

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

<https://doi.org/10.35381/i.p.v8i15.5199>

Detección vehicular con yolov11l para estimación del factor de hora pico

Vehicle Detection Using YOLOv11L to Estimate the Rush Hour Factor

Marco Antonio Tacuri-Rivas

mtacuri@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador

<https://orcid.org/0000-0002-7466-8076>

José Luis Ordóñez-Fernández

jlordonez@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador

<https://orcid.org/0000-0002-4314-1319>

Hiroe Naomi Ordóñez-Barreto

hiroeorba@gmail.com

Unidad Educativa Juana de Dios, Machala, El Oro
Ecuador

<https://orcid.org/0009-0002-1746-1017>

Kevin Edú Naranjo-Zumba

Kevin.naranjo@est.umet.edu.ec

Universidad Metropolitana, Machala, El Oro
Ecuador

<https://orcid.org/0009-0009-1645-414X>

Recibido: 02 de abril 2026

Revisado: 03 de mayo 2026

Aprobado: 15 de junio 2026

Publicado: 01 de julio 2026

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

RESUMEN

Este estudio tuvo como objetivo evaluar la efectividad de un sistema automatizado de aforo vehicular basado en inteligencia artificial para la determinación del volumen y factor horario de máxima demanda. Metodológicamente, se implementó un sistema de visión por computadora utilizando el algoritmo YOLOv11l para la detección y clasificación vehicular, procesando secuencias de video de 12 horas diarias (06:00–18:00) durante 7 días consecutivos. Con respecto a los resultados, el VHMD registrado fue de 1,698 vehículos (Día 2, entre 17:00–18:00), con un FHP que varió entre 0.65 y 0.84 según el día analizado. En conclusión, el sistema de aforo vehicular automatizado constituye una herramienta confiable y eficiente para la determinación del volumen y factor horario de máxima demanda, superando las limitaciones de los métodos manuales tradicionales y proporcionando información detallada sobre los patrones de movilidad en diferentes días de la semana.

Descriptores: Automatización; planificación del transporte; vehículo automotor; inteligencia artificial; análisis estadístico (Tesauro UNESCO)

ABSTRACT

The objective of this study was to evaluate the effectiveness of an automated vehicle counting system based on artificial intelligence for determining traffic volume and the peak-hour demand factor. Methodologically, a computer vision system using the YOLOv11l algorithm was implemented for vehicle detection and classification, processing video sequences of 12 hours per day (6:00 a.m.–6:00 p.m.) for 7 consecutive days. Regarding the results, the recorded VHMD was 1,698 vehicles (Day 2, between 5:00 PM–6:00 PM), with an FHP ranging from 0.65 to 0.84 depending on the day analyzed. In conclusion, the automated vehicle counting system is a reliable and efficient tool for determining traffic volume and the peak-hour factor, overcoming the limitations of traditional manual methods and providing detailed information on mobility patterns on different days of the week.

Descriptors: Automation; transportation planning; motor vehicle; artificial intelligence; statistical analysis. (UNESCO Thesaurus)

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

INTRODUCCIÓN

El crecimiento poblacional y el incremento del parque automotor han generado importantes desafíos en la gestión del tráfico y la planificación de infraestructura vial; como consecuencia la congestión vehicular y los accidentes de tráfico se están convirtiendo en problemas sociales que demandan soluciones basadas en información precisa sobre los patrones de movilidad vehicular (Ahn & Lee, 2022). Este rápido aumento del número de vehículos ha provocado un incremento de la congestión del tráfico, los accidentes de tráfico y los delitos relacionados con vehículos a motor (Bai et al., 2024). Por lo tanto, es importante investigar cómo afecta en los patrones de viaje y la planificación urbana el comportamiento del flujo de vehículos en las vías e intersecciones en las horas de máxima demanda (Zhou et al., 2022).

La congestión del tránsito es un problema común en varias ciudades latinoamericanas, ya que dificulta la movilidad urbana. En Cali, se propuso una solución digital que usa algoritmos genéticos para hallar las mejores localizaciones posibles de servicios oncológicos, con el fin de facilitar su acceso (Cuervo et al., 2024).

En los últimos años la inteligencia artificial está siendo muy utilizada en muchas disciplinas; particularmente la clasificación y el seguimiento preciso de vehículos son temas cada vez más importantes para los sistemas de transporte inteligentes (ITS) y para la planificación que utiliza información de localización precisa (Neupane et al., 2022). Los enfoques de aprendizaje profundo, en particular las redes neuronales convolucionales, han demostrado un rendimiento excepcional en diversas aplicaciones de visión artificial Alawaji et al. (2024).

En los últimos años, la detección y clasificación de vehículos se ha convertido en una de las principales tareas en los sistemas de transporte inteligente, ya que la detección y clasificación de objetos basados en visión por computadora sigue siendo un reto para resolver problemas de tráfico (Avianto et al., 2022; Berwo et al., 2023; Mahum et al., 2026). Esta es una tarea compleja en el procesamiento de imágenes, ya que implica

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

clasificar diversos vehículos según su color, modelo y marca. El uso de la inteligencia artificial no solo se limita a ejecutar tareas mecánicas, sino que va más allá (Gonzalez, 2025); como es el uso de un recurso pedagógico que tributa al mejoramiento de la calidad de vida, la efectividad y la innovación pedagógica (Gonzalez, 2025). En este contexto, no solo se pretende que la inteligencia artificial sea eficiente en términos tecnológicos, sino también que su uso sea ético y no atente contra los derechos fundamentales (Dávila Romero et al., 2025).

En la ingeniería vial, la aplicación de la inteligencia artificial en la predicción precisa y oportuna del flujo de tráfico desempeña un papel crucial en la mejora de la utilización de las carreteras, la reducción de la congestión y la optimización de la gestión del transporte público (Pan et al., 2025; Ye et al., 2022; J. Zhang et al., 2025). Esta predicción se la puede estimar realizando aforos vehiculares, los cuales permiten calcular diferentes parámetros como el volumen y factor horario de máxima demanda, los cuales contribuyen en gran medida al dimensionamiento geométrico de vías y planificación del transporte público. En particular el factor horario de máxima demanda (factor de hora pico) se lo evalúa con flujos horarios en intervalos de 5, 10 o 15 minutos. Este factor de hora pico, mide la variabilidad de vehículos dentro de la hora de máxima demanda, y se expresa como.

$$FHP = \frac{VHMD}{12V_5} \quad [1]$$

donde VHMD es el volumen horario de máxima demanda y V_5 es el volumen máximo en un intervalo de 5 minutos dentro de la hora pico.

A continuación, se presentan algunas investigaciones realizadas en el campo de la ingeniería de tráfico usando el algoritmo de clasificación YOLO.

Yu et al. (2024) propusieron ETS-YOLOv7, una mejora de YOLOv7 para tráfico, que integra CBAM para filtrar características clave, WIoUv3 para manejar variaciones de

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

escala y CLAN para reducir cómputo. Validado en UA-DETRC, logró un mAP del 90,2% (un 3% más que YOLOv7) y 149 FPS, superando a otros métodos en precisión y eficiencia.

H. Zhang et al. (2025) utilizaron un algoritmo de detección mejorado (YOLO-BS) basado en YOLOv8 (You Only Look Once versión 8) para la detección de señales de tránsito. Este algoritmo aborda los desafíos de los fondos complejos y los objetivos de detección de pequeño tamaño en las imágenes de señales de tráfico.

Chaman et al. (2026) proporcionaron una comparación justa y reproducible de las últimas arquitecturas YOLO para determinar su idoneidad para subsistemas de percepción críticos, incluidos el Reconocimiento de Señales de Tráfico (TSR), Sistemas de Detección de Peatones (PDS), Sistemas de Detección de Vehículos (VDS), Sistemas de Prevención de Colisiones (CAS) y Asistencia Inteligente de Velocidad (ISA).

El propósito de la presente investigación es determinar el volumen y factor horario de máxima demanda correspondientes a los siete días de la semana. Estos datos se los obtuvo usando inteligencia artificial, específicamente se valió de la visión por computadora y redes neuronales convolucionales, eligiendo el algoritmo YOLO tanto para la detección, conteo y clasificación de vehículos.

Finalmente, es necesario mencionar que este artículo constituye uno de los capítulos centrales de la tesis doctoral del firmante, por lo que sus conclusiones serán posteriormente integradas en el marco general de aquel trabajo de mayor envergadura.

MÉTODO

Esta investigación se sustenta en los hallazgos preliminares de un manuscrito sometido a revisión en la revista Springer Nature, titulado: "Optimización de la Clasificación Vehicular en Escenarios de Tráfico Real: Evaluación de YOLOv11l bajo un Dataset de Perspectivas Integrales"; el cual constituye uno de los objetivos específicos para la tesis doctoral en progreso titulada: "Inteligencia artificial en el aforo vehicular para la estimación

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

del tránsito promedio diario anual". Con base en dicho manuscrito, el presente estudio (1) reutiliza el dataset previamente construido, (2) aplica el mismo modelo YOLOv11l, pero (3) extiende el análisis hacia la determinación del volumen y factor horario de máxima demanda, lo cual también contribuye a la estimación del tránsito promedio diario anual.

Brevemente, dicho dataset fue construido a partir de imágenes extraídas de grabaciones realizadas desde tres posiciones de la cámara: cercana, intermedia y lejana, con el objetivo de capturar vehículos a diferentes distancias y escalas. Esta diversidad de perspectivas permite que el modelo YOLOv11l aprenda representaciones robustas de los vehículos independientemente de su tamaño en la imagen, mejorando la detección en escenarios reales donde los vehículos pueden aparecer en primer plano o al fondo de la escena.

El dataset incluye nueve clases de vehículos: moto, auto, suv, camioneta, van, bus, volqueta, vehículos ligeros (camiones pequeños, medianos, cabezales) y vehículos pesados (camiones grandes, mixer, tráiler), etiquetadas manualmente en formato YOLO mediante la herramienta LabelImg. El dataset se dividió en: 70% entrenamiento, 20% validación y 10% prueba.

Las grabaciones se realizaron con una cámara Dahua con resolución 3840x2160 píxeles y una tasa de 30 fps. El procesamiento se ejecutó en una laptop ASUS con procesador Intel Core i9, 64 GB de RAM y una GPU NVIDIA QUADRO RTX 6000 con 24 GB de memoria dedicada. El desarrollo del software se realizó en Python 3.10, utilizando las librerías Ultralytics (YOLO), OpenCV, NumPy y Pandas.

Tomando como base lo expuesto anteriormente, el procesamiento del video se realizó en los siguientes pasos:

- Configuración: definición del día a procesar, selección del intervalo de tiempo y establecer línea de conteo.
- Procesamiento de cada frame del video:

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

Para el procesamiento de cada frame se desarrolló una aplicación en Python que integra el modelo YOLOv11l previamente entrenado y funciones diseñadas por los autores. El flujo de procesamiento es el siguiente:

- a) **Lectura de frames:** El video se procesa frame por frame, extrayendo 4 frames por segundo para reducir el costo computacional, manteniendo una resolución de 3840x2160 píxeles, con el fin de evitar imágenes excesivamente similares que puedan inducir al modelo a memorizar en lugar de generalizar para diferentes modelos de vehículos pertenecientes a la misma clase.
- b) **Detección de vehículos:** Sobre cada frame seleccionado, el modelo YOLOv11l realiza la detección de objetos. Se consideran válidas únicamente las detecciones con un umbral de confianza ≥ 0.5 , y se aplica Non-Maximum Suppression (NMS) con un umbral de 0.5 para eliminar detecciones redundantes.
- c) **Clasificación por clase:** Las detecciones válidas se clasifican en las 9 categorías especificadas anteriormente.
- d) **Conteo y agrupación horaria:** Para evitar el doble conteo de un mismo vehículo en frames consecutivos, se implementó un algoritmo de seguimiento (tracking) basado en Intersection over Union (IoU) (proporcionado por el mismo modelo YOLO), que asigna un identificador único a cada vehículo mientras permanece en el campo de visión. El conteo se realiza estableciendo una línea virtual de detección en un punto fijo del frame (aproximadamente a la mitad de la calzada), de modo que cuando el centroide del vehículo cruza dicha línea, el vehículo es contabilizado y clasificado. Este método evita conteos duplicados de vehículos que permanecen estáticos o que se mueven lentamente dentro del campo de visión.
- e) **Almacenamiento de datos:** Los resultados se almacenan simultáneamente en una matriz y se exportan a una hoja de cálculo en formato Excel, como medida de contingencia ante posibles interrupciones del sistema eléctrico, garantizando la integridad de la información.

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

f) **Cálculo de indicadores:** A partir de la matriz de conteos horarios, se calculan los siguientes indicadores de tráfico:

- Volumen Horario de Máxima Demanda (VHMD): la hora con el mayor número total de vehículos.
- Intervalo pico de 5 minutos: el intervalo de 5 minutos con mayor flujo dentro de la hora VHMD.
- Factor Horario Pico (FHP): $FHP = VHMD / (4 \times Q_{5min})$, donde Q_{5min} es el flujo máximo en 5 minutos.

El rango horario de 06:00 a 18:00 se seleccionó porque coincide con la jornada laboral y escolar típica, franja en la que se concentra la mayor parte del flujo vehicular y donde suele presentarse el VHMD en entornos urbanos.

RESULTADOS

Los resultados del procesamiento de los siete días de aforo se resumen en la Tabla 1, donde se incluyen: el total de vehículos contabilizados por día (Total día), el volumen horario de máxima demanda (VHMD) con su respectivo rango horario, el intervalo de 5 minutos con mayor flujo dentro de esa hora (Intervalo pico) y el factor horario pico (FHP).

Tabla 1

Volumen horario de máxima demanda (VHMD) y factor de hora pico (FHP).

Día	Total día	VHMD	Rango horario	Intervalo pico	FHP
Día 1	15510	1407	14:00–15:00	14:55–15:00	0.81
Día 2	16152	1698	17:00–18:00	17:30–17:35	0.82
Día 3	11023	1413	17:00–18:00	17:40–17:45	0.84
Día 4	7536	964	15:00–16:00	15:05–15:10	0.66
Día 5	7570	916	17:00–18:00	17:40–17:45	0.65
Día 6	5227	576	17:00–18:00	17:50–17:55	0.73
Día 7	3235	413	16:00–17:00	16:00–16:05	0.65

Elaboración: Los autores.

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

La Tabla 1 revela una clara diferencia entre días laborables y fines de semana, con volúmenes totales que oscilan entre 15,510 y 7,536 vehículos para los primeros, y entre 5,227 y 3,235 para los segundos. El VHMD más alto se registró en el Día 2 (1,698 vehículos/hora), coincidiendo con el mayor volumen diario (16,152). No obstante, el Día 3 presenta un VHMD similar (1,413) con un total diario significativamente menor (11,023), lo que sugiere que la intensidad de la hora pico no depende exclusivamente del volumen total diario.

Los intervalos pico de 5 minutos se concentran mayoritariamente entre las 17:30 y las 18:00, excepto en los Días 1 y 4, donde ocurren a las 14:55–15:00 y 15:05–15:10, respectivamente. El FHP varía entre 0.65 y 0.84, indicando que en todos los días existe una concentración significativa del tráfico en pocos minutos. Los valores más bajos (Día 4: 0.66; Día 5: 0.65; Día 7: 0.65) reflejan una demanda altamente concentrada, mientras que el valor más alto (Día 3: 0.84) sugiere una distribución más uniforme dentro de la hora pico, lo cual tiene implicaciones para la gestión del tránsito y la sincronización semafórica.

DISCUSION

Los resultados obtenidos demuestran que el sistema automatizado basado en YOLOv11l es altamente efectivo para la determinación del volumen y factor horario de máxima demanda en escenarios de tráfico real. La implementación de un dataset con nueve clases vehiculares capturadas desde tres posiciones distintas (cercana, intermedia y lejana), junto con un algoritmo de seguimiento basado en IoU, ha permitido obtener mediciones precisas y detalladas del flujo vehicular durante los siete días de aforo.

Comparación con estudios previos

En los últimos años, el algoritmo YOLO (You Only Look Once) ha sido ampliamente utilizado para la detección y clasificación vehicular en sistemas de transporte inteligente.

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

Yu et al. (2024) propusieron ETS-YOLOv7, una mejora de YOLOv7 para tráfico, que integra CBAM para filtrar características clave, WIoUv3 para manejar variaciones de escala y CLAN para reducir cómputo, logrando un mAP del 90.2% en el dataset UA-DETRC, con una velocidad de procesamiento de 149 FPS. H. Zhang et al. (2025) desarrollaron YOLO-BS, una versión mejorada de YOLOv8 para la detección de señales de tránsito en fondos complejos. Chaman et al. (2026) proporcionaron una comparación reproducible de las últimas arquitecturas YOLO para subsistemas de percepción críticos, incluyendo sistemas de detección de vehículos.

En el ámbito del conteo y clasificación vehicular, estudios previos han reportado resultados variables según la arquitectura utilizada, el número de clases y las condiciones de captura. Berwo et al. (2023) lograron una precisión del 87% en detección vehicular con YOLOv5 en condiciones de baja iluminación. Mahum et al. (2026) alcanzaron un mAP del 94.9% con YOLO-O en el dataset COCO. Avianto et al. (2022) obtuvieron precisiones del 98.73% en clasificación de vehículos con CNN y aprendizaje multitarea, aunque con un número reducido de clases.

Análisis del Factor Horario Pico (FHP)

Los valores de FHP obtenidos (0.65-0.84) indican que, en todos los días analizados, existe una concentración significativa del tráfico en pocos minutos dentro de la hora pico. El FHP más alto (Día 3: 0.84) sugiere una demanda relativamente uniforme durante la hora pico, mientras que los valores más bajos (Día 5 y 7: 0.65) reflejan un alta.

Patrones de movilidad

La diferencia entre días laborables (FHP: 0.65-0.84) y fines de semana (FHP: 0.65–0.73) refleja patrones de movilidad distintos, consistentes con los hallazgos de Zhou et al. (2022), quienes demostraron que los patrones de viaje difieren significativamente entre horas pico y días de la semana. En nuestro estudio, los volúmenes totales de los fines de semana (Día 6: 5227; Día 7: 3235) representan entre el 32% y el 48% del volumen de los

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

días laborables (15510-16152), lo que confirma la fuerte dependencia del tráfico vehicular de la actividad laboral y educativa.

Implicaciones prácticas

Los resultados de este estudio tienen aplicaciones concretas para la planificación y gestión del tránsito urbano:

Sincronización semafórica: Los intervalos pico de 5 minutos identificados (ej. Día 2: 17:30–17:35) permiten ajustar los tiempos de los semáforos para aliviar la congestión en los momentos críticos.

Planificación vial: La identificación del VHMD y su rango horario (ej. Día 1: 14:00–15:00) orienta la asignación de recursos de control de tráfico (agentes, señalización temporal).

Modelos de estimación del TPDA: La integración de estos datos con otras fuentes (clima, eventos especiales) puede mejorar la precisión de los modelos de estimación del tránsito promedio diario anual.

Limitaciones del estudio

Este estudio presenta algunas limitaciones que deben considerarse:

- **Muestreo temporal:** El análisis se limitó a 7 días consecutivos, lo que no capta variaciones estacionales o por eventos especiales (feriados, lluvias intensas, accidentes).
- **Área geográfica:** Los resultados corresponden a una única vía en ciudad, por lo que su generalización a otros contextos debe hacerse con cautela.

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

- **Condiciones climáticas:** No se analizó el impacto de condiciones climáticas adversas (lluvia, niebla) en el rendimiento del modelo, lo que podría afectar la precisión de la detección.
- **Clases de vehículos:** Si bien se incluyeron nueve clases, algunas categorías (vehículos ligeros y pesados) agrupan múltiples tipos, lo que podría ocultar variaciones dentro de cada grupo.

Trabajo futuro

Las líneas futuras de investigación incluyen:

- **Extensión temporal:** Ampliar el muestreo a varios meses para captar estacionalidad y eventos atípicos.
- **Comparación de modelos:** Evaluar el rendimiento de otras arquitecturas (YOLOv8, YOLOv9, RT-DETR) para determinar la más eficiente para aforo vehicular.
- **Integración con otros sensores:** Combinar la visión artificial con sensores inductivos (espiras) o radar para validación cruzada.
- **Entrenamiento con condiciones adversas:** Aumentar el dataset con imágenes nocturnas y con lluvia para mejorar la robustez.
- **Estimación del TPDA:** Utilizar los datos de aforo para calibrar modelos de estimación del tránsito promedio diario anual, conectando directamente con el objetivo general de la tesis doctoral en curso.

CONCLUSIONES

Finalmente, se sintetizan las conclusiones más relevantes extraídas del estudio, las cuales integran los hallazgos principales y su contribución al campo del aforo vehicular automatizado, así como su proyección hacia la estimación del Tránsito Promedio Diario Anual (TPDA) en el marco de la tesis doctoral en desarrollo.

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

1. Los valores de FHP (0.65–0.84) revelan una alta concentración del tráfico en intervalos de 5 minutos dentro de la hora pico, especialmente en días laborables entre las 17:00 y 18:00.
2. La inclusión de tres perspectivas (cercana, intermedia y lejana) en el dataset mejora la robustez del modelo frente a variaciones de escala y ángulo, lo cual es crítico para su aplicación en entornos urbanos no controlados.
3. Los resultados permiten optimizar la sincronización semafórica y la planificación de recursos de control de tránsito en los momentos y días de mayor demanda.
4. Este estudio constituye un avance empírico y metodológico dentro de la tesis doctoral, sentando las bases para la estimación del Tránsito Promedio Diario Anual (TPDA) mediante inteligencia artificial.

CONFLICTO DE INTERÉS

Los autores declaran que no tienen conflicto de interés en la publicación de este artículo.

FINANCIAMIENTO

No monetario.

AGRADECIMIENTO

A todos los actores sociales involucrados en el desarrollo de la investigación.

REFERENCIAS CONSULTADAS

Ahn, H., & Lee, Y. H. (2022). Vehicle Classification and Tracking Based on Deep Learning. *Journal of Web Engineering*, 21(4), 1283–1294. <https://doi.org/10.13052/jwe1540-9589.21412>

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

- Alawaji, K., Hedjar, R., & Zuair, M. (2024). Traffic Sign Recognition Using Multi-Task Deep Learning for Self-Driving Vehicles. *Sensors*, 24(11). <https://doi.org/10.3390/s24113282>
- Avianto, D., Harjoko, A., & Afiahayati. (2022). CNN-Based Classification for Highly Similar Vehicle Model Using Multi-Task Learning. *Journal of Imaging*, 8(11). <https://doi.org/10.3390/jimaging8110293>
- Bai, T., Luo, J., Zhou, S., Lu, Y., & Wang, Y. (2024). Vehicle-Type Recognition Method for Images Based on Improved Faster R-CNN Model. *Sensors*, 24(8), 1–14. <https://doi.org/10.3390/s24082650>
- Berwo, M. A., Khan, A., Fang, Y., Fahim, H., Javaid, S., Mahmood, J., Abideen, Z. U., & M.S, S. (2023). Deep Learning Techniques for Vehicle Detection and Classification from Images/Videos: A Survey. *Sensors*, 23(10), 1–35. <https://doi.org/10.3390/s23104832>
- Chaman, M., Maliki, A. El, Dahou, H., & Hadjoudja, A. (2026). Benchmarking YOLO-based deep learning models for real-time object detection in hybrid ADAS and intelligent transportation systems. *Results in Engineering*, 29(October 2025), 108942. <https://doi.org/10.1016/j.rineng.2025.108942>
- Cuervo, L. G., Villamizar, C. J., Cuervo, D., Zapata, P., Ospina, M. B., Valencia, S. M., Polo, A., Suárez, Á., Bula, M. O., & Miranda, J. J. (2024). *Improving accessibility to radiotherapy services in Cali , Colombia : cross - sectional equity analyses using open data and big data travel times from 2020*. 1–27. <https://doi.org/10.1186/s12939-024-02211-6>
- Dávila Romero, C., Winy, M. V., Nivin Vargas, L., & Medina Villacorta, A. (2025). Inteligencia artificial, prueba judicial y el impacto en el derecho de defensa en el Perú. *Revista de La Fundación Koinomia*. <https://doi.org/https://doi.org/10.35381/r.k.v11i21.4997>
- Gonzalez, M. (2025). Desafíos y beneficios del uso de inteligencia artificial en docentes de educación secundaria: Revisión sistemática. *Revista de La Fundación Koinomia*. <https://doi.org/http://doi.org/10.59659/revistatribunal.v5i11.153>
- Mahum, R., Irshad, U., El-Sherbeeney, A. M., Shehab, M., & Lee, S. M. (2026). YOLO-O: An Improved YOLO-Based Framework for Vehicle Detection. *IET Image Processing*, 20(1). <https://doi.org/10.1049/ipr2.70337>

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

- Neupane, B., Horanont, T., & Aryal, J. (2022). Real-Time Vehicle Classification and Tracking Using a Transfer Learning-Improved Deep Learning Network. *Sensors*, 22(10), 1–21. <https://doi.org/10.3390/s22103813>
- Pan, Y. A., Li, F., Li, A., Niu, Z., & Liu, Z. (2025). Urban intersection traffic flow prediction: A physics-guided stepwise framework utilizing spatio-temporal graph neural network algorithms. *Multimodal Transportation*, 4(2), 100207. <https://doi.org/10.1016/j.multra.2025.100207>
- Yan, G., & Chen, Y. (2021). The Application of Virtual Reality Technology on Intelligent Traffic Construction and Decision Support in Smart Cities. *Wireless Communications and Mobile Computing*, 2021. <https://doi.org/10.1155/2021/3833562>
- Ye, J., Xue, S., & Jiang, A. (2022). Attention-based spatio-temporal graph convolutional network considering external factors for multi-step traffic flow prediction. *Digital Communications and Networks*, 8(3), 343–350. <https://doi.org/10.1016/j.dcan.2021.09.007>
- Yu, D., Yuan, Z., Wu, X., Wang, Y., & Liu, X. (2024). Real-Time Monitoring Method for Traffic Surveillance Scenarios Based on Enhanced YOLOv7. *Applied Sciences (Switzerland)*, 14(16). <https://doi.org/10.3390/app14167383>
- Zhang, H., Liang, M., & Wang, Y. (2025). YOLO-BS: a traffic sign detection algorithm based on YOLOv8. *Scientific Reports*, 15(1), 1–11. <https://doi.org/10.1038/s41598-025-88184-0>
- Zhang, J., Cheng, J., & Li, F. (2025). Traffic flow prediction based on temporal attention and multi-graph adjacency fusion using DynamicChebNet. *Scientific Reports*, 15(1), 1–16. <https://doi.org/10.1038/s41598-025-12598-z>
- Zhou, Y., He, Z., Chen, J. Y., Ni, L., & Dong, J. (2022). Investigating Travel Flow Differences between Peak Hours with Spatial Model with Endogenous Weight Matrix Using Automatic Vehicle Identification Data. *Genetics Research*, 2022. <https://doi.org/10.1155/2022/7729068>

Marco Antonio Tucari-Rivas; José Luis Ordóñez-Fernández; Hiroe Naomi Ordoñez-Barreto; Kevin Edú Naranjo-Zumba

©2026 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>)