 416 x 416 píxeles para el entrenamiento y la prueba.            | Se utilizan métricas como <b>precisión</b> (hasta el 97.5%) y <b>recall</b> . Además, se mide el rendimiento predictivo de los modelos con métricas como <b>MAE (Error Medio Absoluto)</b> y <b>RMSE (Error Cuadrático Medio)</b> .        |
| A20 | Se utilizan <b>ResNet-50</b> , <b>ResNet-101</b> , y <b>Faster R-CNN</b> en combinación para detectar vehículos en áreas de puntos ciegos.                                                                          | Se utilizaron conjuntos de datos de <b>vehículos comerciales grabados mediante cámaras instaladas</b> en los espejos laterales de autobuses. Las imágenes fueron ajustadas a 224x224 píxeles para mejorar el rendimiento del sistema y se aplicaron <b>técnicas de aumento de datos</b> .                                                | Las métricas incluyen la <b>tasa de detección positiva (TPR)</b> y la <b>tasa de falsos positivos (FDR)</b> . El sistema alcanzó un TPR del 98.72% y un FDR del 3.05%.                                                                     |
| A21 | Se utilizan los algoritmos <b>YOLOv3</b> y <b>SSD</b> para la detección de vehículos.                                                                                                                               | El procesamiento se realiza utilizando el conjunto de datos <b>BDD100K</b> , que contiene imágenes de vehículos capturadas desde varios ángulos. Las imágenes son etiquetadas y procesadas con los algoritmos YOLOv3 y SSD para la comparación de resultados.                                                                            | Se utiliza la <b>precisión media (mAP)</b> y la velocidad de procesamiento en <b>FPS</b> . YOLOv3 alcanzó un mAP del 76.1% con 50 FPS, mientras que SSD logró un mAP del 74.3% con 46 FPS.                                                 |
| A22 | Se utiliza <b>SSD</b> optimizado con <b>Focus Loss</b> para mejorar la precisión en la detección de vehículos en los videos de drones.                                                                              | Se realiza una <b>transformación de brillo</b> en el espacio HSV para adaptar las <b>imágenes a diferentes condiciones de luz</b> . El tamaño de las imágenes de entrada es de 50x50 píxeles y se recogen muestras positivas y negativas para entrenar el modelo.                                                                        | La métrica utilizada es la <b>tasa de detección de vehículos (TPR)</b> , que alcanzó el 96.49%.                                                                                                                                            |
| A23 | Se utiliza un modelo de red neuronal convolucional <b>YOLOv5</b> para la detección de vehículos, complementado con el algoritmo de seguimiento <b>DeepSORT</b> .                                                    | Se utilizan <b>grabaciones de video de cámaras de tráfico</b> en el campus de Texas A&M, procesadas con un modelo YOLOv5 preentrenado, seguido de una <b>proyección homográfica</b> para mapear la información a un plano real a escala (UTM).                                                                                           | Se utiliza la <b>precisión media (mAP)</b> del 69.6% para la detección y la <b>precisión de conteo</b> del 96.91% en la detección de volumen de tráfico.                                                                                   |
| A24 | Se utilizan <b>PSPNet</b> para segmentación semántica de las imágenes y <b>SENet</b> para la clasificación de los escenarios peligrosos relacionados con vehículos y peatones.                                      | Las imágenes se recopilan de varias fuentes, incluyendo <b>Baidu Map Street View</b> y los conjuntos de datos <b>Cityscape</b> y <b>Apollo</b> . Las imágenes se segmentan y clasifican utilizando PSPNet y SENet, y luego se identifican los escenarios de peligro relacionados con el tráfico motorizado y no motorizado.              | Se utiliza la <b>precisión</b> de clasificación (96.71%) y el <b>recall</b> para validar la detección y clasificación de escenarios peligrosos.                                                                                            |
| A25 | Se emplean <b>redes neuronales artificiales (ANN)</b> junto con características de flujo óptico denso y energía para la detección y el reconocimiento de vehículos.                                                 | Se convierte el <b>video en imágenes</b> , y luego se procesan con <b>técnicas de filtrado y extracción de características</b> (flujo óptico y energía). Además, se aplica un proceso de optimización mediante minería de grafos para seleccionar las características más relevantes.                                                    | Las métricas utilizadas incluyen <b>tasa de reconocimiento promedio</b> (93.75%) en LISA y <b>precisión</b> (82.85%) en KITTI, además de otras métricas como la <b>tasa de verdaderos positivos</b> y la <b>tasa de falsos positivos</b> . |
| A26 | Se utiliza un <b>clasificador en cascada</b> basado en características <b>LBP</b> y <b>Haar</b> para la detección de vehículos.                                                                                     | Se recopilan <b>imágenes de vehículos desde videos de dashcam y fuentes en línea</b> . Estas imágenes son etiquetadas y luego redimensionadas a 340x135 píxeles para entrenar el clasificador.                                                                                                                                           | Las métricas utilizadas incluyen la <b>precisión</b> de detección del 88.3% y la <b>velocidad de procesamiento (FPS)</b> , con 13 FPS para video y 15 FPS para cámara en la plataforma empujada.                                           |
| A27 | Se utilizan detectores basados en <b>redes neuronales profundas</b> entrenados con características estáticas y de movimiento. El modelo base seleccionado fue <b>Faster R-CNN</b> con <b>AlexNet</b> como backbone. | Se entrenaron detectores utilizando pequeños conjuntos de datos de <b>video</b> con 100 y 200 imágenes. Se procesaron tanto <b>imágenes en formato RGB</b> (para características estáticas) como <b>imágenes binarias</b> (para características de movimiento).                                                                          | Las métricas utilizadas incluyen <b>precisión</b> , <b>recall</b> , <b>F-measure</b> y <b>Kappa</b> , con una precisión superior al 95% en la mayoría de los casos.                                                                        |
| A28 | Se utiliza <b>Mask R-CNN</b> con un backbone <b>ResNet-101</b> para la detección y segmentación de vehículos.                                                                                                       | Se utilizaron imágenes de los conjuntos de datos <b>KITTI</b> y <b>BDD100K</b> , y se realizó la anotación de las máscaras utilizando la herramienta <b>VGG Image Annotator (VIA)</b> . Las imágenes fueron preprocesadas con <b>anotaciones poligonales</b> .                                                                           | Las métricas utilizadas incluyen <b>mAP</b> (90.27%), <b>mAR</b> (92.38%), <b>Jaccard Index</b> (79.85%) y <b>Dice Coefficient</b> (87.67%).                                                                                               |
| A29 | Se utilizan <b>YOLOv4</b> para la detección y <b>DeepSORT</b> para el seguimiento y clasificación de vehículos en tiempo real.                                                                                      | Se recopilan <b>imágenes de diferentes clases de vehículos</b> (coches, motocicletas, autobuses, camiones) a partir de un conjunto de datos personalizado y se etiquetan automáticamente utilizando el <b>toolkit OIDv4</b> .                                                                                                            | Las métricas incluyen <b>mAP</b> (82.08%) y la <b>velocidad de procesamiento</b> de 14 FPS en una GPU GTX 1660ti.                                                                                                                          |

| ID  | P1                                                                                                                                                                 | P2                                                                                                                                                                                                                                                                                           | P3                                                                                                                                                                             |
|-----|--------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| A30 | Se utiliza el modelo <b>YOLO</b> para la detección, clasificación y seguimiento de vehículos. También se compara con <b>K-NN</b> y <b>Faster R-CNN</b> .           | Se utilizaron <b>imágenes de tráfico obtenidas de cámaras de vigilancia</b> , que fueron etiquetadas manualmente. El modelo YOLO procesó estas imágenes para detectar y clasificar los vehículos en tiempo real.                                                                             | Se utiliza la <b>precisión promedio (AP)</b> , que fue del 90.32% para YOLO. También se comparó con Faster R-CNN (88.10%) y K-NN (82.12%).                                     |
| A31 | Se utiliza un modelo modificado YOLOv4-tiny ( <b>mYOLOv4-tiny</b> ) para la detección de vehículos en tiempo real.                                                 | Se recopilan <b>imágenes en tiempo real desde cámaras de tráfico</b> y se procesan mediante mYOLOv4-tiny para detectar vehículos. Luego, se utilizan modelos CFNN para la clasificación y seguimiento de los vehículos.                                                                      | Las métricas utilizadas incluyen <b>precisión</b> (99%), <b>mAP</b> y <b>F1 score</b> , junto con la <b>velocidad de procesamiento</b> medida en <b>FPS</b> (más de 30 FPS).   |
| A32 | Se utiliza <b>YOLOv4_AF</b> , una versión optimizada de YOLOv4, que incorpora el módulo de atención CBAM y mejoras en la red de pirámide de características (FPN). | Se utilizaron los conjuntos de datos <b>BIT-Vehicle</b> y <b>UA-DETRAC</b> , en los cuales se realizó la detección y clasificación de vehículos utilizando técnicas de aprendizaje profundo. Las imágenes fueron preprocesadas para mejorar el rendimiento en escenarios con interferencias. | Se utilizan métricas como la <b>mAP</b> (83.45%), el <b>F1 score</b> (0.816), además de <b>precisión</b> y <b>recall</b> .                                                     |
| A33 | Se utiliza una <b>red neuronal convolucional (CNN)</b> optimizada que combina datos de sensores de fibra óptica Bragg y CCTV.                                      | Se recopilan <b>datos de sensores FBG</b> y de <b>imágenes de CCTV</b> . Las imágenes se procesan y se ajustan a un tamaño específico para ser utilizadas en la CNN, mientras que los datos de los sensores se convierten en mapas de presión y se integran en el sistema híbrido.           | Se utilizan métricas de <b>precisión</b> que varían entre el 90% y el 97% según el tipo de vehículo clasificado, además de la matriz de confusión para validar los resultados. |
| A34 | Se utiliza el algoritmo de <b>XGBoost</b> para la clasificación de vehículos en tiempo real.                                                                       | El conjunto de datos <b>SRM2KTR</b> es procesado utilizando técnicas de <b>transformada random</b> y <b>wavelet</b> para la compresión de imágenes y la extracción de bordes, seguido de segmentación basada en bordes y regiones.                                                           | Las métricas utilizadas incluyen <b>precisión</b> (98.81%), <b>mAP</b> y el <b>tiempo de procesamiento</b> (0.16 ns por imagen).                                               |

Figura V


Algoritmos aplicados para la detección de vehículos analizados en las investigaciones.



Fuente: Elaboración Propia

**Figura VI**

Métricas de validación utilizadas en la detección de vehículos analizadas en las investigaciones.



Fuente: Elaboración Propia

#### IV. CONCLUSIONES

La seguridad vial es una problemática de salud pública que necesita una atención urgente, debido al creciente número de accidentes en zonas urbanas, falta de sistemas eficientes para la detección y gestión del tráfico vehicular. A través de esta presente revisión sistemática de la literatura, se proporcionó una visión amplia y actualizada de estudios relacionados a la detección de vehículos, analizando tres aspectos fundamentales los cuales son los algoritmos, enfoques de procesamiento de datos y métricas de validación utilizadas en este campo. Por lo tanto, para llevar a cabo esta revisión, se utilizaron motores de búsqueda académicos como Google Académico, PubMed, e IEEE Xplore; la cual mediante la aplicación de cadenas de palabras claves y cadenas de búsqueda, se logró filtrar las investigaciones más relevantes para este campo. Asimismo, a través de criterios de inclusión y exclusión, se seleccionaron únicamente aquellos estudios que cumplieran con lo establecido y que permitan responder a las preguntas centrales. Por lo que, permitió ofrecer una revisión actualizada y enfocada a los

desafíos específicos de la detección de vehículos en entornos urbanos. Entre los algoritmos más detectados se encuentran YOLOv5 y Faster R-CNN, demostrando ser efectivos para la detección precisa y en tiempo real de vehículos en escenarios complejos. Por lo que estos algoritmos no solo mejoran la capacidad de monitorear el tráfico, sino que también contribuyen a reducir la incidencia de accidentes, al permitir una identificación rápida de posibles peligros viales. En cuanto al procesamiento de datos, los estudios revisados han empleado conjuntos de datos propios y de fuentes públicas; es decir, algunas investigaciones utilizaron conjuntos de datos extraídos de videos de vigilancia en autopistas y ciudades, como UA-DETRAC, VisDrone, KITTI y otros creados a partir de videos grabados con drones. Además, hicieron uso de técnicas avanzadas como la superresolución y el aumento de datos que permite mejorar los resultados en la detección de vehículos pequeños y lejanos. Respecto a las métricas de validación, predomina la precisión, lo que resalta su importancia en la evaluación del rendimiento de los modelos para garantizar que las predicciones sean correctas. En consecuencia, las

investigaciones revisadas han aportado significativamente al desarrollo de tecnologías para la detección de vehículos en el tráfico urbano, sentando una base sólida para futuras investigaciones en el ámbito de la seguridad vial. No obstante, aún persisten desafíos importantes, como la integración de estos algoritmos en sistemas ya implementados por instituciones u organismos nacionales, particularmente en zonas urbanas de alta congestión como Lima Metropolitana.

## REFERENCIAS

- [1] Ahmed, M., Zaghdoud, R., Ahmed, M., Sendi, R., Alsharif, S., Alabdulkarim, J., Saad, B., Alsabt, R., Rahman, A., & Krishnasamy, G. (2023). *A Real-Time Computer Vision Based Approach to Detection and Classification of Traffic Incidents*. *Big Data Cogn. Comput.*, 7, 22. <https://doi.org/10.3390/bdcc7010022>
- [2] Ahmed, S., Mohammed, M., Abdulqadir, S., El-kader, R., El-shall, N., Chandran, D., Rehman, M., & Dhama, K. (2023). *Road traffic accidental injuries and deaths: A neglected global health issue*. *Health Science Reports*, 6. <https://doi.org/10.1002/hsr2.1240>
- [3] Alanazi, F. (2023). *A Systematic Literature Review of Autonomous and Connected Vehicles in Traffic Management*. *Applied Sciences*. <https://doi.org/10.3390/app13031789>
- [4] Ameratunga, S., Hajar, M., & Norton, R. (2006). *Road-traffic injuries: Confronting disparities to address a global-health problem*. *The Lancet*, 367, 1533-1540. [https://doi.org/10.1016/S0140-6736\(06\)68654-6](https://doi.org/10.1016/S0140-6736(06)68654-6)
- [5] Atouf, I., Okaishi, W., Zaaran, A., Slimani, I., & Benrabh, M. (2020). *A real-time system for vehicle detection with shadow removal and vehicle classification based on vehicle features at urban roads*. *International Journal of Power Electronics and Drive Systems*, 11, 2091-2098. <https://doi.org/10.11591/IJPEDS.V11.I4.PP2091-2098>
- [6] Berhanu, Y., Alemayehu, E., & Schröder, D. (2023). *Examining car accident prediction techniques and road traffic congestion: A comparative analysis of road safety and prevention of world challenges in low-income and high-income countries*. *Journal of Advanced Transportation*. <https://doi.org/10.1155/2023/6643412>
- [7] Chen, Z., Cao, L., & Wang, Q. (2022). *YOLOv5-Based Vehicle Detection Method for High-Resolution UAV Images*. *Mobile Information Systems*. <https://doi.org/10.1155/2022/1828848>
- [8] Coanqui, F. Y., Estofanero, R. F., & Mamani, H. W. (2022). *Aplicación de inteligencia y visión artificial para la obtención del aforo vehicular* (Tesis de Licenciatura, Universidad Peruana Unión).
- [9] Cueva, W. F., & Muñoz, F. S. (2017). *Análisis, monitoreo e implementación de un algoritmo para el conteo del tráfico vehicular aplicando visión artificial* (Tesis de Bachiller, Universidad del Azuay).
- [10] Goniewicz, K., Goniewicz, M., Pawłowski, W., & Fiedor, P. (2016). *Road accident rates: Strategies and programmes for improving road traffic safety*. *European Journal of Trauma and Emergency Surgery*, 42, 433-438. <https://doi.org/10.1007/s00068-015-0544-6>.
- [11] Gorea, R. (2016). *Financial impact of road traffic accidents on the society*. *The International Journal of Ethics*, 2. <https://doi.org/10.18099/IJETV.V2I1.11129>
- [12] Guzmán-Torres, J. A., Domínguez-Mota, F. J., Tinoco-Guerrero, G., García-Chiquito, M. C., & Tinoco-Ruiz, J. G. (2024). *Efficacy evaluation of You Only Learn One Representation (YOLOR) algorithm in detecting, tracking, and counting vehicular traffic in real-world scenarios, the case of Morelia México: An artificial intelligence approach*. *AI (Basel, Switzerland)*, 5(3), 1594–1613. <https://doi.org/10.3390/ai5030077>
- [13] Kazmi, S. S., Shamshad, S., Nasim, F., Hashim, S., Azam, N., & Ambar, B. (2024). *Real-Time Vehicle Detection with Advanced Machine Learning Algorithms*. *Journal of Computing & Biomedical Informatics*, 7(02). <https://doi.org/10.56979/702/2024>
- [14] Kitchenham, B., Brereton, O. P., Budgen, D., Turner, M., Bailey, J., & Linkman, S. (2009). *Systematic literature reviews in software engineering—a systematic literature review*. *Information and software technology*, 51(1), 7-15.
- [15] Klinjun, N., Kelly, M., Praditsathaporn, C., & Petsirasan, R. (2021). *Identification of factors affecting road traffic injuries incidence and severity in southern Thailand based on accident investigation reports*. *Sustainability*. <https://doi.org/10.3390/su132212467>

- [16] Kuchewar, S., Meshram, R., & Gadge, S. (2012). *Demographic study and medico-legal aspect of fatal road traffic accident in Aurangabad*. Journal of Life Sciences, 4, 10-7. <https://doi.org/10.1080/09751270.2012.11885188>
- [17] Mandal, V. (2019). *Artificial intelligence enabled automatic traffic monitoring system* (Tesis de Maestría, University of Missouri-Columbia).
- [18] Martínez, S., Sánchez, R., & Yañez-Pagans, P. (2018). *Road safety: Challenges and opportunities in Latin America and the Caribbean*. Latin American Economic Review, 28, 1-30. <https://doi.org/10.1186/S40503-019-0078-0>
- [19] Moshayedi, A., Roy, A., Taravet, A., Liao, L., Wu, J., & Gheisari, M. (2023). *A Secure Traffic Police Remote Sensing Approach via a Deep Learning-Based Low-Altitude Vehicle Speed Detector through UAVs in Smart Cities: Algorithm, Implementation and Evaluation*. Future Transportation. <https://doi.org/10.3390/futuretransp3010012>
- [20] Mustaqim, M. F., Nugroho, A., & Suni, A. F. (2021). *Sistem Deteksi Kecepatan Kendaraan Menggunakan Metode Haar Cascade untuk Keamanan Berkendara*. Edu Elekrika Journal, 10(2), 30-34. <https://doi.org/10.15294/eej.v10i2.47870>
- [21] Musunuri, Y., Kwon, O., & Kung, S. (2022). *SRODNet: Object Detection Network Based on Super Resolution for Autonomous Vehicles*. Remote. Sens., 14, 6270. <https://doi.org/10.3390/rs14246270>
- [22] Nasution, S. M., Husni, E., Kuspriyanto, K., & Yusuf, R. (2023). *Heterogeneous Traffic Condition Dataset Collection for Creating Road Capacity Value*. Big Data Cogn. Comput., 7, 40. <https://doi.org/10.3390/bdcc7010040>
- [23] Nguyen, H. (2021). *Multiscale Feature Learning Based on Enhanced Feature Pyramid for Vehicle Detection*. Complex., 2021, 5555121:1-5555121:10. <https://doi.org/10.1155/2021/5555121>
- [24] Pan, D. (2021). *From Artificial Intelligence to Traffic Analysis: Automatic Video Detection and Tracking of Cyclists, Pedestrians, Mopeds and Vehicles* (Tesis de Maestría, The George Washington University).
- [25] Peña, J. M. Y. (2017). *Sistema de detección y conteo de vehículos utilizando visión artificial* (Tesis de Grado, Universidad Nacional de Piura).
- [26] Pérez, J. (2019). *Análisis de tráfico vehicular mediante visión artificial* (Tesis de Maestría, Universidad Técnica de Ambato. Facultad de Ingeniería en Sistemas, Electrónica e Industrial. Maestría en Automatización y Sistemas de Control).
- [27] Quistberg, D., Koepsell, T., Boyle, L., Miranda, J., Johnston, B., & Ebel, B. (2014). *Pedestrian signalization and the risk of pedestrian-motor vehicle collisions in Lima, Peru*. Accident; Analysis and Prevention, 70, 273-81. <https://doi.org/10.1016/j.aap.2014.04.012>
- [28] Sleet, D., & Branche, C. (2004). *Road safety is no accident*. Journal of Safety Research, 35(2), 173-4. <https://doi.org/10.1016/J.JSR.2004.03.007>
- [29] Švorc, D., Tichý, T., & Růžicka, M. (2021). *An infrared video detection and categorization system based on machine learning*. Neural Network World. <https://doi.org/10.14311/nnw.2021.31.014>
- [30] Wegman, F. (2017). *The future of road safety: A worldwide perspective*. IATSS Research, 40, 66-71. <https://doi.org/10.1016/J.IATSSR.2016.05.003>
- [31] Xu, C., Wang, G., Yan, S., Yu, J., Zhang, B., Dai, S., Li, Y., & Xu, L. (2020). *Fast Vehicle and Pedestrian Detection Using Improved Mask R-CNN*. Mathematical Problems in Engineering, 2020, 1-15. <https://doi.org/10.1155/2020/5761414>
- [32] Yusof, N., Sophian, A., Zaki, H., Bawono, A., Embong, A., & Ashraf, A. (2024). *Assessing the performance of YOLOv5, YOLOv6, and YOLOv7 in road defect detection and classification: a comparative study*. Bulletin of Electrical Engineering and Informatics. <https://doi.org/10.11591/eei.v13i1.6317>
- [33] Zhang, F., Li, C., & Yang, F. (2019). *Vehicle Detection in Urban Traffic Surveillance Images Based on Convolutional Neural Networks with Feature Concatenation*. Sensors (Basel, Switzerland), 19. <https://doi.org/10.3390/s19030594>
- [34] Zhang, Y., Guo, Z., Wu, J., Tian, Y., Tang, H., & Guo, X. (2022). *Real-Time Vehicle Detection Based on Improved YOLO v5*. Sustainability. <https://doi.org/10.3390/su141912274>
- [35] Zhang, Y., Sun, Y., Wang, Z., & Jiang, Y. (2023). *YOLOv7-RAR for Urban Vehicle Detection*. Sensors (Basel, Switzerland), 23. <https://doi.org/10.3390/s23041801>

- [36] Zulkhairi, M., Mustafah, Y., Abidin, Z., Zaki, H., & Rahman, H. (2019). *Car Detection Using Cascade Classifier on Embedded Platform*. 2019 7th International Conference on Mechatronics Engineering (ICOM), 1-3. <https://doi.org/10.1109/ICOM47790.2019.8952064>
- [37] Zuraimi, M., & Zaman, F. (2021). *Vehicle Detection and Tracking using YOLO and DeepSORT*. 2021 IEEE 11th IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE), 23-29. <https://doi.org/10.1109/ISCAIE51753.2021.9431784>

**Financiamiento:**

Propia.

**Conflictos de interés:**

Los autores declaran no tener conflictos de interés

**Contribuciones de autoría:**

Luz Elena Torres Talaverano: Introducción, Metodología, Desarrollo de la Metodología y Redacción.

Ciro Rodriguez Rodriguez: Asesoramiento, Revisión y Redacción.

Pedro Martin Lezama Gonzales: Asesoramiento, Revisión y Redacción.

Ivan Carlo Petrlik Azabache: Conclusiones, Revisión y Redacción.