

Una Revisión Sistemática de Literatura de Implementaciones de Sistemas de Control de Tráfico

Eduardo Rodrigo Wong Leon
2019100646@ucss.pe
<https://orcid.org/0009-0000-6544-9114>
Universidad Católica Sedes Sapientiae, Perú

Marco Antonio Coral Ygnacio
mcoral@ucss.edu.pe
<https://orcid.org/0000-0001-6628-1528>
Universidad Católica Sedes Sapientiae, Perú

Recibido:30/11/2023
Aceptado:14/02/2024

Resumen

La congestión vehicular es una problemática que se manifiesta frecuentemente en ciudades con alta población y puede deberse a diversos factores como la mala planificación civil o transporte público deficiente. Esto provoca un incremento en los accidentes de tránsito, la contaminación del aire, la pérdida de combustible y el descontento ciudadano. Es por ello que se considera importante la implementación de sistemas de control de tráfico que genere fluidez en el tránsito vehicular y reduzca los tiempos de viaje. Este trabajo desarrolla una revisión sistemática de literatura con el propósito de identificar los métodos, algoritmos y modelos más eficientes para la construcción de un sistema de control de tráfico. Los resultados identifican tres métodos y tres algoritmos considerados muy eficientes para el desarrollo de estos sistemas de los cuales se resaltan el filtro bayesiano y las redes neuronales convolucionales. También se demuestra que You Only Look Once conocido como YOLO es el modelo de procesamiento de imagen más eficiente para estas implementaciones.

Palabras clave: *control de tráfico, métodos, algoritmos, modelos, YOLO, implementaciones.*

Abstract

Traffic congestion is a recurrent problem in cities with high population and may be due to various factors such as poor civil planning or deficient public transportation. This causes an increase in traffic accidents, air pollution, fuel loss and citizen discontent. That is why it is considered important to implement traffic control systems that generate fluidity in vehicular traffic and reduce travel times. This work develops a systematic literature review with the purpose of identifying the most efficient methods, algorithms and models for the construction of a traffic control system. The results identify three methods and three algorithms considered very efficient for the development of these systems of which the Bayesian filter and convolutional neural networks are highlighted.

It is also shown that You Only Look Once known as YOLO is the most efficient image processing model for these implementations.

Keywords: *traffic control, methods, algorithms, models, YOLO, implementations.*

Cómo citar:

Wong Leon, E. R., & Coral Ygnacio, M. A. (2024). Una Revisión Sistemática de Literatura de Implementaciones de Sistemas de Control de Tráfico. *Interfases*, 19, e6779. <https://doi.org/10.26439/interfases2024.n19.6779>

1. Introducción

La congestión vehicular se manifiesta muchas veces en ciudades en desarrollo, con poco avance o inversión en el control de tránsito (Kumaran et al., 2019), durante las horas pico de la mañana y la noche, convirtiéndose en un problema crónico que, si no es solucionado, seguirá afectando enormemente no solo a la eficiencia del transporte ciudadano, sino también la calidad de vida de sus residentes.

Durante los últimos años, se han realizado esfuerzos para abordar la congestión de tráfico con nuevos métodos y tecnologías, siendo el uso de la inteligencia artificial (IA) la preferida (Chabchoub et al., 2021). En esta línea tenemos el procesamiento de imágenes que utiliza dispositivos inteligentes como cámaras de alta resolución. Por otro lado, existen propuestas basadas en metodologías de optimización a fin de predecir el comportamiento del tráfico para su control (Cheng et al., 2023).

La congestión del tráfico es un problema de gran relevancia debido a sus múltiples repercusiones tales como el incremento de accidentes de tránsito, la contaminación del aire, el descontento de la ciudadanía, entre otros. La importancia del tema radica en la necesidad de optimizar la gestión del tráfico y reducir los problemas asociados, mejorando la calidad de vida de los residentes y fortaleciendo la eficiencia de la administración municipal (Joo & Lim, 2021).

En los años recientes se ha propuesto la aplicación de metodologías y modelos basados en IA como las redes convolucionales (Vélez-Serrano et al., 2021) o sistemas multi-agentes (Wakkumbura et al., 2021). Brindando soluciones precisas y eficientes, pero que en ocasiones no son adaptables a más de un contexto.

A pesar de la evolución y uso de tecnologías basadas en IA el control de tráfico sigue teniendo deficiencias en ciudades con mucha aglomeración de personas y que carecen de la incorporación de tecnología de vanguardia en sus instrumentos de control de tránsito (Liu et al., 2020). La motivación del trabajo se centra en detectar propuestas viables para el control de tráfico en ciudades grandes y que aproveche las herramientas ya incorporadas y sin requerir un cambio masivo en estas.

Se propone una revisión sistemática de literatura para identificar las tecnologías, métodos y modelos utilizados en la construcción de sistemas de control de tráfico y cuáles de estos resultan más viables y eficientes. Esto con el objetivo de recopilar soluciones para reducir la congestión vehicular a través de un sistema de control de semáforos.

Esta revisión sistemática de literatura sigue la metodología de Kitchenham (2009), utilizando su ciclo de recopilación y selección de bibliografía para obtener artículos relevantes al campo de estudio a investigar y conseguir una conclusión precisa.

El presente artículo se organiza en cinco capítulos. En el primero se encuentra la introducción del artículo, el segundo detalla el estado del arte del tema de investigación, el tercero describe la metodología y el proceso de revisión de literatura, el cuarto muestra los resultados de la investigación y las conclusiones se detallan en el quinto capítulo.

2. Estado del arte

Las soluciones de control de tráfico muestran una transición hacia soluciones más avanzadas y adaptativas, impulsadas en gran medida por la aplicación de la IA y la tecnología (Wang et al., 2023). Estas tecnologías están diseñadas para abordar los desafíos de la congestión vehicular en ciudades grandes, optimizar la gestión del tráfico y mejorar la calidad de vida de los residentes (Chabchoub et al., 2021).

Control de tráfico

El control de tráfico es un campo de estudio amplio y crucial en la gestión del transporte y la movilidad urbana que implica administrar los componentes viales de tránsito vehicular de modo que se logre la optimización y se eviten problemáticas de congestión y accidentes vehiculares (Li, Y. et al., 2021).

Se han desarrollado diversas estrategias a lo largo de los años para abordar la congestión vehicular y mejorar la eficiencia del tráfico. Tradicionalmente, el control de tráfico se ha basado en la programación de tiempos fijos para semáforos y el uso de sensores de tráfico en las intersecciones. Sin embargo, durante estos últimos años, con el avance de la tecnología y la incorporación de la IA, se han explorado enfoques más dinámicos y adaptativos que puedan mejorar la eficiencia de tránsito en las ciudades con aglomeración de vehículos como el uso de redes neuronales (Shin et al., 2019) o modelos de predicción (Bao et al., 2023) y control de semáforos (Tunc & Soylemez, 2023) para la generación de “olas verdes”.

2.1. La tecnología en el control de tráfico

La tecnología desempeña un papel fundamental en el control de tráfico (Rasheed et al., 2022), ha permitido una mayor flexibilidad en la gestión del flujo vehicular. Pueden incluir sensores de tráfico avanzados, cámaras de vigilancia y sistemas de semaforización inteligente. Los sensores de vanguardia utilizan IA y aprendizaje profundo como redes convolucionales neuronales (CNN) y redes neuronales recurrentes que les permiten registrar nuevos datos en tiempo real y mejorar su propia base de datos, aumentando su precisión. Las cámaras de vigilancia utilizadas para el control de tráfico normalmente incluyen procesamiento local como las NVIDIA DeepStream, permitiendo incorporar modelos inteligentes como YOLO (You Only Look Once). Estas tecnologías se enfocan en conectarse a un sistema general para utilizar los datos recopilados en tiempo real con el objetivo de una toma de decisiones más profunda y de mayor precisión para optimizar el tráfico (Phursule et al., 2023). No obstante, con la llegada de la IA, cada vez se requiere menos del factor humano y la toma de decisiones se le es delegada a agentes inteligentes que han recibido entrenamiento o aprenden en tiempo real, reduciendo el trabajo del personal de monitoreo y mitigando la posibilidad de errores y demoras humanas.

En países desarrollados, se ha creado el concepto smart cities (Aqib et al., 2019) que incorpora de manera integral la IA para acoplar la gestión de tráfico a otros ámbitos como, la comunicación entre vehículos privados, infraestructuras y peatones conectados con el Internet de las Cosas (Chahal et al., 2023)..

2.2. Aplicación de la IA en el control de tráfico

La IA ha revolucionado el campo del control de tráfico al proporcionar herramientas y técnicas avanzadas para la toma de decisiones y la optimización en tiempo real. Algunos campos clave de la IA relacionados con el control de tráfico se detallarán a continuación

2.2.1. Procesamiento de Imagen

El procesamiento de imágenes desempeña un papel crucial en la supervisión y el control del tráfico. Se utilizan cámaras de alta resolución para capturar imágenes de las intersecciones y carreteras en tiempo real, y luego se aplican algoritmos de visión por computadora para analizar el flujo de tráfico, detectar vehículos, peatones y condiciones de la carretera. Esto proporciona datos visuales esenciales que permitirán el entrenamiento y posterior toma de decisiones en tiempo real de los modelos inteligentes de control de semaforización para la optimización del flujo de tráfico (Shin et al., 2019). Aunque en ocasiones puede ser impreciso debido a eventos inusuales o específicos que generalmente no suceden, cada año se proponen mejoras de precisión con el uso de nuevos modelos de IA (Chabchoub et al., 2021).

2.2.2. Predicción de tráfico

La predicción de tráfico implica el uso de modelos de IA para anticipar el comportamiento del tráfico en un área determinada. Estos modelos reciben datos históricos de tráfico, condiciones meteorológicas, eventos especiales y otros factores relevantes a través de entradas que, para el tema de tránsito, generalmente provienen de sensores y videocámaras (Chahal et al., 2023).

Aunque principalmente se utiliza el aprendizaje guiado y supervisado para entrenar los modelos de predicción (Aqib et al., 2019), se han desarrollado propuestas para permitir que estos modelos aprendan mientras están en funcionamiento, utilizando datos en tiempo real (Hao, W. et al., 2020).

2.2.3. Semaforización inteligente

Los sistemas de semaforización inteligente utilizan algoritmos y modelos de IA para ajustar los tiempos de los semáforos de manera dinámica en función de las condiciones actuales del tráfico (Rasheed et al., 2022). Esto permite una mejor adaptación a las necesidades del tráfico en tiempo real, reduciendo la congestión y mejorando la fluidez. Estos sistemas suelen integrarse con datos de sensores y cámaras para tomar decisiones informadas, incluso utilizando modelos de predicción que incrementen su nivel de precisión para generar olas verdes (Hao, S. et al., 2019).

3. Metodología

A través de la revisión sistemática de literatura se puede sintetizar conocimientos, descubrimientos, métodos y tecnologías utilizadas en las implementaciones de sistemas de control de tráfico. En esta investigación se toma de guía el marco metodológico propuesto por Kitchenham (2009), que consta de tres etapas: planificación, realización e informe de la revisión

3.1. Planificación de la revisión

Para la fase de planificación, se define el tema de investigación con el propósito de determinar el alcance de la revisión. Luego se determinan preguntas de investigación referentes al tema seleccionado. Estas se muestran a continuación.

- P1: ¿Qué algoritmos y métodos se utilizan en la construcción de sistemas de control de semaforización?
- P2: ¿Qué modelos de reconocimiento de objetos por imagen se utilizan para la identificación de densidad vehicular?
- P3: ¿Qué patrones se deben tener en cuenta para la identificación de vehículos por imagen?
- P4: ¿Qué algoritmos y métodos son los más eficientes para construir un sistema sobre la infraestructura de tráfico existente?

3.2. Realización de la revisión

En esta etapa se detalla el procedimiento de revisión de literatura, explicando la fase de búsqueda y selección de bibliografía.

3.2.1. Estrategias de búsqueda

Para la búsqueda de fuentes bibliográficas en la base de datos SCOPUS se utilizan palabras clave referentes a las preguntas de investigación del tema de control de tráfico, formulando con estas la cadena de búsqueda: ("traffic signal control" OR "smart traffic light" OR "traffic light control") AND ("vehicle counting" OR "vehicle detection" OR sensors) AND ("image recognition system" OR "image processing" OR software OR algorithms).

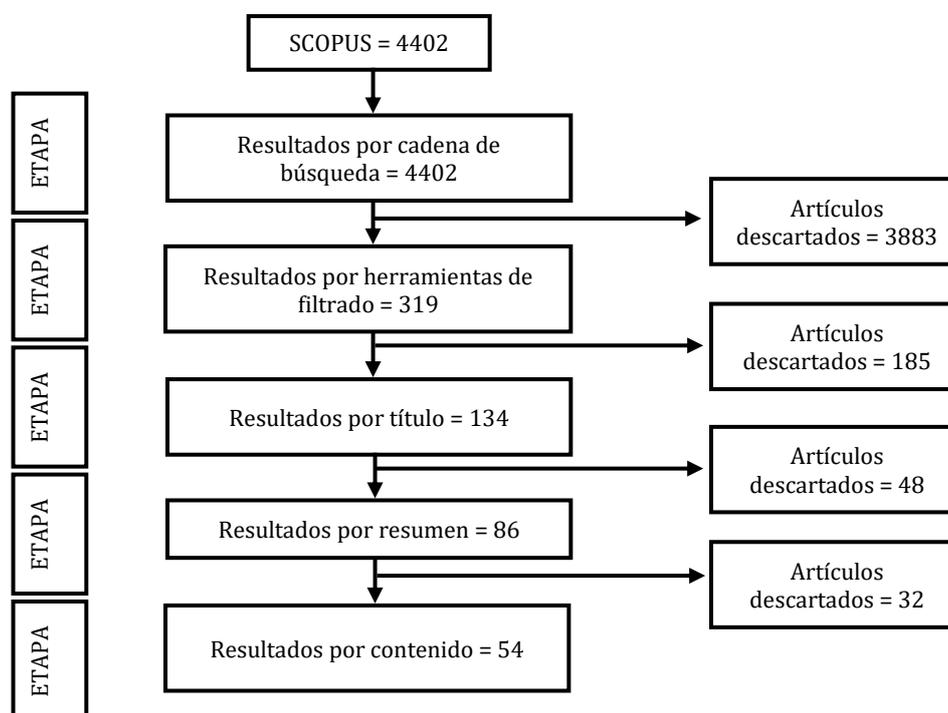
Se determinan criterios que mejoren la calidad de los resultados como que estos no tengan una antigüedad mayor a los 5 años o que cuenten con una versión en inglés. También se establece que los artículos deben contar con Identificador de Objeto Digital (DOI) para garantizar su confiabilidad. Es esencial que los artículos seleccionados se centren en el tema de control de tráfico con propuestas de implementación o aplicación para obtener resultados en contextos reales y una conclusión precisa. Los criterios a tomar en cuenta para la búsqueda y posterior selección de artículos son los que se muestran a continuación en la Tabla 1.

Tabla 1*Criterios de inclusión y exclusión*

Criterios de inclusión.	Criterios de exclusión.
Artículos centrados en la investigación del tema control de semáforos.	Investigación descriptiva.
Artículos con DOI.	Sin implementación.
Publicación en inglés.	Artículos que no se relacionen con el tema de control de semáforos.
Artículos centrados en técnicas, metodologías, tecnologías o herramientas para el control de semáforos.	Informes, revistas, boletines, comentarios.
	Antigüedad mayor a 5 años.

3.2.2. Selección de estudios

A partir de la cadena de búsqueda, durante la primera etapa del cribado, se seleccionaron 4402 artículos. La segunda etapa se realizó utilizando las herramientas disponibles por la base de datos de SCOPUS teniendo en cuenta los criterios definidos en la Tabla 1, siendo seleccionados 319 artículos. Para la tercera etapa, se revisaron títulos referentes al tema de control de tráfico, quedando 134 artículos. Luego se realizó una revisión del resumen para asegurar la relevancia y utilidad de los artículos, quedando así 86 artículos seleccionados. Finalmente se realiza la lectura del texto completo del artículo, quedando 54 artículos. Se resume el proceso de selección y cribado en la Figura 1.

Figura 1*Diagrama de flujo de cribado*

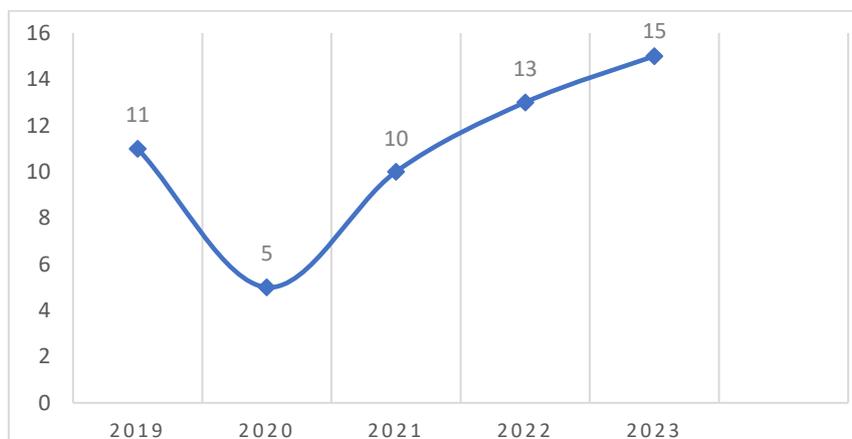
3.2.3. Extracción y análisis de datos

Se realiza un análisis cuantitativo representado en gráficos estadísticos a partir de los datos extraídos de la realización de la revisión. En el siguiente enlace se puede encontrar el procedimiento de extracción y análisis de datos con mayor detalle: https://docs.google.com/spreadsheets/d/1rVCe81Os0tMwbYX9mGeQvW6opIaoMelK/edit?usp=drive_link&oid=109493883837738690362&rtpof=true&sd=true

La Figura 2 muestra las publicaciones por año, de esta es posible determinar que existe un interés creciente desde el 2021 en el tema del control inteligente de tráfico, esto sugiere que existe una demanda global de soluciones para esta problemática excepto por el año 2020, que tuvo una caída drástica en la publicación de artículos posiblemente debido a la pandemia del COVID-19. La creciente demanda de soluciones a la problemática de control de tráfico con semaforización inteligente podría crear oportunidades para la colaboración internacional y el desarrollo de nuevas tecnologías que sean aplicables a una variedad de contextos.

Figura 2

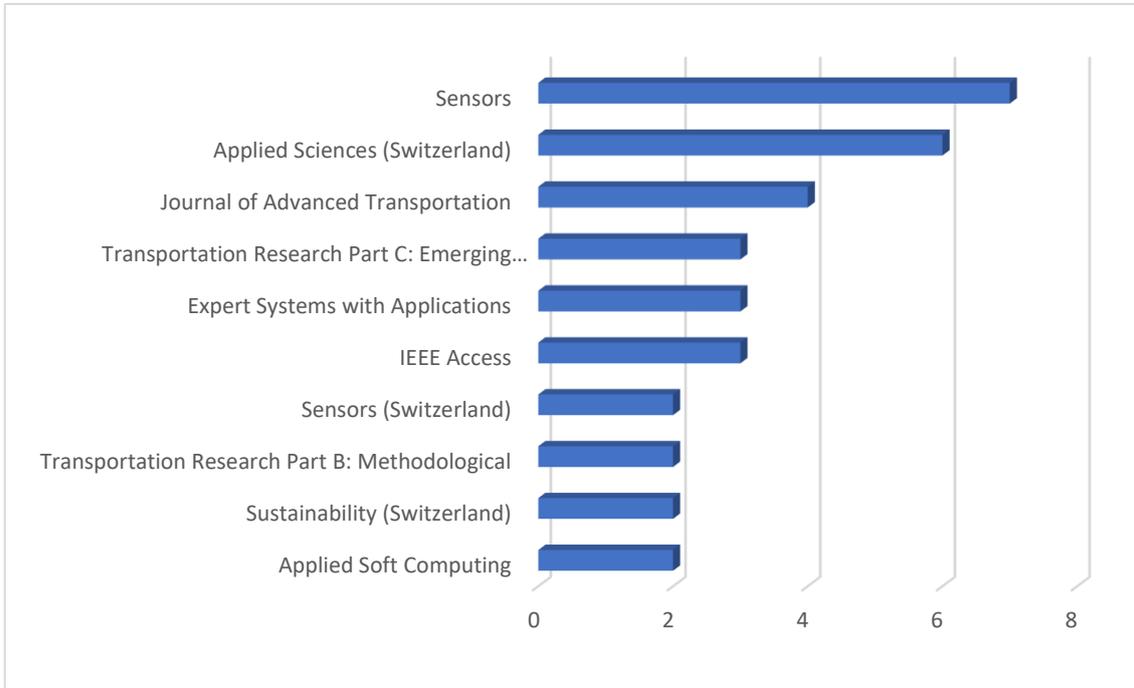
Artículos publicados por año



La Figura 3 muestra la cantidad de artículos publicados por journal. Se puede notar que existe una mayor cantidad de publicaciones alrededor del tema de control inteligente de tráfico en las revistas Sensors (7), Applied Sciences (6) y Journal of Advanced Transportation (4). Esto nos indica que en las mencionadas revistas es posible encontrar información del tema de investigación en mayor cantidad y con un mayor desarrollo. Esto nos permite tener un juicio previo del artículo proveniente de la revista al momento de seleccionar uno para cerciorar un punto o afirmación referente al tema de investigación.

Figura 3

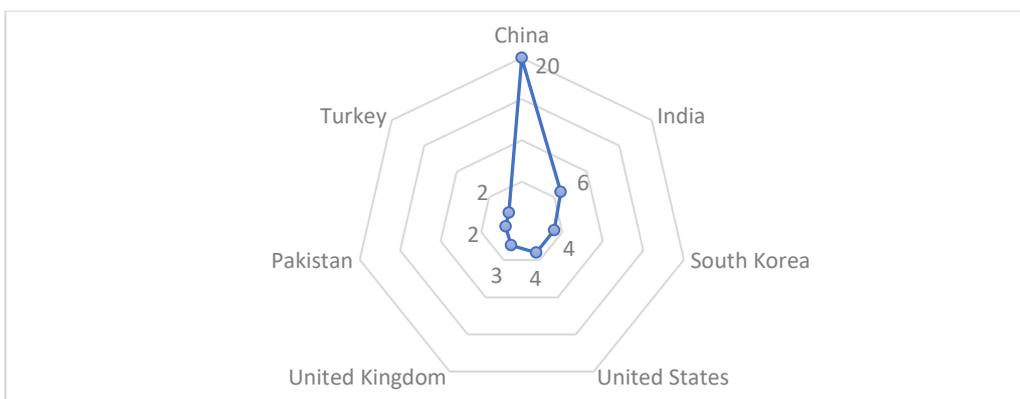
Artículos publicados por journal



En la Figura 4 se muestran los países con más artículos publicados, siendo China (20) e India (6) los que tienen mayor cantidad de estos. Se han excluido del gráfico 11 países pues solo cuentan con una sola publicación. Se determina que la problemática e investigación de soluciones del tema de control de tráfico abunda mayoritariamente en países orientales como China, debido a la sobrepoblación en sus principales ciudades. Esto nos indica que en los artículos pertenecientes a estos países tienen un enfoque más amplio y cercano a la problemática, además de en una cantidad mayor que en países occidentales.

Figura 4

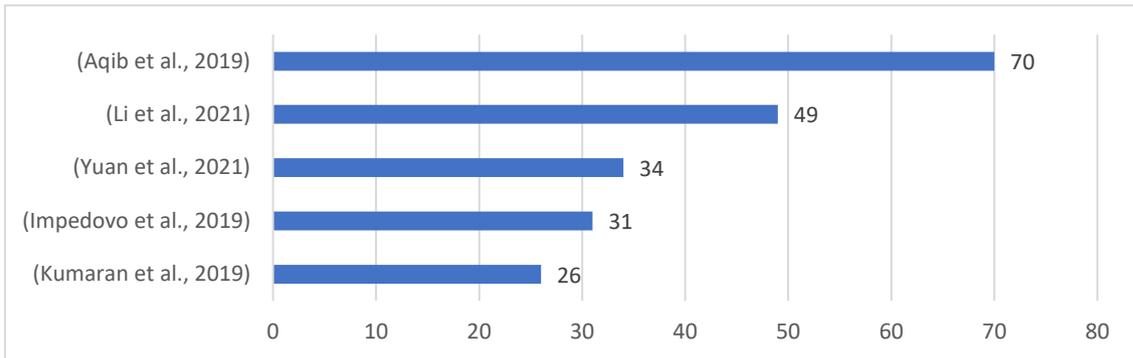
Artículos publicados por país



La Figura 5 muestra los cinco artículos con mayor cantidad de citas en otros trabajos, el más citado tiene 70, seguido de 49 el segundo lugar y 34 el tercero, todos son citados al menos una vez por algún autor. Siete trabajos cuentan con solo 1 citación. Se determina a través del gráfico que existen múltiples citaciones lo cual demuestra el interés en los temas tratados.

Figura 5

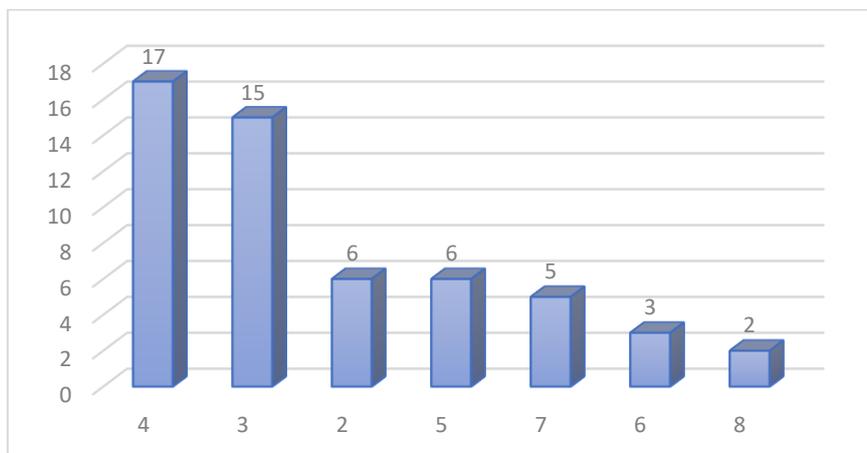
Artículos con mayor cantidad de citas



La Figura 6 muestra la cantidad de artículos publicados según la cantidad de autores, se evidencia 17 publicaciones con cuatro autores, 15 con 3 autores, también 2 trabajos con 8 autores cada uno. Ningún trabajo cuenta con solo un autor. Se manifiesta que alrededor del tema de control inteligente de tráfico existe una mayor colaboración entre varios investigadores. Esto podría indicar que una solución inteligente para el problema de control de tráfico resulta lo suficientemente complejo como para necesitar varios especialistas de diversos enfoques y áreas.

Figura 6

Cantidad de autores por artículos publicado



3.3. Informe de la revisión

En esta etapa se recopilan los resultados y respuestas a las preguntas de investigación definidas en la primera etapa obtenidas tras la revisión de literatura. A continuación, se responden a las cuatro preguntas.

P1: ¿Qué algoritmos y métodos se utilizan en la construcción de sistemas de control de semaforización?

Un algoritmo es un grupo de instrucciones organizadas y secuenciadas que en conjunto sirven para un propósito o función. En programación, la principal diferencia entre algoritmo y método es que este último es una implementación específica y concreta del primero. En la Tabla 3 se recopilan y describen los algoritmos y métodos utilizados por los autores en sus propuestas de implementación. Solo se rescatan aquellos de uso principal que son señalados y detallados en el proceso de construcción del sistema de los artículos revisados.

Tabla 3

Algoritmos y métodos utilizados en sistemas de control de semaforización

REFERENCIA	ALGORITMO	MÉTODO	DESCRIPCIÓN
(Yuan et al., 2021); (Jin & Ma, 2019)		Bayesian Filter	Es un método basado en un filtro recursivo que se utiliza para estimar el estado de un sistema dinámico a partir de una secuencia de mediciones ruidosas y medir su incertidumbre.
(Stoilova & Stoilov, 2022); (Chahal et al., 2023)	Bi-level Algorithm		Es un tipo de algoritmo de optimización que se utiliza para resolver problemas con dos niveles de toma de decisiones.
(Shin et al., 2019); (Vélez-Serrano et al., 2021); (Islam et al., 2022)	Convolutional Neural Network (CNN)		Es un tipo de algoritmo de aprendizaje profundo que es particularmente adecuado para la clasificación y reconocimiento de imágenes.
(Tan et al., 2022); (Aqib et al., 2019); (Bao et al., 2023); (Islam et al., 2022); (Impedovo et al., 2019)		Deep Learning	Es un método de aprendizaje automático que utiliza redes neuronales artificiales para aprender de los datos procesados.
(Mukhtar et al., 2023); (Rasheed et al., 2022); (Joo & Lim, 2021); (Li, Z. et al., 2021); (Zheng et al., 2022)	Deep Q-Network (DQN)		Es un algoritmo de aprendizaje por refuerzo que utiliza el aprendizaje profundo para aprender una política. DQN se ha demostrado que es efectivo para resolver una variedad de problemas, como realizar predicciones y controlar mecanismos inteligentes.
(Damadam et al., 2022); (Rasheed et al., 2022); (Tan et al., 2022); (Wu et al., 2022); (Wang et al., 2023); (Li, Z. et al., 2021); (Szoke et al., 2023); (Li, Y. et al., 2021)		Deep Reinforcement Learning	Es un método de aprendizaje por refuerzo que utiliza el aprendizaje profundo para aprender una política.
(Tunc & Soylemez, 2023); (Chabchoub et al., 2021); (Chatterjee et al., 2019); (Wakkumbura et al., 2021)		Fuzzy Logic Control (FLC)	Es un tipo de sistema de control que utiliza lógica borrosa para tomar decisiones. FLC se utiliza para controlar sistemas complejos que son difíciles de modelar utilizando métodos de control tradicionales.

(Yuan et al., 2021); (Jin & Ma, 2019)	Gaussian Process	Es un método estadístico que se puede utilizar para la regresión, clasificación y predicción.
(Kim et al., 2023)	Genetic Algorithm	Es un algoritmo metaheurístico que está inspirado en el proceso de selección natural y es utilizado para resolver problemas de optimización.
(Mukhtar et al., 2023)	Graph Convolutional Network (GCN)	Es un tipo de algoritmo de aprendizaje profundo que se puede utilizar para aprender en base de datos representados como grafos.
(Shin et al., 2019); (Chabchoub et al., 2021); (Wakkumbura et al., 2021); (Zhang et al., 2020); (Li, Y. et al., 2021)	Image Processing	Es un método que utiliza un conjunto de técnicas para manipular y analizar imágenes digitales.
(Bao et al., 2023); (Cheng et al., 2023); (Hao, W. et al., 2020); (Islam et al., 2022); (Chahal et al., 2023)	Long Short-Term Memory (LSTM)	Es un método que utiliza redes neuronales recurrentes para el procesamiento de datos secuenciales, como el procesamiento del lenguaje natural y la traducción automática.
(Damadam et al., 2022); (Korecki & Helbing, 2022); (Kumaran et al., 2019); (Yuan et al., 2021); (Wakkumbura et al., 2021); (Szoke et al., 2023); (Impedovo et al., 2019)	Machine Learning	Es un método que le da a las computadoras la capacidad de aprender sin ser programadas explícitamente, se puede utilizar para resolver una amplia gama de problemas, como clasificación, regresión y predicción.
(Wakkumbura et al., 2021); (Suga et al., 2023); (Mukhtar et al., 2023); (Rasheed et al., 2022); (Shehu et al., 2020); (Li, Z. et al., 2021)	Multi Agent Technology	Es un método que se ocupa del diseño y desarrollo de sistemas que consisten en el uso de múltiples agentes inteligentes para resolver problemas complejos que no pueden ser resueltos por un solo agente.
(Cheng et al., 2023)	Snake Optimization Algorithm	Es un tipo de algoritmo metaheurístico que está inspirado en el movimiento de las serpientes y es efectivo para optimizar el procesamiento de información.

P2: ¿Qué modelos de reconocimiento de objetos por imagen se utilizan para la identificación de densidad vehicular?

Los modelos inteligentes son pequeños sistemas capaces de tomar decisiones y adaptarse a través del conocimiento e información adquiridos antes y durante su funcionamiento. La Tabla 4 muestra los modelos de procesamiento de imagen para reconocimiento de objetos utilizados en la construcción de sistemas de control de semaforización propuestos en los artículos revisados. En cada modelo se describe su uso en el proceso y las características que lo diferencian.

Tabla 4*Modelos de reconocimiento de objetos utilizados en identificación de densidad vehicular*

REFERENCIA	MODELO	DESCRIPCIÓN
(Shin et al., 2019); (Chabchoub et al., 2021); (Wakkumbura et al., 2021); (Zhang et al., 2020); (Li, Y. et al., 2021)	You Only Look Once (YOLO)	Es un modelo detector de objetos de una sola pasada que identifica y clasifica objetos en una imagen en un solo paso. Puede predecir todas las cajas delimitadoras, clases y probabilidades en una sola pasada.
(Chabchoub et al., 2021); (Wakkumbura et al., 2021)	Single Shot MultiBox Detector (SSD)	Es un modelo de reconocimiento de objetos de detección rápida que identifica y clasifica objetos en una imagen en un solo paso. Es similar a YOLO, pero dado que utiliza cajas delimitadoras predefinidas puede ser más precisa, aunque también más lenta.
(Li, Y. et al., 2021)	Faster R-CNN	Es un modelo detector de objetos de dos pasos que primero genera un conjunto de regiones candidatas y luego clasifica cada región candidata. Esto puede ser más preciso que YOLO y SSD, pero es menos eficiente.
(Li, Y. et al., 2021)	Mask R-CNN	Es una extensión de Faster R-CNN que también predice máscaras para cada objeto detectado. Esto permite al modelo segmentar los objetos detectados, lo que es útil para aplicaciones como el reconocimiento de objetos y la visión por computadora de la robótica.

P3: ¿Qué patrones se deben tener en cuenta para la identificación de vehículos por imagen?

Los patrones son un conjunto de características recurrentes que pueden ser identificadas dentro de un grupo de datos. En la Tabla 5 se recopilan los aspectos y características que los autores señalan para el entrenamiento del modelo inteligente para procesamiento de imagen en sus propuestas. Se señalan únicamente los patrones que contribuyen a la precisión del modelo para el reconocimiento de vehículos.

Tabla 5*Patrones para la identificación de vehículos por procesamiento de imagen*

REFERENCIA	PATRONES	DESCRIPCIÓN
(Li, Y. et al., 2021) (Wakkumbura et al., 2021)	Formas	La mayoría de carros siguen formas estandarizadas con las que se puede facilitar la identificación como del tipo "muscle" o "sedan".
(Shin et al., 2019) (Li, Y. et al., 2021)	Dimensiones	Los autores señalan que, tras una correcta configuración del contexto de reconocimiento, se puede identificar vehículos con mayor facilidad gracias a sus dimensiones superiores a otros objetos o personas que se desplacen en la imagen
(Tunc & Soylemez, 2023); (Chabchoub et al., 2021) (Li, Y. et al., 2021)	Color	Cambios abruptos en las tonalidades facilitan la identificación de los vehículos
(Li, Y. et al., 2021)	Placas de matrícula	El autor señala que la identificación de una placa vehicular dentro de una de las formas facilita su reconocimiento como vehículo

P4: ¿Qué algoritmos y métodos son los más eficientes para construir un sistema sobre la infraestructura de tráfico existente?

La Tabla 6 detalla un análisis general de eficiencia de los algoritmos y métodos utilizados en las propuestas de los autores, observando las características que estos consideran afectan de manera positiva o negativa en la precisión y confiabilidad de sus sistemas de control de semáforos. Se determina el nivel de eficiencia en tres estados: ineficiente, eficiente y muy eficiente. La calificación se basa en las observaciones y resultados de optimización de las colas de tráfico presentadas en los trabajos revisados. Si la reducción de longitud de cola es menor al 20% y presenta dificultades que afectan a la precisión del sistema, se considera ineficiente. Si la reducción de longitud de cola es menor al 20% y las dificultades no afectan a la precisión del sistema o la reducción es mayor y las dificultades sí afectan, se considera eficiente. Si la reducción supera el 20% y las dificultades sean ajenas a la precisión del sistema se considera muy eficiente. También se compara su eficiencia con el resto para incrementar la confiabilidad de la calificación. La Tabla 6 muestra la rúbrica establecida para la calificación del nivel de eficiencia.

Tabla 6

Rúbrica de evaluación de nivel de eficiencia

	Reducción de longitud de cola menor a 20%	Reducción de longitud de cola mayor a 20%
Las dificultades presentadas afectan a la precisión del sistema	Ineficiente	Eficiente
Las dificultades presentadas no afectan a la precisión del sistema	Eficiente	Muy eficiente

Tabla 7

Nivel de eficiencia de algoritmos y métodos utilizados en sistemas de control de semaforización

REFERENCIA	ALGORITMO /MÉTODO	NIVEL	OBSERVACIONES
(Stoilova & Stoilov, 2022); (Chahal et al., 2023)	Bi-level Algorithm	Eficiente	Uno de los autores señala que su funcionamiento por dos niveles incrementa su precisión y utilidad, pero su capacidad de adaptación a problemas muy específicos es inferior en comparación a otros algoritmos.
(Tunc & Soylemez, 2023); (Chabchoub et al., 2021); (Chatterjee et al., 2019); (Wakkumbura et al., 2021)	Fuzzy Logic Control (FLC)	Eficiente	Los autores hacen observaciones de su aceptable eficiencia en sistemas de semáforos tradicionales, no obstante, debido a esto su adaptabilidad en situaciones muy complejas no es la mejor.
(Yuan et al., 2021); (Jin & Ma, 2019)	Gaussian Process	Eficiente	Los autores lo comparan con la Fuzzy Logic en cuanto a su utilidad para sistemas de control de tráfico.

(Bao et al., 2023); (Cheng et al., 2023); (Hao, S. et al., 2020); (Islam et al., 2022); (Chahal et al., 2023)	Long Short-Term Memory (LSTM)	Eficiente	Los autores señalan que es muy útil para predicción de tráfico y registro de información en tiempo real, pero en ocasiones puede tener problemas cuando los datos de tráfico son muy ruidosos
(Tan et al., 2022); (Aqib et al., 2019); (Bao et al., 2023); (Islam et al., 2022); (Impedovo et al., 2019)	Deep Learning	Ineficiente	Los autores señalan que por sí sola puede resultar poco eficiente debido a su baja precisión y las grandes cantidades de datos que requiere para el control de tráfico. No obstante, puede utilizarse como base de algoritmos más complejos.
(Kim et al., 2023)	Genetic Algorithm	Ineficiente	El autor señala que, aunque puede resolver problemas complejos de control de tráfico, también puede resultar demasiado lento para su uso en tiempo real.
(Cheng et al., 2023)	Snake Optimization Algorithm	Ineficiente	El autor señala que puede ralentizarse en intersecciones de más de dos carriles por dirección.
(Yuan et al., 2021); (Jin & Ma, 2019)	Bayesian Filter	Muy eficiente	Los autores señalaron su gran eficiencia para la predicción de tráfico en diversas situaciones, ya que puede manejar grandes cantidades de datos en tiempo real.
(Shin et al., 2019); (Vélez-Serrano et al., 2021); (Islam et al., 2022)	Convolutional Neural Network (CNN)	Muy eficiente	Los autores señalan que son esenciales para la creación de un modelo inteligente en control de tráfico.
(Mukhtar et al., 2023); (Rasheed et al., 2022); (Joo & Lim, 2021); (Li, Z. et al., 2021); (Zheng et al., 2022)	Deep Q-Network (DQN)	Muy eficiente	Los autores señalan que mientras cuente con buen entrenamiento aprender una política efectiva puede ser una de las mejores opciones para el control de tráfico debido a su procesamiento por redes.
(Damadam et al., 2022); (Rasheed et al., 2022); (Tan et al., 2022); (Wu et al., 2022); (Wang et al., 2023); (Li, Z. et al., 2021); (Szoke et al., 2023); (Li, Y. et al., 2021)	Deep Reinforcement Learning	Muy Eficiente	Los autores señalan que es esencial para el aprendizaje recursivo y la mejora constante de la capacidad de toma de decisiones de un modelo inteligente en el sistema de control de tráfico.
(Mukhtar et al., 2023)	Graph Convolutional Network (GCN)	Muy eficiente	Los autores señalan que es muy útil y eficiente para el procesamiento de datos estructurados en el control de tráfico debido a su capacidad de lectura de grafos.
(Wakkumbura et al., 2021); (Suga et al., 2023); (Mukhtar et al., 2023); (Rasheed et al., 2022); (Shehu et al., 2020); (Li, Z. et al., 2021)	Multi Agent Technology	Muy eficiente	Los autores señalan que, si se logra superar la complejidad de su implementación, puede llegar a resultar extremadamente eficiente y estable.

4. Discusión de los resultados

Los resultados hallados a través del proceso de revisión de literatura describen la existencia de 6 algoritmos y 10 métodos utilizados para la construcción de sistemas de control de semáforos. Entre estos los más utilizados son el Deep Reinforcement Learning y el Machine Learning, pues sirven como base para la construcción de modelos inteligentes para el cambio de luces y predicción de tráfico. Los artículos también describen la importancia de las CNN y la construcción de una base de datos de entrenamiento amplias para incrementar la precisión de estos sistemas (Islam et al., 2022).

Entre los algoritmos y métodos utilizados, los de mayor eficiencia para la predicción de densidad vehicular y el cambio óptimo de luces son el filtro bayesiano, la tecnología multi-agente (Mukhtar et al., 2023), las CNN y el aprendizaje profundo, demostrando buena adaptabilidad durante horas de congestión de tráfico y eventos específicos como pase de vehículos de emergencia. Los resultados sugieren que si estos se utilizan para la predicción de la densidad vehicular se deben iterar varias ocasiones en estratos diferentes del día para evitar malas adecuaciones (Jin & Ma, 2019). Por otro lado, se descartan aquellos que para situaciones de tránsito denso resultan lentos, poco precisos o de mala adaptación como los algoritmos genéticos o el algoritmo de optimización de serpiente.

También se menciona que para el uso de procesamiento de imagen en estos sistemas los modelos de mayor utilidad son YOLO, SSD, Faster R-CNN y Mask R-CNN debido a su confiabilidad para el reconocimiento de objetos por imagen. Se enfatiza la superioridad de YOLO frente al resto de modelos debido a su velocidad de procesamiento con su funcionalidad de una sola pasada que resulta eficiente para el reconocimiento de densidad vehicular en tiempo real (Chabchoub et al., 2021). Se resalta que el Mask R-CNN solo se utiliza como extensión a la aplicación del Faster R-CNN (Shin et al., 2019).

Además, se describe que los patrones visuales que los autores priorizan en el entrenamiento de sus modelos de procesamiento de imagen para la identificación de vehículos son las formas, el color, las dimensiones y las placas de vehículos (Li, Y. et al., 2021). Se menciona que a esta última se le debe brindar mayor atención en la creación de la base de imágenes de entrenamiento para facilitar el reconocimiento de un vehículo frente al resto de objetos.

5. Conclusiones

A través de esta revisión de literatura se determina que el uso de modelos o algoritmos de IA se convierte en la mejor opción para el desarrollo de soluciones contra la problemática de congestión vehicular y control de semáforos, pues aportan una mayor optimización del control de luces y señales de tránsito debido a su capacidad de predicción de la densidad de tráfico.

Se puede afirmar que el modelo de procesamiento de imagen que se adecúa mejor en el proceso de reconocimiento de vehículos es YOLO debido a los resultados obtenidos por los artículos revisados. Esto se debe a su capacidad para detectar varios objetos a la vez, su rápida toma de decisiones basada en los resultados detectados y su consumo óptimo de recursos computacionales, permitiendo su aplicación en tiempo real en un sistema de control de semáforos.

A partir del análisis de las observaciones en los artículos revisados, es posible determinar que para el entrenamiento del modelo de reconocimiento de objetos se debe priorizar aquellas secuencias de imágenes que muestran los vehículos y su matrícula al menos una vez por cuadro. Esto debido a que así se mejora la precisión del modelo inteligente a la hora de distinguir vehículos de otros objetos en movimiento.

De acuerdo al análisis de los resultados, se concluye que el algoritmo más preciso para la construcción de un sistema de control de semáforos es el filtro bayesiano aplicado

en las CNN, pues permite modelar la incertidumbre de los datos del tráfico para facilitar el aprendizaje y predicción de la densidad vehicular, mejorando la precisión de las decisiones en el cambio de luces de los semáforos.

6. Referencias

- Ahmed, B., Shehzad, Q., Ullah, I., Zahoor, N., & Tayyab, H. M. (2022). An Effective Combination of PLC and Microcontrollers for Centralized Traffic Control and Monitoring System †. *Engineering Proceedings*, 12(1). <https://doi.org/10.3390/engproc2021012071>
- Aqib, M., Mehmood, R., Alzahrani, A., Katib, I., Albeshri, A., & Altowaijri, S. M. (2019). Smarter traffic prediction using big data, in-memory computing, deep learning and gpus. *Sensors (Switzerland)*, 19(9). <https://doi.org/10.3390/s19092206>
- Bae, B., Liu, Y., Han, L. D., & Bozdogan, H. (2019). Spatio-temporal traffic queue detection for uninterrupted flows. *Transportation Research Part B: Methodological*, 129, 20–34. <https://doi.org/10.1016/j.trb.2019.09.001>
- Bao, Y., Huang, J., Shen, Q., Cao, Y., Ding, W., Shi, Z., & Shi, Q. (2023). Spatial–Temporal Complex Graph Convolution Network for Traffic Flow Prediction. *Engineering Applications of Artificial Intelligence*, 121. <https://doi.org/10.1016/j.engappai.2023.106044>
- Chabchoub, A., Hamouda, A., Al-Ahmadi, S., & Cherif, A. (2021). Intelligent Traffic Light Controller using Fuzzy Logic and Image Processing. *International Journal of Advanced Computer Science and Applications*, 12(4). <https://doi.org/10.14569/IJACSA.2021.0120450>
- Chahal, A., Gulia, P., Gill, N. S., & Priyadarshini, I. (2023). A Hybrid Univariate Traffic Congestion Prediction Model for IoT-Enabled Smart City. *Information (Switzerland)*, 14(5). <https://doi.org/10.3390/info14050268>
- Chatterjee, K., De, A., & Chan, F. T. S. (2019). Real time traffic delay optimization using shadowed type-2 fuzzy rule base. *Applied Soft Computing Journal*, 74, 226–241. <https://doi.org/10.1016/j.asoc.2018.10.008>
- Chen, S., Shang, C., & Zhu, F. (2023). A Flexible Traffic Signal Coordinated Control Approach and System on Complicated Transportation Control Infrastructure. *Sensors*, 23(13). <https://doi.org/10.3390/s23135796>
- Cheng, R., Qiao, Z., Li, J., & Huang, J. (2023). Traffic Signal Timing Optimization Model Based on Video Surveillance Data and Snake Optimization Algorithm. *Sensors*, 23(11). <https://doi.org/10.3390/s23115157>
- Damadani, S., Zourbakhsh, M., Javidan, R., & Faroughi, A. (2022). An Intelligent IoT Based Traffic Light Management System: Deep Reinforcement Learning. *Smart Cities*, 5(4), 1293–1311. <https://doi.org/10.3390/smartcities5040066>
- Eriskin, E., Terzi, S., & Ceylan, H. (2022). Development of dynamic traffic signal control based on Monte Carlo simulation approach. *Measurement: Journal of the International Measurement Confederation*, 188. <https://doi.org/10.1016/j.measurement.2021.110591>
- Feng, L., Zhao, X., Lin, H., & Li, R. (2022). Urban Arterial Signal Coordination Using Spatial and Temporal Division Methods. *Journal of Advanced Transportation*, 2022. <https://doi.org/10.1155/2022/4879049>

- Fu, T., Yu, Q., Lao, H., Liu, P., & Wan, S. (2023). Traffic Safety Oriented Multi-Intersection Flow Prediction Based on Transformer and CNN. *Security and Communication Networks*, 2023. <https://doi.org/10.1155/2023/1363639>
- Goyal, A., Singh, M., & Aeron, A. (2019). Simulation of traffic optimization to reduce congestion. *International Journal of Innovative Technology and Exploring Engineering*, 8(11), 3780–3783. <https://doi.org/10.35940/ijitee.K2122.0981119>
- Gravelle, E., & Martínez, S. (2020). Using time-inconsistent wait-time functions for cycle-free coordinated traffic intersections. *IFAC Journal of Systems and Control*, 12. <https://doi.org/10.1016/j.ifacsc.2020.100087>
- Hao, S., Yang, L., Ding, L., & Guo, Y. (2019). Distributed Cooperative Backpressure-Based Traffic Light Control Method. *Journal of Advanced Transportation*, 2019. <https://doi.org/10.1155/2019/7481489>
- Hao, W., Rong, D., Yi, K., Zeng, Q., Gao, Z., Wu, W., Wei, C., & Scepanovic, B. (2020). Traffic Status Prediction of Arterial Roads Based on the Deep Recurrent Q-Learning. *Journal of Advanced Transportation*, 2020. <https://doi.org/10.1155/2020/8831521>
- Impedovo, D., Balducci, F., Dentamaro, V., & Pirlo, G. (2019). Vehicular traffic congestion classification by visual features and deep learning approaches: A comparison. *Sensors (Switzerland)*, 19(23). <https://doi.org/10.3390/s19235213>
- Islam, Z., Abdel-Aty, M., & Mahmoud, N. (2022). Using CNN-LSTM to predict signal phasing and timing aided by High-Resolution detector data. *Transportation Research Part C: Emerging Technologies*, 141. <https://doi.org/10.1016/j.trc.2022.103742>
- Jafari, S., Shahbazi, Z., & Byun, Y. C. (2021). Improving the performance of single-intersection urban traffic networks based on a model predictive controller. *Sustainability (Switzerland)*, 13(10). <https://doi.org/10.3390/su13105630>
- Jin, J., & Ma, X. (2019). A non-parametric Bayesian framework for traffic-state estimation at signalized intersections. *Information Sciences*, 498, 21–40. <https://doi.org/10.1016/j.ins.2019.05.032>
- Joo, H., & Lim, Y. (2021). Traffic signal time optimization based on deep q-network. *Applied Sciences (Switzerland)*, 11(21). <https://doi.org/10.3390/app11219850>
- Kelathodi Kumaran, S., Prosad Dogra, D., & Pratim Roy, P. (2019). Queuing theory guided intelligent traffic scheduling through video analysis using Dirichlet process mixture model. *Expert Systems with Applications*, 118, 169–181. <https://doi.org/10.1016/j.eswa.2018.09.057>
- Kim, M., Schrader, M., Yoon, H. S., & Bittle, J. A. (2023). Optimal Traffic Signal Control Using Priority Metric Based on Real-Time Measured Traffic Information. *Sustainability (Switzerland)*, 15(9). <https://doi.org/10.3390/su15097637>
- Kitchenham, B., Pearl Brereton, O., 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. <https://doi.org/10.1016/j.infsof.2008.09.009>
- Korecki, M., & Helbing, D. (2022). Analytically Guided Reinforcement Learning for Green It and Fluent Traffic. *IEEE Access*, 10, 96348–96358. <https://doi.org/10.1109/ACCESS.2022.3204057>
- Kumaran, S. K., Mohapatra, S., Dogra, D. P., Roy, P. P., & Kim, B. G. (2019). Computer vision-guided intelligent traffic signaling for isolated intersections. *Expert Systems with Applications*, 134, 267–278. <https://doi.org/10.1016/j.eswa.2019.05.049>

- Li, Y., Chen, Y., Yuan, S., Liu, J., Zhao, X., Yang, Y., & Liu, Y. (2021). Vehicle detection from road image sequences for intelligent traffic scheduling. *Computers and Electrical Engineering*, 95. <https://doi.org/10.1016/j.compeleceng.2021.107406>
- Li, Z., Yu, H., Zhang, G., Dong, S., & Xu, C. Z. (2021). Network-wide traffic signal control optimization using a multi-agent deep reinforcement learning. *Transportation Research Part C: Emerging Technologies*, 125. <https://doi.org/10.1016/j.trc.2021.103059>
- Lilhore, U. K., Imoize, A. L., Li, C. T., Simaiya, S., Pani, S. K., Goyal, N., Kumar, A., & Lee, C. C. (2022). Design and Implementation of an ML and IoT Based Adaptive Traffic-Management System for Smart Cities. *Sensors*, 22(8). <https://doi.org/10.3390/s22082908>
- Liu, W. L., Gong, Y. J., Chen, W. N., & Zhang, J. (2020). EvoTSC: An evolutionary computation-based traffic signal controller for large-scale urban transportation networks. *Applied Soft Computing*, 97. <https://doi.org/10.1016/j.asoc.2020.106640>
- Mukhtar, H., Afzal, A., Alahmari, S., & Yonbawi, S. (2023). CCGN: Centralized collaborative graphical transformer multi-agent reinforcement learning for multi-intersection signal free-corridor. *Neural Networks*, 166, 396–409. <https://doi.org/10.1016/j.neunet.2023.07.027>
- Noaen, M., Mohajerpoor, R., H. Far, B., & Ramezani, M. (2021). Real-time decentralized traffic signal control for congested urban networks considering queue spillbacks. *Transportation Research Part C: Emerging Technologies*, 133. <https://doi.org/10.1016/j.trc.2021.103407>
- Ojeniyi, A., Aro, T., & Thiak, A. M. (2019). Design of an agent-based traffic control system. *International Journal of Engineering and Advanced Technology*, 8(6 Special Issue 3), 71–76. <https://doi.org/10.35940/ijeat.F1012.0986S319>
- Oszczypała, M., Ziółkowski, J., Małachowski, J., & Lęgas, A. (2023). Nash Equilibrium and Stackelberg Approach for Traffic Flow Optimization in Road Transportation Networks—A Case Study of Warsaw. *Applied Sciences (Switzerland)*, 13(5). <https://doi.org/10.3390/app13053085>
- Phursule, R., Lal, D., Waghare, S., Mughni, M. A., Ransubhe, S., & Shiralkar, C. (2023). Enhancing Traffic Flow Using Computer Vision Based - Dynamic Traffic Light Control and Lane Management. *International Journal on Recent and Innovation Trends in Computing and Communication*, 11(7 S), 386–391. <https://doi.org/10.17762/ijritcc.v11i7s.7014>
- Rasheed, F., Yau, K. L. A., Noor, R. M., & Chong, Y. W. (2022). Deep reinforcement learning for addressing disruptions in traffic light control. *Computers, Materials and Continua*, 71(2), 2225–2247. <https://doi.org/10.32604/cmc.2022.022952>
- Ren, Y., Yin, H., Wang, L., & Ji, H. (2023). Data-Driven RBFNN-Enhanced Model-Free Adaptive Traffic Symmetrical Signal Control for a Multi-Phase Intersection with Fast-Changing Traffic Flow. *Symmetry*, 15(6). <https://doi.org/10.3390/sym15061235>
- Shehu, H. A., Sharif, M. H., & Ramadan, R. A. (2020). Distributed Mutual Exclusion Algorithms for Intersection Traffic Problems. *IEEE Access*, 8, 138277–138296. <https://doi.org/10.1109/ACCESS.2020.3012573>
- Shin, J., Roh, S., & Sohn, K. (2019). Image-Based Learning to Measure the Stopped Delay in an Approach of a Signalized Intersection. *IEEE Access*, 7, 169888–169898. <https://doi.org/10.1109/ACCESS.2019.2955307>

- Stoilova, K., & Stoilov, T. (2022). Model Predictive Traffic Control by Bi-Level Optimization. *Applied Sciences (Switzerland)*, 12(9). <https://doi.org/10.3390/app12094147>
- Suga, S., Fujimori, R., Yamada, Y., Ihara, F., Takamura, D., Hayashi, K., & Kurihara, S. (2023). Traffic information interpolation method based on traffic flow emergence using swarm intelligence. *Artificial Life and Robotics*, 28(2), 367–380. <https://doi.org/10.1007/s10015-022-00847-7>
- Szoke, L., Aradi, S., & Bécsi, T. (2023). Traffic Signal Control with Successor Feature-Based Deep Reinforcement Learning Agent. *Electronics (Switzerland)*, 12(6). <https://doi.org/10.3390/electronics12061442>
- Tan, J., Yuan, Q., Guo, W., Xie, N., Liu, F., Wei, J., & Zhang, X. (2022). Deep Reinforcement Learning for Traffic Signal Control Model and Adaptation Study. *Sensors*, 22(22). <https://doi.org/10.3390/s22228732>
- Tunc, I., & Soylemez, M. T. (2023). Fuzzy logic and deep Q learning based control for traffic lights. *Alexandria Engineering Journal*, 67, 343–359. <https://doi.org/10.1016/j.aej.2022.12.028>
- Vélez-Serrano, D., Álvaro-Meca, A., Sebastián-Huerta, F., & Vélez-Serrano, J. (2021). Spatio-temporal traffic flow prediction in madrid: An application of residual convolutional neural networks. *Mathematics*, 9(9). <https://doi.org/10.3390/math9091068>
- Wakkumbura, R. T., Hettige, B., & Edirisuriya, A. (2021). Real-time traffic controlling system using multi-agent technology. *Journal European Des Systemes Automates*, 54(4), 633–640. <https://doi.org/10.18280/jesa.540413>
- Wang, H., Zhu, J., & Gu, B. (2023). Model-Based Deep Reinforcement Learning with Traffic Inference for Traffic Signal Control. *Applied Sciences (Switzerland)*, 13(6). <https://doi.org/10.3390/app13064010>
- Wu, Q., Wu, J., Shen, J., Du, B., Telikani, A., Fahmideh, M., & Liang, C. (2022). Distributed agent-based deep reinforcement learning for large scale traffic signal control. *Knowledge-Based Systems*, 241. <https://doi.org/10.1016/j.knosys.2022.108304>
- Yuan, Y., Zhang, Z., Yang, X. T., & Zhe, S. (2021). Macroscopic traffic flow modeling with physics regularized Gaussian process: A new insight into machine learning applications in transportation. *Transportation Research Part B: Methodological*, 146, 88–110. <https://doi.org/10.1016/j.trb.2021.02.007>
- Zhang, L., Wang, L., & Zhao, Q. (2020). Traffic State Recognition of Intersection Based on Image Model and PCA Hashing. *Journal of Advanced Transportation*, 2020. <https://doi.org/10.1155/2020/3828395>
- Zhao, P., Yuan, Y., & Guo, T. (2022). Extensible Hierarchical Multi-Agent Reinforcement-Learning Algorithm in Traffic Signal Control. *Applied Sciences (Switzerland)*, 12(24). <https://doi.org/10.3390/app122412783>
- Zheng, Q., Xu, H., Chen, J., Zhang, D., Zhang, K., & Tang, G. (2022). Double Deep Q-Network with Dynamic Bootstrapping for Real-Time Isolated Signal Control: A Traffic Engineering Perspective. *Applied Sciences (Switzerland)*, 12(17). <https://doi.org/10.3390/app12178641>
- Zou, Y., Liu, R., Li, Y., Ma, Y., & Wang, G. (2021). Signal adaptive cooperative control of two adjacent traffic intersections using a two-stage algorithm. *Expert Systems with Applications*, 174. <https://doi.org/10.1016/j.eswa.2021.114746>