

Machine Learning in urban traffic monitoring and demand prediction: systematic review

León Castillo, Marco Antonio¹, Meza Cuya, Piero Antonio² ,
Ibáñez Estrella, José Luis³, Rueda Ñopo, Melisa Isabel⁴

¹Marco Antonio' Universidad Tecnológica del Perú, Perú, u21209679@utp.edu.pe

²Piero Antonio' Universidad Tecnológica del Perú, Perú, u21202821@utp.edu.pe

³Jose Luis' Universidad Tecnológica del Perú, Perú, c31477@utp.edu.pe

⁴Melisa Isabel' Universidad Tecnológica del Perú, Perú, c18750@utp.edu.pe

Abstract- *Rapid urban growth and vehicular congestion have driven the search for technological solutions to improve mobility in urban environments. This systematic review analyzed Machine Learning techniques applied to traffic monitoring and passenger demand prediction. Different approaches used in recent literature were explored, as well as their effectiveness compared to traditional methods.*

The study was conducted following the PICO strategy and PRISMA methodology to ensure a rigorous and transparent process. A systematic search was carried out in scientific databases such as Scopus, IEEE Xplore and Web of Science, initially identifying 660 articles. Using the PICO strategy, the general question and keywords that helped the search for articles were generated. After applying the inclusion and exclusion criteria defined in the PRISMA protocol, 47 relevant studies were selected between 2021 and 2025. The findings were organized to answer four research questions: definition of the urban transportation system, techniques used, effectiveness versus traditional methods, and improvements achieved. It was identified that the most commonly employed techniques included deep neural networks, reinforcement learning, and hybrid models. These tools were applied to tasks such as vehicle flow prediction, incident detection and transportation user behavior analysis. In general, Machine Learning-based models demonstrated significant advantages in accuracy, adaptive capacity and real-time data processing, especially in dynamic urban contexts. It was concluded that Machine Learning represents a key tool for the transformation of urban transport systems, contributing to more efficient, resilient and data-driven planning.

Keywords- *Machine Learning, Urban transportation, Traffic monitoring, Demand forecasting.*

Machine Learning en el monitoreo del tráfico urbano y predicción de demanda: revisión sistemática

Resumen- El crecimiento urbano acelerado y la congestión vehicular han impulsado la búsqueda de soluciones tecnológicas para mejorar la movilidad en entornos urbanos. Esta revisión sistemática analizó las técnicas de Machine Learning aplicadas al monitoreo del tráfico y la predicción de la demanda de pasajeros. Se exploraron diferentes enfoques utilizados en la literatura reciente, así como su efectividad en comparación con métodos tradicionales. El estudio se realizó siguiendo la estrategia PICO y la metodología PRISMA para garantizar un proceso riguroso y transparente. Se llevó a cabo una búsqueda sistemática en bases de datos científicas como Scopus, IEEE Xplore y Web of Science, identificando inicialmente 660 artículos. Usando la estrategia PICO, se generó la pregunta general y las palabras clave que ayudaron a la búsqueda de artículos. Luego de aplicar los criterios de inclusión y exclusión definidos en el protocolo PRISMA, se seleccionaron 47 estudios relevantes entre el año 2021 y 2025. Los hallazgos fueron organizados para responder a cuatro preguntas de investigación: definición del sistema de transporte urbano, técnicas utilizadas, eficacia frente a métodos tradicionales y mejoras logradas. Se identificó que las técnicas más empleadas incluyeron redes neuronales profundas, aprendizaje por refuerzo y modelos híbridos. Estas herramientas fueron aplicadas a tareas como la predicción del flujo vehicular, la detección de incidentes y el análisis del comportamiento de los usuarios del transporte. En general, los modelos basados en Machine Learning demostraron ventajas significativas en precisión, capacidad de adaptación y procesamiento de datos en tiempo real, especialmente en contextos urbanos dinámicos. Se concluyó que el Machine Learning representa una herramienta clave para la transformación de los sistemas de transporte urbano, contribuyendo a una planificación más eficiente, resiliente y basada en datos.

Palabras clave- Machine Learning, Transporte urbano, Monitoreo de tráfico, Predicción de demanda

I. INTRODUCCIÓN

El crecimiento acelerado de las ciudades y el proceso de urbanización han generado una presión creciente sobre los sistemas de transporte, especialmente en países en vía de desarrollo. Esta expansión urbana no planificada ha derivado en congestión vehicular crónica, ineficiencias operativas y una experiencia negativa para la ciudadanía. Frente a este panorama, las tecnologías emergentes han comenzado a desempeñar un rol protagónico en la búsqueda de soluciones más eficientes, sostenibles y dinámicas. En el campo del monitoreo y la gestión del tráfico urbano, el Machine Learning (ML) se ha consolidado como una herramienta poderosa para analizar grandes volúmenes de datos en entornos urbanos complejos, permitiendo predecir condiciones del tráfico, identificar patrones de movilidad y anticipar la demanda de pasajeros [1], [2]. Estudios recientes han mostrado avances significativos en este campo, por ejemplo, se han implementado sistemas competitivos de clasificación del estado del tráfico mediante ML [1] y modelos como STGCN-LSTM combinados con algoritmos PPO [3], logrando una optimización notable del flujo vehicular y la reducción de la congestión. Asimismo, el uso del Internet de las Cosas (IoT) ha fortalecido estas soluciones al proporcionar datos en tiempo real provenientes de sensores, cámaras y dispositivos móviles, lo que incrementa la

precisión de las predicciones y la capacidad de respuesta [2]. Además, investigaciones recientes destacan que la proximidad a características urbanas, como espacios públicos y nodos de transporte, mejora significativamente la precisión de los modelos predictivos de tráfico, al integrar factores contextuales que suelen ser ignorados por enfoques más tradicionales [4].

En conjunto, estas tecnologías permiten adaptar rutas, ajustar la temporización de semáforos, redistribuir recursos y diseñar respuestas ágiles ante eventos inesperados. No obstante, la adopción de estos enfoques aún es limitada, lo que restringe la toma de decisiones basadas en evidencia y obstaculiza el desarrollo de un transporte verdaderamente inteligente. Pese a los avances internacionales en la aplicación de Machine Learning e IoT para la gestión del tráfico urbano, su implementación en algunos países latinoamericanos es ineficiente. Actualmente, la planificación del transporte todavía se sustenta en métodos tradicionales que no se ajustan a los cambios dinámicos del entorno urbano, generando efectos adversos como alta congestión, ineficiencia en la asignación de recursos y tiempos excesivos de espera para los usuarios [1], [2]. Diversas investigaciones han evidenciado el potencial del ML para clasificar condiciones del tráfico y optimizar rutas. Por ejemplo, el trabajo de Nasution et al. [1] propone un sistema de clasificación inteligente con altos niveles de precisión, mientras que Rajha et al. [4] demuestran que la integración de datos espaciales urbanos y el entorno físico mejora sustancialmente las predicciones de tráfico. A su vez, Patil et al. [5] exploran algoritmos de refuerzo como el Double Q-Learning para encontrar rutas óptimas. La elección de este tema responde a la necesidad urgente de modernizar la gestión del tráfico urbano, aprovechando herramientas científicas y tecnológicas de probada eficacia. Tecnologías inteligentes como el Machine Learning y el IoT están revolucionando los sistemas de transporte en diversas ciudades del mundo, gracias a su capacidad para anticipar la demanda, redistribuir flujos vehiculares en tiempo real y reducir significativamente la congestión [2], [3]. Ante el crecimiento del uso de tecnologías avanzadas y la brecha de conocimiento en la planificación del transporte urbano en contextos con realidades similares a la peruana, este estudio se propuso analizar y clasificar las diversas técnicas de machine learning aplicadas al monitoreo del tráfico y la predicción de la demanda de pasajeros. El objetivo de la presente RSL, fue analizar el Machine Learning en el monitoreo del tráfico urbano y predicción de demanda. El presente documento se encuentra organizado en cinco secciones para facilitar su comprensión. La Introducción establece el contexto de la investigación, el problema abordado,

su justificación y los objetivos planteados. A continuación, la sección de Metodología describe detalladamente el método utilizado para la Revisión Sistemática de la Literatura (RSL), incluyendo la estrategia PICO, la formulación de la pregunta general de investigación y los criterios de inclusión y exclusión aplicados mediante PRISMA para la selección de artículos. Posteriormente, la sección de resultados organiza y presenta la información obtenida de los trabajos seleccionados, respondiendo a las preguntas PICO a través de tablas y agrupaciones temáticas. Seguidamente, la discusión aborda la importancia de los hallazgos más relevantes, contextualizándolos críticamente. Finalmente, en las conclusiones, se sintetizan los principales resultados del estudio, se reafirma el objetivo de investigación, se presentan las limitaciones de la RSL y se sugieren futuras vías para la investigación.

II. METODOLOGÍA

Una Revisión Sistemática de la Literatura (RSL) es un enfoque metodológico que permite recopilar, evaluar e interpretar de manera estructurada los estudios existentes sobre un área de conocimiento, con el fin de obtener conclusiones a partir de la evidencia disponible. En este estudio, se realizó una RSL con el propósito de identificar, analizar y comparar los enfoques basados en técnicas de Machine Learning aplicados al monitoreo del tráfico en entornos urbanos, evaluando su efectividad frente a métodos tradicionales. Para organizar el proceso de búsqueda y formulación de preguntas de investigación, se utilizó la estrategia PICO, la cual permite descomponer la necesidad de información en componentes clave: Población, Intervención, Comparación, Resultado y opcionalmente, Contexto y Tiempo. Esta estructura facilitó la construcción de la pregunta principal ¿Qué enfoques basados en técnicas de machine learning se han aplicado al monitoreo del tráfico en sistemas de transporte urbano, y qué mejoras se han logrado en comparación con los métodos tradicionales? y de subpreguntas específicas para cada componente, así como la selección de palabras clave relevantes para la búsqueda sistemática en bases de datos científicas, como se evidencia en la Tabla I.

TABLA I
ESTRATEGIA PICO

Componente	Pregunta	Palabras Clave
P: Población/Problema	¿Cómo se define el sistema de transporte urbano?	Urban transportation system, Urban transport authorities
I: Intervención	¿Qué técnicas de machine learning se han utilizado para el monitoreo del tráfico?	Machine Learning, Traffic monitoring
C: Comparación	¿Cuál es la eficacia en comparación con los métodos tradicionales?	Conventional transport models, Traffic improvement, Performance comparison
O: Resultado	¿Cómo ha contribuido el machine learning a la mejora del monitoreo de tráfico?	Machine Learning, Traffic management, Smart cities

La búsqueda sistemática se realizó en las siguientes bases de datos: Scopus, IEEE y Web of Science, seleccionadas por su

relevancia y cobertura en publicaciones científicas de alto impacto. En cada una se aplicó una ecuación de búsqueda adaptada pero equivalente, formulada a partir de combinaciones entre los términos clave definidos previamente en la Tabla I. Estas ecuaciones fueron ajustadas según la sintaxis y los filtros disponibles en cada plataforma, asegurando coherencia en los criterios de búsqueda. En la Tabla II se detallan las bases de datos utilizadas, junto con las ecuaciones de búsqueda aplicadas y la fecha exacta en que se realizó la búsqueda en cada una de ellas.

TABLA II
ECUACIONES DE BÚSQUEDA

Base de Datos	Ecuación Empleada	Fecha de Búsqueda
Scopus	TITLE-ABS-KEY ("Smart cities" OR "Urban transport authorities") OR TITLE-ABS-KEY ("Machine Learning" OR "Traffic monitoring") OR TITLE-ABS-KEY ("Conventional transport models" OR "Performance comparison") OR TITLE-ABS-KEY ("Traffic improvement" OR "Traffic management") AND TITLE-ABS-KEY ("Urban transportation system") AND PUBYEAR > 2019	22 de abril de 2025
IEEE Xplore	("All Metadata":Machine Learning) AND ("All Metadata":traffic management) AND ("All Metadata":traffic monitoring) AND ("All Metadata":smart cities) Refined By: Year: 2020-2025	7 de mayo de 2025
Web of Science	(ALL=(Smart cities) AND ALL=(Urban transport authorities) AND ALL=(Machine Learning) AND ALL=(Traffic monitoring) AND ALL=(Conventional transport models) AND ALL=(Performance comparison) AND ALL=(Traffic improvement) AND ALL=(Traffic management) OR ALL=(Urban transportation system)) AND (DT=("REVIEW" OR "ARTICLE") AND OA=("OPEN ACCESS") AND PY=("2025" OR "2024" OR "2023" OR "2022" OR "2021") AND OAJ=("ALL OPEN ACCESS") AND OA=("OPEN ACCESS") AND DT=("REVIEW"))	3 de mayo de 2025

Así también, como se evidencia en la tabla III y IV se establecieron criterios de inclusión y exclusión con el propósito de filtrar de manera sistemática los estudios más relevantes y alineados con los objetivos de la revisión. Los criterios de inclusión delimitaron los elementos mínimos requeridos para considerar un estudio dentro del análisis. Por otro lado, los criterios de exclusión permitieron descartar trabajos que, aunque relacionados, no contribuían directamente a los objetivos del análisis.

TABLA III
CRITERIOS DE INCLUSIÓN

Código	Criterio
CI1	Estudios que empleen técnicas de machine learning
CI2	Que aborden la gestión del tráfico urbano o la predicción de la demanda de pasajeros, en sistemas de transporte público.
CI3	El ámbito del estudio abarca al menos el nivel de ciudad.

TABLA IV
CRITERIOS DE EXCLUSIÓN

Código	Criterio
CE1	Estudios centrados principalmente en diseño de infraestructura o políticas

CE2	Trabajos que se enfoquen exclusivamente en la demanda o tráfico de vehículos privados, sin relación con entornos urbanos más amplios.
CE3	Investigaciones que no utilicen tecnologías como Machine Learning para monitorear, predecir o gestionar el tráfico urbano.
CE4	Investigaciones que dentro de sus aportes no cumplan con la capacidad de aportar respuestas a las preguntas PICO planteadas.

Para guiar el proceso de selección de los estudios, se aplicó la metodología PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), que permitió estructurar de manera clara y transparente el propósito de la revisión. Para la etapa de identificación de investigaciones se recopiló de las bases de datos Scopus (189), IEEE Xplore (129) y Web Of Science (342) un total de 660 artículos. En el primer filtro se eliminó 3 artículos por ser duplicados quedando 657. En el segundo filtro de selección, correspondiente al cribado, se excluyeron 445 artículos por no presentar títulos, resúmenes y/o palabras clave relacionados con la temática de estudio obteniendo 212 artículos. En el tercer filtro, donde se evaluó la disponibilidad del texto completo en formato PDF o HTML, se excluyeron 45 documentos quedando 167. En el cuarto filtro, correspondiente a la etapa de elegibilidad, donde se realizó la revisión de texto completo y aplicación de los criterios de inclusión y exclusión, se excluyeron 120 artículos obteniéndose Finalmente, para la etapa de inclusión 47 artículos para la revisión sistemática como se denota en la Figura 1.




Fig. 1 Diagrama de flujo PRISMA

III. RESULTADOS

A. Organización de la información

En la Figura 2, se observa que, al agrupar los artículos seleccionados para la revisión sistemática por año de publicación, el 2024 concentra la mayor cantidad con 16 artículos, seguido por el 2025 con 13. Luego, se ubicaron los

años 2023, 2022 y 2021 con 10, 6 y 2 artículos, respectivamente.




Fig. 2 Años de publicación de los artículos

B. Artículos más citados

En la Figura 3, se evidencia los diez artículos más citados incluidos en la revisión sistemática. El artículo con mayor número de citas fue el de los autores Weiwei Jiang y Jiayun Luo, titulado “*Graph Neural Network for Traffic Forecasting: A Survey*”, con un total de 524 citas de la web of Science [6].




Fig. 3 Cantidad de citas por artículo.

C. Origen de los artículos

En la Figura 4, se muestra la distribución de artículos por país mediante un gráfico circular 3D. se observa que, China fue el país con el mayor número de publicaciones incluidas en la revisión sistemática, con un total de 20 artículos equivalente al 42.6%.




Fig. 4 Distribución por país.

D. Revistas de Publicación:

En la Figura 5, se presenta el recuento de los artículos incluidos para la revisión sistemática agrupados según la revista en la que fueron publicados. Se observa que IEEE Access es la revista con mayor número de artículos, con un total de 7 publicaciones. Le sigue Journal of Advanced Transportation con 6 artículos, y en tercer lugar Sustainability con 5 artículos. Finalmente, las revistas Smart Cities y Electronics cuentan con 3 y 2 artículos, respectivamente. Estos datos corresponden a 5 de las revistas con mayor frecuencia de aparición en el conjunto de estudios seleccionados.




Fig. 5 Conteo de artículos por revista de publicación.

E. Recolección de la información

A partir de los artículos reunidos para el desarrollo de la RSL, se responderán las preguntas PICO, planteadas inicialmente en la tabla I.

P1: ¿Cómo se define el sistema de transporte urbano?

En la Tabla V se presenta la definición del sistema de transporte urbano según distintos autores, agrupadas por similitud temática, de las cuales se tiene una definición básica, una definición en base a la gestión y optimización de tráfico, en referencia al sistema de transporte urbano como un sistema multimodal y una red de transporte, con respecto a las tecnologías emergentes, una definición que lo aborda como un sistema a modelar y en cómo se define bajo el contexto de ciudades inteligentes. De los resultados analizados, solo se consideraron 20 artículos, ya que los restantes no ofrecieron una definición clara y concisa del concepto, al centrarse en otros aspectos del estudio. En primer lugar, varios estudios definieron el sistema de transporte urbano básicamente como una infraestructura fundamental para las ciudades modernas, caracterizada por su complejidad, conformada por múltiples elementos y en constante transformación, lo que la hacía impredecible [6][7]. Asimismo, se consideró vital para el desarrollo económico y la mejora en la calidad de vida, al promover un sistema limpio, inteligente y resiliente [8][9][10]. Desde el enfoque de gestión y optimización del tráfico, el sistema de transporte urbano fue definido como un conjunto de prácticas basadas en el control de señales de tráfico para regular la congestión vehicular. Los semáforos de tiempo fijo fueron considerados elementos centrales en estas estrategias, aunque se reconoció su ineficacia para cumplir dicha función en contextos complejos [11][12]. Además, se lo concibió como una infraestructura estrechamente vinculada a la planificación urbana, compuesta por intersecciones, carriles y vehículos gestionados mediante estrategias orientadas a optimizar su eficiencia [13][14]. En otros estudios, el sistema de transporte urbano se describió como una red multimodal que incluye transporte público, metro, camiones y vehículos de pasajeros, todos interconectados e interactuando de forma constante para facilitar una mejor gestión del flujo vehicular [15][16][17][18]. Desde una perspectiva centrada en el uso de datos y tecnologías emergentes, el sistema fue definido como uno inteligente, capaz de integrar múltiples tecnologías, operadores de transporte y servicios de taxi. Este enfoque buscó mejorar la eficiencia general y equilibrar la oferta y la demanda en tiempo real

mediante el uso de predicciones [19][20]. La red integrada de elementos se apoyó en servidores de procesamiento en tiempo real, con datos gestionados por tecnologías inteligentes que emplearon modelos de lenguaje grandes (LLM) para su administración [21][22]. Para otros autores, el sistema de transporte urbano fue considerado un objeto de modelado. Se representó mediante grafos que definían intersecciones, conexiones entre ellas y sus relaciones espaciales y temporales, con el propósito de optimizar rutas y reducir la congestión [23][5]. Finalmente, en el contexto de las ciudades inteligentes, se abordó como un marco de estudio centrado en la mejora de servicios existentes de transporte público, incorporando la movilidad activa y la micro movilidad, y adaptando nuevas soluciones tecnológicas para su despliegue [24].

TABLA V

DEFINICIÓN DE SISTEMA DE TRANSPORTE URBANO

Temática	Definición
Definición básica	- El sistema de transporte urbano es una de las infraestructuras más importantes en las ciudades modernas, fundamental para facilitar los desplazamientos diarios de millones de personas que se ha vuelto más complejo con el paso de los años [6] - El sistema de transporte urbano es un conjunto complejo de elementos diversos, caracterizado por su constante cambio y la impredecibilidad de algunos de sus aspectos. [7] - El sistema de transporte urbano es vital para la prosperidad económica y la conectividad social, ya que facilita la circulación de las personas dentro de la ciudad. [8] - El sistema de transporte urbano y público se define como uno de los elementos más importantes que impactan la calidad de vida en la mayoría de las ciudades [9] - El sistema de transporte público urbano se define como un elemento central para las economías mundiales y para la vida de las personas, siendo un sistema que busca ser limpio, inteligente y resistente. [10]
Gestión y Optimización del Tráfico	-La gestión del sistema de transporte y tráfico urbano se define como un conjunto de prácticas que se basan en el control de señales de tráfico, cuyo propósito es regular el flujo vehicular en los principales puntos de congestión. Aun así, se ha observado que los semáforos tradicionales de tiempo fijo resultan ineficaces para esta tarea. [11] - El sistema de transporte urbano está relacionado con la optimización del tráfico, siendo los semáforos un elemento central en sus estrategias de control. [12] - El sistema de transporte urbano es una infraestructura que se encuentra intrínsecamente ligada a la planificación urbana, siendo un factor determinante que influye directamente en el movimiento, el desarrollo y la organización de los espacios urbanos. [13] - El sistema de transporte urbano es un entorno integrado que combina la infraestructura vial, incluyendo intersecciones y carriles, con una diversidad de vehículos, tanto autónomos como tradicionales. Este sistema se gestiona mediante estrategias dinámicas que buscan optimizar su eficiencia. [14]
Sistemas Multimodales y Redes de Transporte	-El sistema de transporte urbano es una serie de modos que incluyen el transporte público, como autobuses, tranvías y metro. La eficiencia y sostenibilidad de estos componentes son fundamentales para resolver los problemas de congestión urbana [15] - El sistema de transporte urbano es una red de transporte público multimodal (MPTN) que integra modos como el metro y los autobuses. Esta red está diseñada específicamente para aliviar la congestión en áreas metropolitanas. [16] - El sistema de transporte urbano es un sistema compuesto por múltiples modos de tráfico interconectados, que

	interactúan de manera constante debido al comportamiento de los pasajeros [17] - El sistema de transporte urbano se describe como una red multimodal que engloba tanto vehículos de pasajeros como camiones. Esta red se conceptualiza como dividida en "reservorios" interconectados, cuyas dinámicas se modelan eficazmente mediante el Diagrama Fundamental Macrocópico (MFD). Este enfoque busca optimizar la gestión del flujo vehicular. [18]
Tecnologías Emergentes y Datos en el Transporte Urbano	-El sistema de transporte urbano se define como un sistema inteligente que integra tecnologías avanzadas como sensores, big data, algoritmos de aprendizaje automático y simulación virtual. Su objetivo principal es mejorar la eficiencia general, reducir la congestión vehicular y optimizar la gestión del tráfico. [19] - El sistema de transporte urbano es un ecosistema que integra servicios de taxis y Empresas de Transporte con el fin de ofrecer movilidad bajo demanda. Su gestión busca equilibrar la oferta y la demanda en tiempo real mediante predicciones precisas [20] - El sistema de transporte urbano es una red integrada que abarca diversos elementos clave: desde los residentes, hasta los múltiples modos de transporte disponibles. Su infraestructura vial se apoya en servidores al borde para el procesamiento de datos en tiempo real. [21] - El sistema de transporte urbano, dentro de un marco de gestión avanzada, es una red que abarca tanto sus infraestructuras físicas, como intersecciones y semáforos, así como los dinámicos flujos vehiculares. Este sistema es gestionado mediante tecnologías inteligentes que integran modelos de lenguaje grandes (LLM) lo cual permite una mejora significativa en la gestión del tráfico. [22]
Sistema de Transporte Urbano como modelo	-El sistema de transporte urbano es una infraestructura que, para su análisis y comprensión, se modela conceptualmente como un grafo ($G=(V,E,A)$). En esta representación, V representa el conjunto de nodos como intersecciones, E es el conjunto de aristas que simbolizan las conexiones entre estos nodos, y A es una matriz de adyacencia que codifica las complejas relaciones espaciales y temporales entre ellos. [23] - El sistema de transporte urbano se define como una red compleja compuesta por nodos, que representan intersecciones, y aristas, que simbolizan segmentos de carretera. Su objetivo principal es optimizar las rutas para minimizar los tiempos de viaje y reducir la congestión. [5]
Transporte Urbano y Ciudades Inteligentes	-En el contexto de las ciudades inteligentes, el sistema de transporte urbano se trata como un marco de estudio que examina cómo mejorar los servicios existentes de transporte público y de mercancías. Esto incluye la introducción de la movilidad activa y la micro movilidad, al mismo tiempo que se adapta al despliegue de nuevas soluciones de transporte. [24]

P2: ¿Qué técnicas de machine learning se han utilizado para el monitoreo del tráfico?

En la Tabla VI, se presenta las distintas técnicas de ML utilizadas en diversos estudios, junto con su respectiva aplicación en un ámbito específico, como lo son la predicción del tráfico, gestión de la demanda, la optimización de las señales de tránsito, análisis de elección de modo, detección de incidentes, monitoreo de tráfico, modelado del tráfico, predicción de la movilidad y de la congestión generada. De los resultados analizados, solo se consideraron 32 artículos, ya que los restantes no ofrecieron una descripción clara de los métodos empleados, presentaban información demasiado general o no especificaban el ámbito del monitoreo de tráfico en el que habían sido aplicados. Con lo que respecta a la predicción de tráfico, varias técnicas de machine learning fueron empleadas. Las redes neuronales recurrentes (RNN), LSTM, GRU, y GCN

fueron fundamentales para modelar secuencias temporales y dependencias espaciales en datos de tráfico [25, 26, 27, 28, 29]. Para la predicción de flujo y tiempo de viaje, se utilizaron modelos tradicionales como ARIMA, K-NN y SVR [13, 15, 30]. Otros enfoques que se aplicaron en la predicción de flujo vehicular y la gestión de la demanda fueron métodos de Deep learning como CNN y variantes híbridas (RNN+CNN/GNN/atención) [6, 31, 17, 32, 33, 34, 35]. La optimización de semáforos representó un área significativa de aplicación debido a su contribución a la mejora de la eficiencia del tráfico, algoritmos de aprendizaje por refuerzo (RL) como Q-learning, DQN, Double Q-learning, y sus variantes Deep RL (DRL) fueron implementados para controlar dinámicamente las fases semafóricas [36, 37, 5, 12, 38, 24]. Además, se integraron algoritmos de optimización como PSO, GA y ACO, así como Lógica Difusa (FL) y modelos híbridos (por ejemplo, PSO + Q-Learning) para la optimización de semáforos y la predicción de carga de tráfico [39]. Para el análisis del comportamiento de elección modal, optimización de rutas y la predicción de la demanda, se recurrió a técnicas como Random Forest (RF), XGBoost, Redes Neuronales (ANN/DNN/CNN), SVM, K-Nearest Neighbors (KNN), Naïve Bayes y AdaBoost [2, 13, 15, 33, 40]. En la detección de incidentes y anomalías, se utilizaron YOLO para la detección vehicular y modelos basados en Transformers como Graph Multi-Resolution Transformer (GMRT) para un análisis a nivel de carril [37, 41]. En el ámbito más amplio del monitoreo y gestión del tráfico, se aplicaron modelos para diversas tareas. Esto incluyó la predicción del flujo vehicular y la detección de cuellos de botella utilizando regresión lineal y K-Means [19]. La predicción de accidentes y la detección de puntos críticos se abordaron con Random Forest, Deep Neural Networks (DNN) y K-Nearest Neighbors (KNN) [2]. Para la extracción de información estática y dinámica del tráfico, como la velocidad y eventos, se empleó Faster R-CNN [29]. Se utilizaron algoritmos de aprendizaje no supervisado como DBSCAN, K-Means, Affinity Propagation, Mean Shift y Gaussian Mixture Models (GMM) para identificar patrones ocultos y tendencias en datos de tráfico [42]. En contextos avanzados de gestión y modelado inteligente del tráfico urbano, se incorporaron Modelos de Lenguaje de Gran Escala (LLMs) como GPT-3.5 y GPT-4, combinados con Modelos Fundamentales de Tráfico (TFMs) y técnicas de aprendizaje por refuerzo [22]. Además, los Graph Neural Networks (GNNs) fueron utilizados para la predicción de movilidad humana y la asignación de tráfico en redes urbanas complejas [43]. El modelado de decisiones y el comportamiento adaptativo en la gestión del tráfico se apoyaron en redes bayesianas y modelos basados en BDI [44]. Finalmente, la predicción de la congestión de tráfico se analizó con una revisión exhaustiva de modelos lineales, basados en árboles y una amplia gama de deep learning y enfoques híbridos [45]. Un modelo de aprendizaje multitarea (MTL) que integra GCN, LSTM y un mecanismo de atención, así como un modelo M2-former (combinando GCN, atención temporal y codificadores-

decodificadores multitarea), fueron propuestos para la predicción avanzada del tráfico y el flujo de entrada a nivel de red [20, 17].

TABLA VI
TÉCNICAS DE MACHINE LEARNING EMPLEADAS

Ámbito de aplicación	Artículos	Técnicas y aplicación
Predicción de tráfico	[25][26][27][28][29]	Deep Learning como Redes Neuronales Recurrentes (RNN), LSTM, GRU, y Redes Neuronales Gráficas (GCN, GAT, DCRNN, GraphSAGE, MPNN), para modelar secuencias y dependencias en datos de tráfico.
Predicción de flujo y tiempo de viaje	[13][15][30]	ARIMA, K-NN, SVR, SVM, Random Forest (RF) y Regresión Lineal, junto con redes neuronales (ANN, DNN, CNN, LSTM, BP, híbridos Kalman-BP) y filtro de Kalman. Estas técnicas se usaron para la predicción del flujo y tiempo de viaje
Predicción de flujo y gestión de la demanda	[6][17][31][32][33][34][35]	Deep Learning como CNN, LSTM (incluyendo BI-LSTM y CONV-BI-LSTM), GRU, MLP, y variantes híbridas como DGCN-TTE (que combina GCN y GRU con atención, además de aprendizaje multitarea). También se utilizaron Random Forest (RF) y XGBoost. Estas técnicas fueron empleadas para la predicción del flujo vehicular y la gestión de la demanda,
Optimización y Control de Semáforos	[5][12][24][36][37][38][39]	Aprendizaje por Refuerzo (RL), incluyendo Q-learning, Deep Q-Networks (DQN), Double Q-Learning y Deep RL (DRL), como el modelo AOCITL. Estos fueron fundamentales para controlar dinámicamente las fases semafóricas y optimizar semáforos en intersecciones, mejorando la eficiencia y la gestión del tráfico. Lógica Difusa (FL), Redes Neuronales Artificiales (ANN), Deep Learning, árboles de decisión, y optimización como PSO, GA y ACO para predecir la carga de tráfico, aprender rutas óptimas en tiempo real y optimizar planes semafóricos.
Análisis de elección modal, optimización de rutas y predicción de la demanda	[2][13][15][33][40]	Random Forest (RF), XGBoost, K-Nearest Neighbors (KNN), SVM, Gradient Boosting, Naïve Bayes y AdaBoost, Redes Neuronales (ANN, DNN, CNN, MLP). También se empleó el método SHAP para el análisis de explicabilidad. Estas herramientas fueron aplicadas para el análisis del comportamiento de elección modal urbano, la optimización de rutas y la predicción de la demanda de pasajeros
Detección de incidentes y anomalías	[37][41]	YOLO para la detección vehicular y modelos basados en Transformers (GMRT) para el análisis a nivel de carril y Lógica Difusa (FL) y Aprendizaje por Refuerzo (RL/DRL), siendo clave en la detección de incidentes y anomalías en el tráfico.
Monitoreo y gestión del tráfico	[19][22][29][42]	Regresión Lineal, K-Means, ARIMA, Random Forest, Deep Neural Networks (DNN), K-Nearest Neighbors (KNN) y Faster R-CNN. Estas herramientas fueron utilizadas para la predicción de flujo vehicular, detección de cuellos de botella, predicción de accidentes, detección de puntos críticos, extracción de información estática y dinámica del tráfico, e identificación de patrones y tendencias mediante algoritmos de aprendizaje no supervisado (DBSCAN, Mean Shift, GMM).
Gestión y modelado del tráfico urbano	[22]	Modelos de lenguaje de gran escala (LLMs) como GPT-3.5 y GPT-4, combinados con Modelos Fundamentales de Tráfico (TMs) que incluyen algoritmos de análisis de tráfico.
Predicción de movilidad humana	[43][44]	Graph Neural Networks (GNNs) y Aprendizaje por Refuerzo (RL) para la predicción de movilidad humana y la asignación de tráfico en redes urbanas complejas. Redes bayesianas y modelos basados

		en BDI (Belief-Desire-Intention) para el modelado de decisiones
Predicción de la congestión de tráfico	[45][20][17]	Para la predicción de la congestión de tráfico y el flujo de entrada a nivel de red, se usaron modelos lineales (LR, MLR, Ridge), modelos basados en árboles (Decision Trees, Extra Trees), y una amplia gama de enfoques de Deep Learning (LSTM, CNN). Se destacaron modelos de aprendizaje multitarea (MTL) que integran GCN, LSTM y mecanismos de atención, incluyendo el modelo M2-former

P3: ¿Cuál es la eficacia en comparación con los métodos tradicionales?

En la Tabla VII, se presentaron comparaciones entre técnicas de machine learning (ML) y diversos métodos tradicionales aplicados a la gestión del tráfico y la demanda de pasajeros. Estas comparaciones se agruparon en función del tipo de análisis realizado en los estudios revisados, desde evaluaciones cuantitativas directas frente a modelos estadísticos clásicos, hasta mejoras estructurales derivadas del diseño del sistema o la arquitectura del modelo. Cabe señalar que 18 estudios quedaron fuera de este análisis específico debido a que no ofrecían una comparación explícita o suficientemente clara frente a enfoques tradicionales. En primer lugar, se identificaron múltiples evaluaciones cuantitativas frente a modelos estadísticos clásicos como ARIMA (AutoRegressive Integrated Moving Average, modelo para series temporales estacionarias y lineales), SVR (Support Vector Regression, regresión basada en márgenes máximos) y MNL (Multinomial Logit, modelo probabilístico para decisiones múltiples). En estos trabajos, enfoques de aprendizaje profundo como RNN (Recurrent Neural Network), LSTM (Long Short-Term Memory, capaz de capturar dependencias a largo plazo) y DGCN-TTE (Dynamic Graph Convolutional Network for Travel Time Estimation, red convolucional en grafos para estimar tiempos de viaje) mostraron consistentemente menores tasas de error, mayor precisión y una mejor capacidad para manejar relaciones no lineales y series temporales no estacionarias [25][27][46][14][34][35]. Modelos más avanzados, como HTF-NET (Hybrid Temporal Fusion Network, red híbrida que integra múltiples escalas temporales) y MGCAF (Multigraph Cross-Attention Fusion, arquitectura que incorpora mecanismos de atención cruzada en múltiples grafos), también destacaron por reducir significativamente los errores frente a ARIMA y redes anteriores, tanto en contextos urbanos simples como en escenarios de alta variabilidad [35][32]. Con respecto a las comparaciones con modelos clásicos de machine learning (por ejemplo, SVM, RF y regresión logística), varios estudios exploraron versiones híbridas, mejoradas o con técnicas de optimización avanzada. Estrategias como XGBoost-CNN (combinación de árboles de decisión optimizados con redes convolucionales) [46], CNN-PSO (red convolucional optimizada mediante algoritmos de enjambre de partículas) [31] y MLP (Multilayer Perceptron, red neuronal con capas totalmente conectadas) con selección de características [12] superaron a sus contrapartes tradicionales en precisión, robustez y velocidad de inferencia. Estas mejoras

fueron especialmente notables en tareas como la clasificación de accidentes, la detección de congestión y la predicción de flujos en entornos complejos o de alta densidad vehicular [46][37][47][31]. Desde una perspectiva centrada en sistemas estáticos o reglas predefinidas, se observaron mejoras relevantes mediante el uso de técnicas como Reinforcement Learning (RL) y Multi-Agent Reinforcement Learning (MARL, aprendizaje por refuerzo multiagente). Estas metodologías, orientadas al control adaptativo del tráfico, reportaron reducciones significativas en tiempos de espera, longitud de colas y duración de los viajes, así como incrementos en eficiencia operativa y adaptabilidad ante cambios inesperados en el entorno urbano. Por ejemplo, modelos como AOCITL (Adaptive Online Cooperative Intersection Traffic Light Control) y el Tree Method (algoritmo basado en estructuras arbóreas para toma de decisiones) lograron reducir los tiempos promedio de viaje hasta en un 40% bajo condiciones disruptivas, como accidentes o picos de tráfico [24][36][33][15][9][39]. Asimismo, se incluyeron estudios enfocados en el desempeño predictivo general, los cuales evidenciaron incrementos significativos en precisión —en algunos casos superiores al 20%— frente a modelos tradicionales [40][48]. Este grupo de investigaciones destacó también la capacidad de los enfoques basados en aprendizaje profundo (deep learning) y transfer learning (reutilización del conocimiento aprendido en nuevos escenarios) para adaptarse eficazmente a condiciones no observadas durante el entrenamiento, lo cual contrasta con la rigidez de los modelos estáticos en contextos dinámicos y cambiantes [49][2][13]. Por último, algunos estudios abordaron comparaciones estructurales, centradas en mejoras en el diseño del modelo o de la arquitectura del sistema. En estos casos, se evidenciaron ventajas en el uso de enfoques como la diversidad de rutas [16], los mecanismos de atención cruzada (cross-attention, que permiten al modelo enfocarse dinámicamente en distintas partes de la entrada) y las estructuras de grafos multicapas [32][17]. En comparación con arquitecturas tradicionales, estos enfoques mejoraron significativamente la precisión en la predicción de flujos vehiculares y en la clasificación de eventos de tráfico. Además, permitieron una mejor identificación de nodos críticos en redes multimodales y una coordinación más eficiente entre subsistemas de transporte, contribuyendo así a una gestión más integral del sistema [32][17][16].

TABLA VII:
COMPARACIONES REALIZADAS

Categoría Comparativa	Comparación realizada y resultados clave
Evaluación cuantitativa frente a modelos estadísticos tradicionales	Los estudios muestran que modelos de machine learning y deep learning como LSTM, GNN, DGCN-TTE, XGBoost-CNN y RL superan consistentemente a métodos tradicionales como ARIMA, SVR y MNL. Logran mayor precisión (mejores RMSE, MAE, MAPE, F1-score) y eficiencia operativa, reduciendo tiempos de espera, viajes y colas, especialmente en contextos urbanos complejos y no estacionarios.
Comparación con enfoques clásicos de machine	Los modelos híbridos y avanzados, como HTF-NET, MGCAF y Faster R-CNN, superan a enfoques clásicos como SVM, Random Forest y regresión

learning mediante versiones optimizadas o híbridas	logística. Presentan mejoras de hasta 63% en métricas de error y aumentos en precisión y eficiencia, gracias a su capacidad para manejar estructuras complejas, datos tridimensionales y adaptarse al tráfico en tiempo real.
Análisis comparativo con sistemas basados en reglas fijas o control estático	Modelos como Deep Learning, RL (incluyendo MARL y AOCITL), Transfer Learning y M2-former mejoran significativamente frente a sistemas estáticos como semáforos fijos. Reducen retrasos, demoras, colas y emisiones, y se adaptan mejor a entornos urbanos variables, superando las limitaciones de los controles no adaptativos.
Comparación centrada en métricas generales de precisión o desempeño predictivo	Modelos como Random Forest, SVM, Gradient Boosting y CNN-PSO muestran mejores resultados que métodos tradicionales, incluso sin detalles técnicos profundos. Alcanzan precisiones de hasta 99% y reducen entre 20–40% la congestión y los tiempos de viaje, gracias a su capacidad para gestionar relaciones no lineales y escenarios urbanos complejos.
Comparación estructural basada en mejoras de diseño o arquitectura del modelo	Las innovaciones estructurales, como el uso de lógica difusa, ANN, PSO y nuevas métricas (ej. índice de diversidad de rutas), mejoran la identificación de puntos críticos y la coordinación del tráfico. Estas estrategias logran reducciones del 35% en retrasos y aumentan la eficiencia frente a sistemas de control fijo o poco adaptativos.

P4: ¿Cómo ha contribuido el machine learning a la mejora del monitoreo de tráfico?

En la tabla VIII en base al análisis de las mejoras logradas mediante el uso de machine learning (aprendizaje automático) en el monitoreo del tráfico urbano, se identificaron siete grupos temáticos que resumieron los principales aportes reportados por los estudios revisados. No obstante, 14 trabajos no fueron considerados en esta síntesis debido a que, si bien describían aplicaciones de técnicas de ML en contextos urbanos, no proporcionaban evidencia concreta o detallada sobre las mejoras alcanzadas como resultado de su implementación. El primer grupo correspondió a la mejora en la precisión de las predicciones del tráfico, particularmente en variables como el flujo vehicular, los tiempos de viaje y la demanda. Estas mejoras se expresaron mediante métricas cuantitativas como MAE (Mean Absolute Error, error absoluto medio), RMSE (Root Mean Squared Error, raíz del error cuadrático medio) y precisión (accuracy). Los algoritmos de machine learning superaron a los métodos tradicionales al anticipar con mayor confiabilidad el comportamiento del tráfico urbano. [25][29][18][23][45][12][38][22]

El segundo grupo reunió estudios que optimizaron el control del tráfico en tiempo real, especialmente en la gestión de semáforos y la coordinación de intersecciones. Se emplearon técnicas como RL (Reinforcement Learning, aprendizaje por refuerzo), que permitieron a los modelos aprender a tomar decisiones eficaces a través de prueba y error. Esto contribuyó a reducir los tiempos de espera y la congestión vehicular. [26][42][48][5][34][35][24]

El tercer grupo destacó la capacidad de los modelos para procesar grandes volúmenes de datos en tiempo real, facilitando la captura de patrones dinámicos del tráfico. Se utilizaron datos provenientes de sensores, cámaras, dispositivos GPS y redes sociales, y técnicas como DL (Deep Learning, aprendizaje

profundo), aptas para identificar patrones complejos en contextos urbanos variables. [13][8][43][14][32][49] El cuarto grupo se centró en la adaptabilidad de los modelos a condiciones cambiantes, como accidentes, eventos especiales, obras o fenómenos meteorológicos adversos. A diferencia de los enfoques tradicionales, los modelos basados en machine learning se ajustaron dinámicamente a nuevos datos, permitiendo una respuesta flexible ante situaciones imprevistas. [31][9] El quinto grupo abordó la detección automática de incidentes y anomalías en las vías, incluyendo accidentes y comportamientos vehiculares atípicos. Se aplicaron técnicas de clasificación, detección de anomalías y modelos de visión por computadora como CNN (Convolutional Neural Networks, redes neuronales convolucionales), que procesaron imágenes de cámaras de tráfico para identificar eventos inusuales con mayor rapidez y precisión. [50][20][30][17] El sexto grupo reportó mejoras en la eficiencia computacional, con una reducción en los tiempos de procesamiento y un uso más eficiente de los recursos. Esto resultó clave para aplicaciones en tiempo real y en dispositivos con limitaciones de hardware, como los utilizados en sistemas de ciudades inteligentes. [19][2] Finalmente, se identificaron mejoras en el apoyo a la planificación y toma de decisiones en transporte urbano. Los modelos permitieron analizar escenarios futuros, evaluar impactos de políticas y optimizar el diseño de rutas e infraestructura, facilitando decisiones basadas en datos confiables. [27][40][41][44]

TABLA VIII
MEJORAS LOGRADAS

Categoría de mejora	Mejoras logradas
Enfocados en la mejora de precisión de predicciones de flujo vehicular, tiempos de viaje o demanda, con métricas cuantitativas	Los estudios muestran que técnicas avanzadas de machine learning, como RNN, GNN, Transformers y aprendizaje por refuerzo, mejoran significativamente la predicción del tráfico, tiempos de viaje y demanda. Logran reducciones en RMSE y MAE, alta precisión y recall, además de optimizar semáforos, reducir congestión y adaptarse a datos ruidosos, integrándose con IoT y gemelos digitales para operar en tiempo real.
Mejora en la coordinación, sincronización o adaptación dinámica de semáforos y señales.	Modelos como reinforcement learning, clustering espaciotemporal, random forest y redes neuronales gráficas han mejorado la sincronización y adaptación dinámica de semáforos, reduciendo la congestión hasta un 20 % y el tiempo de viaje de forma notable. Estas mejoras se apoyan en la detección de patrones espacio-temporales, la escalabilidad y el uso de datos IoT, con resultados aplicados en ciudades reales como Singapur y Río.
Reducción de congestión, tiempos de viaje y emisiones	Técnicas como SVM, GNN, deep learning y DRL han reducido eficazmente congestión, emisiones y tiempos de viaje en condiciones variables. Destacan modelos como DRL para reconfigurar carriles y PPO-LSTM para sincronizar buses, con mejoras en resiliencia y explicabilidad (ej. SHAP), facilitando políticas de transporte más sostenibles.
Interpretabilidad, explicabilidad y toma de decisiones informada	Modelos como CNN-PSO y árboles de decisión permiten interpretar el comportamiento del tráfico, detectar cuellos de botella y ajustar semáforos

	dinámicamente. Logran mejoras cuantificables en eficiencia del flujo (25 %), reducción de retrasos (18.1 %) y disminución de accidentes, habilitando una gestión proactiva e informada del tráfico urbano.
Enfocados en robustez, resiliencia ante ruido, datos faltantes o condiciones extremas.	Los estudios identifican cinco beneficios clave del ML en tráfico urbano: mayor precisión predictiva, mejor sincronización semafórica, reducción de congestión y emisiones, uso de modelos explicables para decisiones informadas, y resiliencia ante datos incompletos o condiciones cambiantes. Esto refuerza la sostenibilidad y adaptabilidad de los sistemas inteligentes.
Modelado de relaciones espaciales y temporales complejas, multigráficos o detección de patrones estructurales.	El uso de machine learning ha permitido modelar con mayor precisión relaciones espaciotemporales, mejorar la detección de cuellos de botella y optimizar rutas de emergencia. La integración con gemelos digitales y programación lógica (PLC) mejora la simulación y el ajuste operativo en tiempo real, fortaleciendo la resiliencia y sostenibilidad urbana.
Enfocados principalmente en mejoras en seguridad, detección de accidentes, zonas peligrosas, etc.	Machine learning ha mejorado la seguridad vial mediante la detección temprana de accidentes y zonas peligrosas. Modelos como GNNs y GMRT capturan relaciones dinámicas, anticipan efectos en cascada y funcionan bien con datos escasos gracias al aprendizaje auto-supervisado, facilitando decisiones autónomas, planificación dinámica y una operación más segura y sostenible.

IV. DISCUSIÓN

La revisión de la literatura reveló que la definición del sistema de transporte urbano difiere significativamente en función de las prioridades investigativas y el enfoque tecnológico del estudio. Mientras un grupo de estudios lo conceptualizó primariamente como una infraestructura compleja y vital para el desarrollo urbano [6][7][8][9][10], otro enfoque se centró en la gestión del tráfico, viéndolo como un conjunto de prácticas para controlar la congestión mediante señales [11][12][13][14]. Adicionalmente, la perspectiva de una red multimodal interconectada, que describe sus componentes y modos de transporte físicos [15][16][17][18], contrasta con el énfasis en tecnologías emergentes, las cuales redefinen el sistema por su función inteligente y predictiva, equilibrando oferta y demanda mediante datos en tiempo real [19][20][21][22]. Esta distinción subraya la diferencia entre la concepción del sistema basada en sus componentes físicos y su función operativa derivada de los datos obtenidos. Asimismo, la consideración del sistema como un objeto de modelado para la optimización [5], [23] se distingue de su encuadre en el contexto de ciudades inteligentes [24]. En conjunto, estas variaciones en las conceptualizaciones demuestran cómo la comprensión del sistema de transporte urbano se adapta continuamente a los avances socio-tecnológicos, reflejando las diversas lentes desde las cuales se aborda la resolución de sus problemáticas. La aplicación de técnicas de machine learning en el monitoreo del tráfico es variada, adaptándose a cada problemática. Se evidenció una marcada preferencia por el Deep Learning, con Redes Neuronales (RNN, LSTM, GRU, GCN) destacando por su

versatilidad en la predicción de tráfico, flujo vehicular y gestión de la demanda [25][26][27][28][29][6][31][17][32][33][34][35][13][15][30]. Sin embargo, para el control y la optimización dinámica, como la gestión de semáforos, el Aprendizaje por Refuerzo (RL) como por ejemplo Q-Learning fue dominante [36][37][5][12][38][24], indicando que su capacidad de decisión en tiempo real supera la aptitud predictiva del Deep Learning en estos contextos. A pesar de su prominencia, modelos tradicionales como Random Forest, K-NN, SVR, SVM y ARIMA mantuvieron su relevancia para tareas específicas, incluyendo el análisis de elección modal y la detección de cuellos de botella [13][15][30][2][33][40][19], sugiriendo que su menor complejidad o mayor interpretabilidad los posiciona como soluciones eficaces para problemáticas diferentes. A su vez, herramientas especializadas como YOLO y modelos basados en Transformers (GMRT) se incorporaron para la detección de incidentes y anomalías [37][41]. Esta diversidad denota que la eficacia y uso de la técnica se rige por su adecuación al desafío particular del monitoreo del tráfico, buscando un equilibrio entre la abstracción de datos, el control operativo y la interpretabilidad. La evaluación de la eficacia de las técnicas de machine learning frente a los métodos tradicionales en el monitoreo del tráfico reveló una superioridad consistente de los enfoques basados en Deep Learning. Modelos como RNN, LSTM y DGCN-TTE demostraron consistentemente menores tasas de error y mayor precisión al manejar relaciones no lineales y series temporales no estacionarias, superando a estadísticos clásicos como ARIMA, SVR y MNL en la predicción de tráfico y flujo vehicular [25][27][46][14][34][35]. Esta ventaja se extendió a arquitecturas avanzadas como HTF-NET y MGCAF, que lograron reducir errores incluso en escenarios de alta variabilidad [35][32]. En contraste, mientras que modelos tradicionales de machine learning (SVM, RF) son aún relevantes, las versiones híbridas u optimizadas, por ejemplo, XGBoost-CNN, CNN-PSO, demostraron una precisión y robustez superiores en tareas como la clasificación de accidentes y detección de congestión [46][37][47][31]. Asimismo, frente a sistemas estáticos o basados en reglas fijas, las metodologías de Reinforcement Learning (RL) y Multi-Agent RL (MARL) mostraron una adaptabilidad significativamente mayor, logrando reducciones notables en tiempos de espera y de viaje en entornos dinámicos [24][36][33][15][9][39]. Esta clara divergencia subraya que los enfoques de machine learning no solo mejoran el desempeño predictivo, sino que también ofrecen una capacidad de adaptación crucial que los métodos tradicionales no logran replicar en la complejidad del transporte urbano. El Machine Learning ha transformado el monitoreo del tráfico urbano, evidenciando mejoras significativas en varias áreas clave. Principalmente, ha elevado la precisión de las predicciones de flujo vehicular, tiempos de viaje y demanda [25][29][18][23][45][12][38][22], superando notablemente a

los métodos tradicionales. Esta mejora predictiva es fundamental para una gestión proactiva. Si bien la precisión es crucial, la contribución del Reinforcement Learning (RL) ha sido impactante en la optimización del control del tráfico en tiempo real, especialmente en la gestión adaptativa de semáforos [26][42][48][5][34][35][24]. Esto contrasta con la rigidez de los sistemas basados en reglas fijas, ofreciendo una capacidad de aprendizaje dinámico que ha demostrado una reducción más significativa de la congestión. Además, la habilidad del Deep Learning para procesar grandes volúmenes de datos en tiempo real de diversas fuentes [13][8][43][14][32][49] representa una ventaja sustancial sobre las limitaciones de los métodos tradicionales ante la saturación de datos. Estas capacidades han permitido una adaptabilidad superior a condiciones cambiantes [31][9], mejorando la respuesta ante incidentes y eventos imprevistos.

V. CONCLUSIONES

Esta revisión sistemática permitió identificar, analizar y clasificar los enfoques basados en técnicas de machine learning aplicados al monitoreo del tráfico y la predicción de la demanda de pasajeros en entornos urbanos. Se comprobó que estas técnicas han superado consistentemente a los métodos tradicionales tanto en precisión como en adaptabilidad, ofreciendo soluciones más eficaces para abordar la congestión, optimizar semáforos, predecir la movilidad y apoyar la toma de decisiones en sistemas de transporte público urbano. Los modelos basados en deep learning y aprendizaje por refuerzo destacaron como los más utilizados, especialmente en tareas como la predicción de flujo vehicular y la gestión dinámica del tráfico. Como aporte a la literatura existente, esta RSL proporciona una síntesis actualizada y temática de las principales técnicas de machine learning aplicadas al transporte urbano, evidenciando sus beneficios en precisión, eficiencia, adaptabilidad, escalabilidad y apoyo a la planificación. Asimismo, el estudio identificó áreas de aplicación emergentes, como el uso de modelos de lenguaje (LLMs), aprendizaje multitarea y redes de grafos, lo que refuerza la evolución constante del campo. Entre las principales limitaciones del estudio se encuentran la restricción de uso de artículos de acceso cerrado y la concentración de resultados en contextos internacionales, lo que restringe la aplicabilidad directa a realidades locales como la peruana. Por ello, se recomienda que futuras investigaciones se centren en adaptar estos modelos a infraestructuras de transporte de países en desarrollo, así como en explorar enfoques híbridos o colaborativos entre agentes urbanos.

AGRADECIMIENTO/RECONOCIMIENTO

Se reconoce las diversas publicaciones utilizadas en la presente RSL ya que a través de ellas se ha logrado el objetivo de la investigación.

REFERENCIAS

- [1] S. M. Nasution, R. R. Septiawan, R. M. Fikri y B. Dirgantoro, "Traffic Management Enhancement: A Competitive Machine Learning System for Traffic Condition Classification", *International Journal of Transport Development and Integration*, vol. 8, no. 4, pp. 553–567, dic. 2024, doi: 10.18280/ijtdi.080407.

- [2] Z. Miao y Q. Liao, "IoT-Based Traffic Prediction for Smart Cities", *IEEE Access*, vol. PP, no. 99, pp. 1–1, ene. 2025, doi: 10.1109/ACCESS.2025.3552276.
- [3] T. Lin y R. Lin, "Smart City Traffic Flow and Signal Optimization Using STGCN-LSTM and PPO Algorithms", *IEEE Access*, vol. PP, no. 99, pp. 1–1, ene. 2024, doi: 10.1109/ACCESS.2024.3519512.
- [4] R. Rajha, S. Shiode y N. Shiode, "Improving Traffic-Flow Prediction Using Proximity to Urban Features and Public Space", *Sustainability*, vol. 17, no. 1, p. 68, dic. 2024, doi: 10.3390/su17010068.
- [5] M. Patil, P. Tambolkar y S. Midlam-Mohler, "Optimizing Traffic Routes With Enhanced Double Q-Learning", *ET Intelligent Transport Systems*, feb. 2025, doi: 10.1049/itr2.70002.
- [6] W. Jiang and J. Luo, "Graph neural network for traffic forecasting: A survey", *Expert Systems with Applications*, vol. 207, art. no. 117921, Nov. 2022, doi: 10.1016/j.eswa.2022.117921.
- [7] J. Huang, Y. Cui, L. Zhang, W. Tong, Y. Shi, and Z. Liu, "An overview of agent-based models for transport simulation and analysis," *Journal of Advanced Transportation*, vol. 2022, Art. no. 1252534, Feb. 2022, doi: 10.1155/2022/1252534.
- [8] H. Son et al., "Leveraging Advanced Technologies for (Smart) Transportation Planning: A Systematic Review," *Sustainability*, vol. 17, no. 5, Art. no. 2245, Mar. 2025, doi: 10.3390/su17052245.
- [9] M. Keshavarz-ghorabae et al., "mcdm approaches for evaluating urban and public transportation systems: a short review of recent studies," *transport*, vol. 37, no. 6, pp. 411–425, 2022, doi: 10.3846/transport.2022.18376.
- [10] D. Darsena, G. Gelli, I. Iudice, and F. Verde, "Sensing technologies for crowd management, adaptation, and information dissemination in public transportation systems: A review," *IEEE Sensors Journal*, vol. 23, no. 1, pp. 68–87, Jan. 2023, doi: 10.1109/JSEN.2022.3223297.
- [11] C. Gheorghe and A. Soica, "Revolutionizing Urban Mobility: A Systematic Review of AI, IoT, and Predictive Analytics in Adaptive Traffic Control Systems for Road Networks," *Electronics*, vol. 14, no. 4, Art. no. 719, Feb. 2025, doi: 10.3390/electronics14040719.
- [12] Z. Huang, "Reinforcement learning based adaptive control method for traffic lights in intelligent transportation," *Alexandria Engineering Journal*, vol. 106, pp. 381–391, Nov. 2024, doi: 10.1016/j.aej.2024.07.046.
- [13] E. B. Lieberthal, N. Serok, J. X. Duan, G. W. Zeng, and S. Havlin, "Addressing the urban congestion challenge based on traffic bottlenecks," *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 382, no. 2285, Art. no. 20240095, Nov. 2024, doi: 10.1098/rsta.2024.0095.
- [14] J. Shen et al., "Optimizing Urban Intersection Management in Mixed Traffic Using Deep Reinforcement Learning and Genetic Algorithms," *IEEE Access*, vol. 13, pp. 41723–41742, 2025, doi: 10.1109/ACCESS.2025.3547849.
- [15] E. C. Ince, "Mapping the Path to Sustainable Urban Mobility: A Bibliometric Analysis of Global Trends and Innovations in Transportation Research," *SUSTAINABILITY*, vol. 17, no. 4, Art. no. 1480, Feb. 2025, doi: 10.3390/su17041480.
- [16] J. Jia, Y. Huang, W. Zhang, Y. Chen, and Z. Liu, "A Route Diversity–Based Approach for Estimating Vulnerability of Stations in a Multimodal Public Transport Network," *Journal of Advanced Transportation*, vol. 2024, Art. no. 6995651, Nov. 2024, doi: 10.1155/2024/6995651.
- [17] Y. Yang, J. Zhang, L. Yang, and Z. Gao, "Network-wide short-term inflow prediction of the multi-traffic modes system: An adaptive multi-graph convolution and attention mechanism based multitask-learning model," *Transportation Research Part C: Emerging Technologies*, vol. 158, Art. no. 104428, Jan. 2024, doi: 10.1016/j.trc.2023.104428.
- [18] M. Saadullah, Z. Zhang, and H. Hu, "Optimizing multi-modal urban traffic flow: Utilizing macroscopic fundamental diagram and Model Predictive Control," *Control Engineering Practice*, vol. 155, Art. no. 106172, Feb. 2025, doi: 10.1016/j.conengprac.2024.106172.
- [19] S. Shen et al., "Construction of Smart Transportation City System Based on Digital Twins," in *Advances in Transdisciplinary Engineering*, vol. 55, pp. 76–86, 2024, doi: 10.3233/ATDE240377.
- [20] Y. Guo, Y. Chen, and Y. Zhang, "Enhancing Demand Prediction: A Multi-Task Learning Approach for Taxis and TNCs," *Sustainability (Switzerland)*, vol. 16, no. 5, Art. no. 2065, Mar. 2024, doi: 10.3390/su16052065.
- [21] S. M. A. Kazmi, Z. Khan, A. Khan, M. Mazzara, and A. M. Khattak, "Leveraging Deep Reinforcement Learning and Healthcare Devices for Active Travelling in Smart Cities," *IEEE Transactions on Consumer Electronics*, pp. 1–1, Sep. 2024, doi: 10.1109/TCE.2024.3470978.
- [22] S. Zhang et al., "TrafficGPT: Viewing, processing and interacting with traffic foundation models," *Transport Policy*, vol. 150, pp. 95–105, May 2024, doi: 10.1016/j.tranpol.2024.03.006.
- [23] T. Ma, X. Wei, S. Liu, and Y. Ren, "MGCAF: A Novel Multigraph Cross-Attention Fusion Method for Traffic Speed Prediction," *International Journal of Environmental Research and Public Health*, vol. 19, no. 21, Art. no. 14490, Nov. 2022, doi: 10.3390/ijerph192114490.
- [24] I. Mavlutova, D. Atstaja, J. Grasis, J. Kuzmina, I. Uvarova, and D. Roga, "Urban Transportation Concept and Sustainable Urban Mobility in Smart Cities: A Review," *Energies*, vol. 16, no. 8, Art. no. 3585, Apr. 2023, doi: 10.3390/en16083585.
- [25] C. Li, L. Bai, L. A. Yao, S. T. Waller, and W. Liu, "A bibliometric analysis and review on reinforcement learning for transportation applications," *Transportmetrica B-Transport Dynamics*, vol. 11, no. 1, Art. no. 2179461, Dec. 2023, doi: 10.1080/21680566.2023.2179461.
- [26] L. Dedie and M. Vujic, "A review of expert systems integration in signal plan optimisation," *Promet-Traffic & Transportation*, vol. 36, no. 5, pp. 797–817, 2024, doi: 10.7307/ptt.v36i5.601.
- [27] A. Mystakidis, P. Koukaras, and C. Tjortjis, "Advances in traffic congestion prediction: An overview of emerging techniques and methods," *Smart Cities*, vol. 8, no. 1, Art. no. 25, Feb. 2025, doi: 10.3390/smartcities8010025.
- [28] E. T. Alotaibi, T. M. Alhuzaymi, and J. M. Herrmann, "Autonomous mobility on demand: from case studies to standardized evaluation," *Frontiers in Future Transportation*, vol. 4, Art. no. 1224322, Oct. 2023, doi: 10.3389/ffutr.2023.1224322.
- [29] Y. He et al., "In-depth insights into the application of recurrent neural networks (RNNs) in traffic prediction: A comprehensive review," *Algorithms*, vol. 17, no. 9, Art. no. 398, Sep. 2024, doi: 10.3390/a17090398.
- [30] B. Liu, T. Zhang, and W. Hu, "Intelligent Traffic Flow Prediction and Analysis Based on Internet of Things and Big Data," *Computational Intelligence and Neuroscience*, vol. 2022, Art. no. 6420799, 2022, doi: 10.1155/2022/6420799.
- [31] R. Cheng, Y. Jiang, and O. A. Nielsen, "Integrated people-and-goods transportation systems: from a literature review to a general framework for future research," *Transport reviews*, vol. 43, no. 5, pp. 997–1020, Sep. 2023, doi: 10.1080/01441647.2023.2189322.
- [32] G. Mustafa, Y. Hwang, and S.-J. Cho, "Predicting Bus Travel Time in Cheonan City through Deep Learning Utilizing Digital Tachograph Data," *Electronics (Switzerland)*, vol. 13, no. 9, Art. no. 1771, May 2024, doi: 10.3390/electronics13091771.
- [33] L. Tang, C. Tang, Q. Fu, and C. Ma, "Predicting travel mode choice with a robust neural network and Shapley additive explanations analysis," *IET Intelligent Transport Systems*, vol. 18, no. 7, pp. 1339–1354, Jul. 2024, doi: 10.1049/itr2.12514.
- [34] G. Jin, H. Sha, J. Zhang, and J. Huang, "Travel Time Estimation Method based on Dual Graph Convolutional Networks via Joint Modeling of Road Segments and Intersections," *(Journal of Geo-Information Science)*, vol. 25, no. 7, pp. 1500–1513, Jul. 2023, doi: 10.12082/dqxkx.2023.220768.
- [35] H. Ulvi, M. A. Yerlikaya, and K. Yildiz, "Urban Traffic Mobility Optimization Model: A Novel Mathematical Approach for Predictive Urban Traffic Analysis," *Applied Sciences (Switzerland)*, vol. 14, no. 13, Art. no. 5873, Jul. 2024, doi: 10.3390/app14135873.
- [36] F. F. Bastarianto, T. O. Hancock, C. F. Choudhury, and E. Manley, "Agent-based models in urban transportation: review, challenges, and opportunities," *European Transport Research Review*, vol. 15, no. 1, Art. no. 19, Jun. 2023, doi: 10.1186/s12544-023-00590-5.
- [37] L. Peng, X. Liao, T. Li, X. Guo y X. Wang, "An Overview Based on the Overall Architecture of Traffic Forecasting," *Data Science and Engineering*, vol. 9, no. 3, pp. 341–359, Sep. 2024, doi: 10.1007/s41019-024-00246-x.
- [38] T. Lyu, P. R. Wang, Y. N. Gao, and Y. Q. Wang, "Research on the big data of traditional taxi and online car-hailing: A systematic review," *Journal of Traffic and Transportation Engineering-English Edition*, vol. 8, no. 1, pp. 1–34, Feb. 2021, doi: 10.1016/j.jtte.2021.01.001.
- [39] R. K. C. Chan, J. M.-Y. Lim, and R. Parthiban, "Missing traffic data imputation for artificial intelligence in intelligent transportation systems: Review of methods, limitations, and challenges," *IEEE Access*, vol. 11, pp. 34080–34093, 2023, doi: 10.1109/ACCESS.2023.3264216.
- [40] Y. Berhanu, E. Alemayehu, and D. Schroeder, "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*, vol. 2023, Art. no. 6643412, Jul. 2023, doi: 10.1155/2023/6643412.
- [41] D. Park, S.-S. Choi, D. Lim, and Y.-S. Kang, "Graph multi-resolution transformer for road traffic anomaly detection," *IEEE Access*, vol. 13, pp. 27428–27437, 2025, doi: 10.1109/ACCESS.2025.3538836.
- [42] M. K. P. Kumari, D. H. Manjaiah, and K. M. Ashwini, "Clustering algorithms to analyse smart city traffic data," *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 8, pp. 101–107, Aug. 2024.
- [43] Y. Cui and D. Lei, "Optimizing Internet of Things-based intelligent transportation system's information acquisition using deep learning," *IEEE Access*, vol. 11, pp. 11804–11810, 2023, doi: 10.1109/ACCESS.2023.3242116.
- [44] M. Mrabet and M. Sliti, "Integrating machine learning for the sustainable development of smart cities," *Frontiers in Sustainable Cities*, vol. 6, Art. no. 1449404, Dec. 2024, doi: 10.3389/frsc.2024.1449404.
- [45] Q. Zhang, Z. L. Ma, P. F. Zhang, and E. Jenelius, "Mobility knowledge graph: review and its application in public transport," *Transportation*, vol. 52, no. 3, pp. 1119–1145, Jun. 2025, doi: 10.1007/s11116-023-10451-8.
- [46] J. Wu, R. Yang, P. Zhao, and L. Yang, "Computer-aided mobility solutions: Machine learning innovations to secure smart urban transportation," *Sustainable Cities and Society*, vol. 107, Art. no. 105422, Jul. 2024, doi: 10.1016/j.scs.2024.105422.
- [47] Q. X. Sun, G. X. Chu, Q. Li, and Y. Zhang, "Identification of recurrent congestion in main trunk road based on grid and analysis on influencing factors," *Journal of Advanced Transportation*, vol. 2022, Art. no. 4729017, Jun. 2022, doi: 10.1155/2022/4729017.
- [48] E.-J. Kim, Y. Kim, and D.-K. Kim, "Interpretable machine-learning models for estimating trip purpose in smart card data," *Proceedings of the Institution of Civil Engineers-Municipal Engineer*, vol. 174, no. 2, pp. 108–117, Jun. 2021, doi: 10.1680/jmuen.20.00003.
- [49] Y. Tang et al., "Robust Reinforcement Learning Strategies with Evolving Curriculum for Efficient Bus Operations in Smart Cities," *Smart Cities*, vol. 7, no. 6, pp. 3658–3677, Dec. 2024, doi: 10.3390/smartcities7060141.
- [50] J. Wang, C. Zhao, and Z. Liu, "Can historical accident data improve sustainable urban traffic safety? A predictive modeling study," *Sustainability*, vol. 16, no. 22, Art. no. 9642, Nov. 2024, doi: 10.3390/su16