

CAPÍTULO V

Transformación de la movilidad urbana: aplicaciones y perspectivas de la inteligencia artificial

Ibai Laña

Las técnicas de inteligencia artificial y *big data* se han convertido en un fuerte atractor de interés mundial dentro de la industria del transporte. La combinación de tecnologías disruptivas y nuevos conceptos como la *Smart City* actualiza el ciclo de vida de los datos de transporte. En este contexto, la inteligencia artificial se considera una nueva baza para que la industria del transporte gestione eficazmente todos los datos que este sector necesita para ofrecer medios de transporte más seguros, limpios y eficientes, así como para que los usuarios personalicen su experiencia de transporte.

Palabras clave: movilidad urbana, inteligencia artificial, optimización, vehículo autónomo.

1. INTRODUCCIÓN

El volumen y la velocidad a la que se generan hoy en día los datos sobre transporte y movilidad han superado con creces las escalas a las que solían captarse, procesarse y analizarse a principios de este siglo. La combinación de nuevos paradigmas de digitalización como el Internet de las cosas (IoT), la proliferación de *Smart Cities* (Zanella *et al.*, 2014), el fuerte descenso de los costes de almacenamiento de datos en el mercado del silicio, los últimos avances en tecnologías inalámbricas y el uso generalizado y de bajo coste de sensores o dispositivos personales ha mejorado drásticamente la capacidad del ser humano para hacerse una idea más detallada de la realidad del transporte y la movilidad (Meekan *et al.*, 2017) gracias a formas más diversas y actualizadas de recopilar, transmitir, almacenar, fusionar, recuperar y procesar datos sobre el transporte (Stathopoulos *et al.*, 2017). Debido al volumen, la variedad (fuente, tipo y formato) y la variabilidad (cambios frecuentes de datos que complican descifrar su significado exacto dentro de su contexto) de los datos de transporte y movilidad, las tareas intensivas en datos como la integración (Khattak *et al.*, 2017), la visualización (Andrienko *et al.*, 2017), la consulta y el análisis para sistemas a gran escala en tiempo real (Amini *et al.*, 2017) son cada vez más importantes en el diseño y la implantación de sistemas de transporte inteligentes (*ITS*, de su nombre en inglés *Intelligent Transportation Systems*). Es un hecho ampliamente reconocido que las aplicaciones *ITS* actuales presentan funcionalidades limitadas de monitorización y análisis de datos (Suh *et al.*, 2017). Como resultado, los retos mencionados exigen funciones realistas y eficaces de supervisión, toma de decisiones y gestión de datos, cuyos requisitos no suelen cumplir los *ITS* desplegados actualmente. Además, la llegada masiva de fuentes de datos en tiempo real conduce, a través de las técnicas de agregación, fusión y aprendizaje incremental, a conocimientos sin precedentes y mejoras relevantes para la política de servicios, actividades y operaciones de transporte.

En este contexto, las tecnologías de inteligencia artificial (IA) y *big data* se han postulado como herramientas clave para la industria del transporte (Rusitschka y Curry, 2016). Las soluciones que se encuentran dentro de este nuevo paradigma tecnológico permiten capturar, gestionar y analizar enormes volúmenes de datos estructurados y no estructurados para mejorar el dominio del transporte y resolver los retos planteados anteriormente. La respuesta pasa por construir nuevos *ITS* y servicios de movilidad basados en los principios y tecnologías del paradigma *big data* y extraer el valor y los conocimientos de la nueva ingente cantidad de datos disponibles. El objetivo final es garantizar que la industria del transporte obtenga valor de sus datos, lo que en el caso concreto del transporte se traducirá en futuros desarrollos centrados en formas de ofrecer métodos de transporte más seguros, limpios y eficientes y experiencias de transporte agradables a sus usuarios finales. Por otra parte, esta disponibilidad de datos habilita el análisis predictivo y en general las técnicas de modelado basado en datos para aplicarlo a dominios tan diversos como la conducción autónoma, el mantenimiento predictivo de infraestructuras [Jeong *et al.*, 2016; Wang y Guo, 2016], el desarrollo de servicios de movilidad con valor añadido (Fonzzone *et al.*, 2016; Su *et al.*, 2016), una mejor comprensión de las necesidades de los usuarios (Chen *et al.*, 2016)] o la visualización de los flujos de personas y su evolución en las ciudades (Kitchin, 2015).

La inteligencia artificial y el procesamiento masivo de datos están revolucionando el sector del transporte y la logística, ofreciendo oportunidades sin precedentes de eficiencia, optimización e innovación. La transformación que estas tecnologías están aplicando sobre la movilidad urbana es el objeto de este documento, que plantea las principales áreas de actuación de la IA en la movilidad urbana y los caminos a los que se dirige la investigación en este ámbito.

2. DATOS Y SMART CITIES

Los datos son una parte fundamental de la conceptualización de una *Smart City* (Colado, *et al.*, 2014)], y su utilización para mejorar la comprensión de los procesos de una ciudad, así como para definir nuevos tipos de servicios, fomenta el despliegue de más sensores y sistemas de captura de datos. Esta situación favorece que las ciudades inteligentes se comporten como grandes generadores de conjuntos de datos que, a menudo, son publicados en portales de datos abiertos, a disposición de ciudadanos y organizaciones que los pueden utilizar y generar nuevas necesidades que, a su vez, promueven el despliegue de nuevos sistemas de captura de datos.

Dentro del amplio conjunto de ámbitos que abarca el concepto de *Smart City*, los relacionados con la movilidad se pueden compendiar en las siguientes categorías:

- *Gestión de la movilidad urbana.* La perspectiva de la administración pública es esencial en movilidad urbana, ya que es de donde parten las políticas que definen tanto la disponibilidad de infraestructuras y su configuración, como la red de transporte público. Las administraciones son un gran consumidor de datos de movilidad para la toma de decisiones. Desde la generalidad de la elaboración de los planes de movilidad hasta la especificidad de la simulación de la afección al tráfico de una intervención viaria, cualquier medida tomada se ve ampliamente beneficiada si se dispone de datos que permitan analizarla y predecir sus consecuencias. Precisamente por este motivo, las administraciones públicas son, al mismo tiempo, grandes generadores de datos de movilidad, ya que son los entornos donde más sensores y elementos de captura de datos de movilidad se despliegan (Liu y Dijk, 2022).
- *Logística urbana y transporte privado.* Las operaciones de logística urbana han experimentado un incremento notable en los últimos años, debido principalmente al auge del comercio online y al reparto de mercancías asociado al mismo (Lauenstein y Schank, 2022). Además del transporte de bienes, las tecnologías digitales han impulsado la aparición y crecimiento de sistemas privados de transporte de pasajeros alternativos a los tradicionales, e incluyen modalidades nuevas como la movilidad compartida o el transporte a la demanda. Tanto los primeros como los segundos suponen un incremento del tráfico y de la demanda de infraestructuras viarias, así como del impacto que estos tienen en la calidad de vida en las ciudades (Hensher y Puckett, 2024). La optimización de estos sistemas, así como su integración en las lógicas del transporte urbano constituyen un área de investigación prolífica, centrada fundamentalmente en las aproximaciones basadas en datos y en modelos de inteligencia artificial.

- **Vehículo autónomo.** Los vehículos autónomos conectados y cooperativos (CCAV) están emergiendo como una fuerza transformadora en la movilidad urbana. Todos los sistemas que facultan el funcionamiento autónomo de estos vehículos, desde los que permiten la percepción del entorno hasta los que controlan cada uno de sus actuadores para navegar por la red viaria, están basados en técnicas y modelos de inteligencia artificial. Desde el punto de vista de la movilidad urbana, la seguridad, la interacción con otros usuarios de las vías (mucho más variados en entornos urbanos) y las comunicaciones entre las infraestructuras de la ciudad y los vehículos (V2X) son los principales campos de investigación (Campisi *et al.*, 2021). Los CCAV pueden mejorar significativamente la eficiencia y la seguridad del tráfico, planificar mejor las rutas, reducir los atascos y mejorar la fluidez del tráfico. Esta conectividad también permite maniobras de conducción cooperativa, como el *platooning*, que pueden aumentar aún más la capacidad de las carreteras y la eficiencia del combustible. Todos estos aspectos, además de los relacionados con el control de los propios vehículos, configuran un gran ámbito de investigación relacionado con los vehículos inteligentes y las smart cities.


2.1. Fuentes de datos

Los diferentes contextos de aplicación citados anteriormente son, al mismo tiempo, consumidores y generadores de datos de diferente índole y disponibilidad. La **figura 1** muestra una representación de la disponibilidad de los tipos de datos más habituales, indicando a su vez los que, por lo general, únicamente pueden obtenerse comprándolos.

Mientras los datos generados por los sensores desplegados por diferentes instituciones en las infraestructuras de movilidad suelen ser publicados en portales de datos abiertos,

Figura 1.

Disponibilidad de diferentes tipos de datos de movilidad urbana



Fuente: Elaboración propia.


y refieren generalmente al uso de dichas infraestructuras, los datos generados por sistemas embarcados en vehículos tienden a no ser públicos. Así, es relativamente sencillo encontrar fuentes de datos con información sobre conteo de vehículos, tiempos de recorrido, u ocupación de diferentes vías, pero la disponibilidad de datos de percepción vehicular generados por el sistema LIDAR de un vehículo son, como norma general, inaccesibles de manera pública. De igual manera, los datos que permiten caracterizar viajes (origen y destino), y que son esenciales para numerosas tareas de gestión y definición de infraestructuras y servicios de transporte público, no suelen estar disponibles de forma pública.

Los datos son un aspecto fundamental en la investigación y desarrollo de sistemas de inteligencia artificial, y su disponibilidad condiciona la forma en la que se produce el avance en los diferentes campos mencionados anteriormente. Así, mientras la investigación de los sistemas de percepción y control de los vehículos se restringe a los contextos de los fabricantes y centros de investigación que tienen acceso a los sistemas implicados, los trabajos relacionados con los datos de alta disponibilidad son abundantes y se extienden mucho más allá del dominio de aplicación.

Es más, como se analizaba en (Manibardo *et al.*, 2021) y se observa en la **figura 2**, una gran parte del corpus académico relacionado con la movilidad urbana está relacionado con la predicción de tráfico, y en particular con el uso de herramientas de aprendizaje profundo (*Deep Learning*), que implican una alta complejidad y baja interpretabilidad de modelos para producir resultados con un impacto escasamente superior al de modelos de regresión mucho más sencillos. La disponibilidad de conjuntos de datos (datasets) completos y abundantes propicia que investigadores sin interés particular en el dominio de la movilidad copen la investigación en este campo, con el objetivo de testear y demostrar las capacidades de las tecnologías de inteligencia artificial más avanzadas.

Figura 2.

Evolución de las publicaciones de predicción de tráfico basadas en *Deep Learning*, con las fechas de publicación de técnicas específicas de aprendizaje profundo



Fuente: Elaboración propia.

En el lado opuesto, los problemas de optimización inteligente que, para el contexto de la movilidad urbana, especialmente en logística, representan una buena parte de los retos a resolver y requieren menos disponibilidad de datos, acapan una fracción considerablemente menor de la atención investigadora.

Esta falta de encuentro entre la investigación en inteligencia artificial y los intereses del campo de la movilidad urbana se está viendo mitigada con las tendencias más actuales, explicadas más adelante. Por un lado, el desarrollo del vehículo autónomo acapara una gran parte de la actividad investigadora actual en el campo, y requiere del uso y despliegue de todas las herramientas IA disponibles, así como el desarrollo de nuevas tecnologías para resolver los retos que plantea. Por otra parte, la aplicación de tecnologías IA modernas a problemas clásicos (por ejemplo aprendizaje por refuerzo para resolver problemas de optimización) está generando interés en ambas comunidades. A continuación se muestran algunas de las principales áreas de investigación de aplicación de la IA en la movilidad urbana.

3. INTELIGENCIA ARTIFICIAL APLICADA A LA MOVILIDAD URBANA

Como se ha visto, las herramientas basadas en inteligencia artificial son esenciales en el desarrollo de los llamados sistemas de transporte inteligentes, con un gran impacto en los elementos que configuran la movilidad urbana. Prácticamente cualquier técnica IA que se haya desarrollado tiene aplicación en alguno de los ámbitos citados anteriormente, si bien las aplicaciones principales podrían categorizarse principalmente en las que hacen uso del modelado basado en datos (aprendizaje máquina) y las que se basan en técnicas de optimización inteligente.

Los modelos de aprendizaje automático y aprendizaje profundo tienen especial relevancia en todos los problemas relacionados con los vehículos autónomos y, como se ha visto anteriormente, para tareas predictivas que frecuentemente se relacionan con la estimación del estado o uso de una infraestructura, o bien predicciones de la demanda de un servicio, bien sea de transporte público o logístico. Estas predicciones tienen gran relevancia para la toma de decisiones tanto en el ámbito administrativo como de gestión logística, sin embargo el reto tecnológico que plantean puede considerarse ampliamente resuelto con las tecnologías disponibles a día de hoy. Por esta razón es posible apreciar un cambio de orientación en las tendencias de investigación, en el que las cada vez más avanzadas técnicas de aprendizaje máquina se utilizan principalmente para el contexto del vehículo autónomo, frente a su aplicación clásica para predicción de series temporales.

Por otra parte, las tecnologías de optimización inteligente, que tuvieron un gran relieve académico en la primera década de los 2000, con el auge de los modelos bioinspirados, han experimentado un declive investigador en los últimos años.

No obstante, como se puede observar en la [figura 3](#), los problemas de optimización representan una gran parte de los retos de la movilidad urbana. Este tipo de problemas afectan particularmente al ámbito de la logística, donde reducir la ruta a recorrer, los vehículos a usar o la forma de cargarlos son tareas que se pueden ver ampliamente beneficiadas por las técnicas de optimización inteligente. Fuera de este ámbito, estas técnicas tienen también impacto en aspectos que pueden ir desde la gestión de los ciclos en los semáforos hasta la selección de rutas óptimas para vehículos eléctricos.

Figura 3.

Ejemplos de problemas de optimización en diferentes áreas de la movilidad urbana



Fuente: Elaboración propia.

Así, la movilidad urbana en el contexto de la smart city es un dominio permeado por la inteligencia artificial y sus aplicaciones afectan a todas sus disciplinas de manera profunda y significativa. Desde la optimización del tráfico y la gestión de flotas hasta la mejora de la seguridad y la experiencia del usuario, la IA ya se utiliza de forma práctica y efectiva en diversas aplicaciones. Sin embargo, el potencial de la IA en este campo es aún más prometedor. A continuación, exploraremos algunas de las tendencias de aplicación y de tecnología más impactantes y transformadoras.

3.1. Tendencias por aplicación

En esta sección se muestran las direcciones emergentes que están guiando la investigación y el desarrollo actuales en este campo desde la perspectiva de la aplicación o el problema a resolver. Estas tendencias pueden observarse en la investigación más reciente en el dominio y revelan las potenciales transformaciones en la manera de moverse en las ciudades que podrían tener lugar en los próximos años.

3.1.1. Transporte público a la demanda

El transporte público a la demanda es un modelo de movilidad que se adapta a las necesidades específicas de los usuarios en tiempo real. A diferencia de los servicios de transporte público tradicionales, que operan con horarios y rutas fijas, el transporte a la demanda ofrece cuando y donde lo necesiten. La implementación de este tipo de transporte público ya es una realidad en algunas ciudades (Cabildo de Tenerife, 2024), y suele utilizarse para dar cobertura pública a zonas con poca demanda o inaccesibles para los servicios de transporte regular, combinándose con las líneas de transporte regulares.

El transporte a la demanda representa un reto tecnológico en lo que refiere al cálculo de rutas, ya que, si bien existen algunas implementaciones que se basan en la pre-reserva del servicio, el enfoque general consiste en la solicitud del servicio en tiempo real, lo que implica adaptar las rutas de algunos vehículos dinámicamente, considerando las peticiones actuales, los vehículos disponibles y la calidad del servicio.

El uso de sistemas de optimización inteligente dinámica puede permitir la creación de rutas de transporte público flexible que pueden cambiar sustancialmente el modelo de transporte de las ciudades y sus entornos.

3.1.2. *Esquemas de incentivos al transporte público/micromovilidad*

El incremento de modos de transporte de pasajeros que ha tenido lugar en los últimos años, así como la gradual incorporación de zonas de bajas emisiones en las grandes ciudades, han favorecido la disponibilidad de alternativas sostenibles al vehículo privado para los desplazamientos intraurbanos. No obstante, la preeminencia de este último está impulsando la promoción desde la administración pública de esquemas de incentivos para el uso de transporte público (EU Urban Mobility Observatory, 2024). Los esquemas de incentivos para el uso de micromovilidad y transporte público son estrategias diseñadas para fomentar el uso de modos de transporte más sostenibles y eficientes en las ciudades. Estos incentivos pueden incluir subsidios, descuentos en tarifas, programas de recompensas y beneficios fiscales para los usuarios que optan por bicicletas, patinetes eléctricos, autobuses, trenes y otros medios de transporte colectivo. Además, las políticas de infraestructura, como la creación de carriles bici y estaciones de carga para vehículos eléctricos, también juegan un papel crucial. Estos esquemas no solo reducen la dependencia de los vehículos privados, sino que también contribuyen a disminuir la congestión, mejorar la calidad del aire y promover un estilo de vida más saludable y sostenible.

Estos esquemas de incentivación no son particularmente novedosos, y tienen un arraigo en aspectos como cuestiones demográficas o culturales, pero la incorporación de los modelos basados en agentes y los sistemas de optimización inteligente están estimulando un área de investigación que permite dar solución al problema de una forma mucho más detallada, y crear incentivos a medida para cada usuario.

3.1.3. *Platooning*

El *platooning* o circulación en "pelotón" es una técnica de conducción en la que varios vehículos se desplazan en convoy, siguiendo de cerca al vehículo delantero de manera automatizada. En el contexto interurbano, el platooning se utiliza principalmente para camiones y vehículos comerciales en autopistas, mejorando la eficiencia del combustible y reduciendo las emisiones gracias a la disminución de la resistencia aerodinámica. En el entorno urbano, el *platooning* puede aplicarse a autobuses y otros vehículos de transporte público, optimizando el flujo del tráfico y mejorando la seguridad vial. Además, el

platooning está empezando a plantearse en entornos urbanos como esquema de funcionamiento para determinados vehículos autónomos, como vehículos de reparto o taxis autónomos. El funcionamiento en convoy de estos vehículos, frecuentemente eléctricos, hace su consumo más eficiente, pero presenta diversos retos en lo que respecta al diseño del sistema de control de unión y separación del pelotón (Wang *et al.*, 2020), el control de la trayectoria o el diseño de la ruta óptima.

Nuevamente, las herramientas IA son fundamentales para la implementación de esta tecnología, permitiendo la coordinación precisa y en tiempo real entre los vehículos. Además, la IA mejora la capacidad de los vehículos para reaccionar a situaciones imprevistas, como cambios repentinos en el tráfico o condiciones climáticas adversas, garantizando así una operación segura y eficiente.

3.1.4. *Movilidad urbana aérea*

La movilidad urbana aérea está emergiendo como una solución innovadora para descongestionar las ciudades y ofrecer nuevas formas de transporte eficiente y sostenible. Actualmente, diversas empresas están desarrollando prototipos de vehículos aéreos autónomos, conocidos como taxis voladores o eVTOLs (vehículos eléctricos de despegue y aterrizaje vertical), que prometen revolucionar la manera en que nos desplazamos en entornos urbanos (Tecnalia, 2024). Los algoritmos de IA son fundamentales para la navegación autónoma, permitiendo a los vehículos aéreos planificar rutas, evitar obstáculos y aterrizar con precisión. Además, la IA será esencial en la gestión del tráfico aéreo en tiempo real, un contexto altamente restringido y regulado, cuya complejidad ya supone un reto para el tráfico aéreo actual, que se verá multiplicado cuando se trate de espacio aéreo urbano. Sin la IA, la coordinación y la precisión necesarias para operar estos sistemas complejos serían prácticamente imposibles de alcanzar, haciendo de la IA un componente crucial para el futuro de la movilidad urbana aérea.

3.2. *Tendencias por tecnología*

Tras explorar las tendencias de aplicación que están moldeando la movilidad urbana, esta sección se enfoca en las tendencias de la investigación en tecnologías de inteligencia artificial que pueden tener capacidad de provocar transformaciones cruciales en la forma en la que se resuelven algunos de los problemas descritos anteriormente.

3.2.1. *Redes neuronales de grafos*

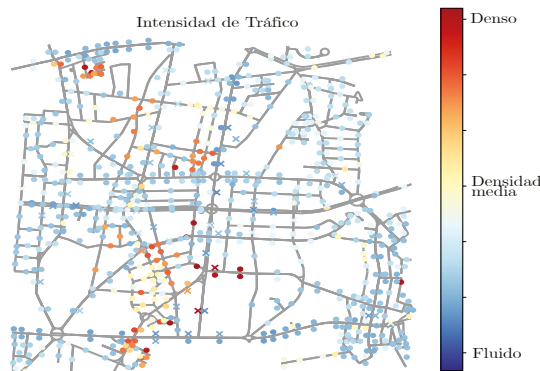
Las redes neuronales de grafos (GNNs, por sus siglas en inglés) son una clase de modelos de aprendizaje profundo diseñados para operar sobre datos estructurados en forma de

grafos. Estos modelos extienden las capacidades de las redes neuronales tradicionales para manejar relaciones complejas y estructuras no euclidianas, lo que los hace particularmente adecuados para aplicaciones donde los datos tienen una estructura de grafo, como lo es la red de carreteras de una ciudad. Como los mapas de las ciudades son habitualmente públicos, es relativamente sencillo obtener un grafo que represente la conectividad de intersecciones y carreteras de una ciudad, y por tanto utilizarlo como fuente de partida para entrenar una *GNN*. De hecho, esta tecnología ha adquirido gran relevancia en lo que respecta a las predicciones de tráfico urbanas (un dominio que como se ha visto anteriormente acapara una gran parte de la actividad investigadora). Actualmente es relativamente sencillo encontrar sistemas de predicción de tráfico cuyas fuentes de datos son los sensores en diferentes puntos de la ciudad y el grafo de la misma, obteniendo por un lado predicciones que consideran la topología de la ciudad, así como un sistema para estudiar las relaciones causales entre el tráfico observado en dichas localizaciones (Zhang *et al.*, 2022).

No obstante, su potencial y futuros usos van más allá de obtener predicciones en localizaciones en las que hay sensores. A través de técnicas basadas en características de los grafos, como el grado, la centralidad o la centralidad de intermediación se pueden obtener caracterizaciones de todos los nodos de un grafo y realizar estimaciones de flujo, ocupación o tiempo de recorrido en cada nodo (Manibardo *et al.*, 2023), tal como se observa en la [figura 4](#). Esto tiene implicaciones de mayor alcance, ya que todos los problemas de rutado por los nodos de una ciudad pueden utilizar tiempos de recorrido estimados en cada uno de los nodos, para obtener rutas más óptimas. Igualmente, en otros entornos en los que se disponga de grafo, como almacenes logísticos, las *GNN* pueden permitir desarrollar modelos conscientes de las topologías reales. Así, el uso de *GNNs* tiene un impacto directo en los nuevos desarrollos de aplicaciones de movilidad urbana.

Figura 4.

Ejemplo de aplicación de grafos para estimar el tráfico a nivel de red




Nota: En la figura se aprecia el tráfico obtenido en los nodos de sensor (marcados con una x), así como en los nodos generados en cada arista.

3.2.2. Aprendizaje por refuerzo


El aprendizaje por refuerzo es una técnica de inteligencia artificial en la que un agente aprende a tomar decisiones óptimas a través de la interacción con un entorno, recibiendo recompensas o penalizaciones en función de sus acciones, donde el objetivo es maximizar una recompensa acumulada a lo largo del tiempo. Este enfoque es bien conocido y establecido para problemas en los que se implementan soluciones basadas en agentes, y tiene una aplicación directa y clara en el aprendizaje de los sistemas de trayectorias de los vehículos autónomos, por ejemplo. En estos problemas, el vehículo es tratado como un agente que busca trazar una trayectoria entre dos puntos, y para ello dispone de acciones, que son recompensadas o penalizadas en función de lo útiles que sean para realizar la trayectoria de la manera más eficaz. Sin embargo, más allá del uso "tradicional" de los sistemas de aprendizaje por refuerzo, existe actualmente una corriente de investigación en la que se está aplicando esta tecnología para resolver problemas de optimización combinatoria. Bajo este paradigma, frente al enfoque de diseñar una solución y evaluarla de acuerdo a una función objetivo, haciendo cambios para evolucionar hacia soluciones mejores, el enfoque basado en aprendizaje por refuerzo construye soluciones dinámicamente y las va penalizando o recompensando de acuerdo con un esquema de recompensas similar a la función objetivo. La *figura 5* muestra las diferencias de entrenamiento entre estos dos esquemas. Así, para un problema de rutado en el que hay que encontrar el mejor orden posible para recorrer una lista de nodos, una solución basada en optimización combinatoria (a la izquierda en la *figura 5*) es construida de una vez, estableciendo un orden particular para navegar por los nodos y evaluando de forma global cómo de buena es esa solución. La solución basada en aprendizaje por refuerzo establece que el agente empieza en uno de los nodos y sus posibles acciones consisten en desplazarse a uno de los nodos disponibles. Cada una de estas acciones es penalizada o recompensada en función de lo buena que es esta decisión de forma global, es decir, considerando la ruta completa. Esta aproximación, mucho más costosa de calcular la primera vez (en su entrenamiento), es capaz de generalizar para mejor para conjuntos grandes de nodos, y obtener soluciones de forma muy rápida, una vez se ha entrenado.

Figura 5.

Diferencias en los esquemas de creación de soluciones para un problema de rutado de vehículos que parte del nodo inicial (en ocre)



Definición completa de solución para resolver con algoritmo de optimización metaheurístico



Definición incremental para resolver con algoritmo de aprendizaje por refuerzo

Nota: Los modelos metaheurísticos crean una solución completa y la evalúan, mientras que las aproximaciones basadas en aprendizaje por refuerzo van calculando la mejor opción a visitar considerando el estado actual del agente y los nodos visitados previamente.

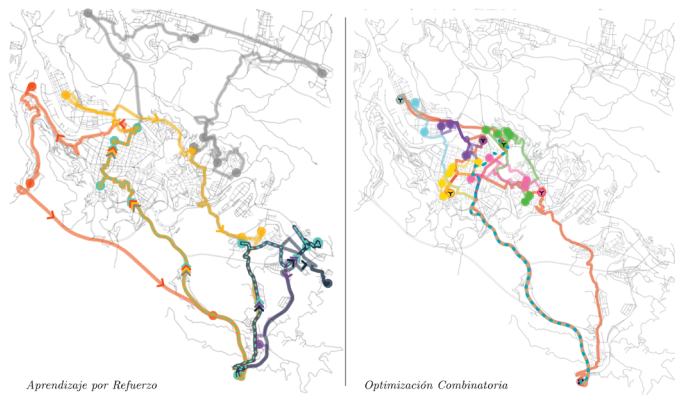
Entrenar un modelo de este tipo es mucho más costoso y elaborado, pero su principal ventaja reside en la capacidad de generalización y la rapidez en tiempo de inferencia. Un sistema de aprendizaje por refuerzo moderno aprenderá, de forma latente en las redes neuronales que lo componen, las características del espacio de solución, y una vez entrenado producirá soluciones nuevas en tiempos de respuesta muy bajos. Este cambio es diferencial respecto a los sistemas de optimización, que requieren un gran esfuerzo computacional cada vez que alguna variable del contexto ha cambiado.

Por este motivo, la utilización de aprendizaje por refuerzo para problemas de optimización puede tener un impacto claro en el ámbito de la movilidad urbana, pudiendo ser empleado para optimizar rutas de transporte, gestionar el tráfico en tiempo real, y mejorar la eficiencia de los sistemas de transporte público, entre otros. Como ejemplo, en (Andres, *et al.*, 2024) se utiliza aprendizaje por refuerzo para resolver un problema de rutado de vehículos frente a una solución equivalente con algoritmos de optimización metaheurística multiobjetivo. El problema está planteado para vehículos autónomos de reparto que comparten parte del recorrido en formación de pelotón (*platoon*), de forma que se produce un aumento de la eficiencia energética del conjunto de vehículos. El objetivo es maximizar el recorrido en formación de pelotón, al mismo tiempo que se minimiza la distancia total recorrida cuando los agentes se separan del mismo para hacer repartos de forma individualizada.

En los resultados mostrados en la [figura 6](#) se puede apreciar que la aproximación de aprendizaje por refuerzo no solamente obtiene mejores soluciones en términos de distancia recorrida,

Figura 6.

Soluciones a un problema de rutado con diferentes agentes que hacen repartos simultáneos basadas en aprendizaje por refuerzo (izquierda) y optimización combinatoria (derecha)



Nota: La solución basada en aprendizaje por refuerzo propone el uso de varios platoons (pelotones de vehículos) que operan de forma simultánea y aumentan considerablemente la ruta compartida. Las rutas compartidas son mostradas con líneas punteadas.

sino también provee de soluciones que no estaban contempladas en la formulación original del problema (como considerar dos *platoons* simultáneos), además de ser capaz de generar soluciones múltiples en tiempos muy bajos. Esta capacidad de adaptación a entornos dinámicos y complejos hace que el aprendizaje por refuerzo sea una herramienta poderosa para abordar los desafíos de la movilidad urbana, permitiendo soluciones más eficientes y sostenibles.

3.2.3. *Explicabilidad*

La explicabilidad de los modelos de inteligencia artificial (xAI) ha emergido como un aspecto crítico en un contexto en el que los sistemas IA están cada vez más integrados en decisiones que afectan diversas áreas de la vida cotidiana, desde la atención médica hasta las finanzas. La explicabilidad ha cobrado especial relevancia en el contexto europeo, con la vigencia de la AI-Act, que establece diversos estándares de uso de las herramientas IA, muchos de ellos relacionados con la explicabilidad de los mismos. La capacidad de entender cómo y por qué los modelos de IA toman ciertas decisiones no solo mejora la transparencia y la confianza en estos sistemas, sino que también es esencial para identificar y corregir sesgos y errores, acercando las salidas de estos modelos a la comprensión de los expertos que los usan.

En el ámbito de los vehículos autónomos, la explicabilidad de los modelos de IA adquiere una relevancia especial. Estos vehículos dependen de algoritmos complejos para tomar decisiones en tiempo real, como la navegación, la detección de obstáculos y la respuesta a situaciones de emergencia. La falta de explicabilidad puede hacer que estos sistemas sean vulnerables a ataques adversarios, donde pequeñas perturbaciones en los datos de entrada pueden llevar a decisiones incorrectas o peligrosas. La explicabilidad de la IA permite a los desarrolladores y reguladores entender mejor el comportamiento de los algoritmos, identificar posibles puntos débiles y fortalecer la seguridad contra ataques adversarios. Además, la xAI facilita la auditoría y la regulación de estos sistemas, asegurando que cumplan con los estándares de seguridad y ética necesarios para su implementación en entornos urbanos.

3.2.4. *IA generativa en la movilidad urbana*

La inteligencia artificial generativa y los modelos de lenguaje están en plena ebullición como una de las áreas más innovadoras y de actualidad dentro de la investigación en IA. Estos modelos tienen la capacidad de generar contenido nuevo y coherente, como texto, imágenes, música y más, a partir de patrones aprendidos de grandes volúmenes de datos. La popularidad de estos modelos se debe en gran parte a su versatilidad y a la multitud de aplicaciones que abarcan, desde la creación de contenido creativo y la personalización de experiencias de usuario hasta la automatización de tareas rutinarias y la mejora de la interacción humano-máquina. En principio el uso de estos sistemas parece alejado de cualquiera de los dominios de la movilidad urbana, más allá de su aplicación en los sistemas de interacción de los vehículos autónomos; no obstante, y quizá por el gran atractivo actual que estos sistemas tienen

en la comunidad investigadora, están empezando a ser utilizados en diversos ámbitos. Sus aplicaciones van desde áreas tangenciales al campo como el análisis de redes sociales para predecir el tráfico, hasta la resolución de problemas mucho más relevantes, como su uso para la explicabilidad de modelos produciendo explicaciones textuales o la agilización del entrenamiento de modelos de aprendizaje por refuerzo a través de instrucciones en lenguaje natural. El potencial de estas herramientas para determinadas aplicaciones, especialmente relacionadas con los vehículos autónomos, está todavía por explorar, pero al igual que en otros campos, es posible que la IA generativa tenga un impacto transformador en la movilidad urbana.

4. CONCLUSIONES

El impacto de la inteligencia artificial en la movilidad urbana es palpable actualmente a través de multitud de servicios y tecnologías de movilidad de las que ya disponemos. La inteligencia artificial ya ha transformado la forma en la que desplazamos personas y bienes en las ciudades. Muchos de los servicios de movilidad, que se suelen dar por sentados, como la entrega eficiente de paquetería, se solucionan con herramientas IA, mientras para otros aspectos como los vehículos autónomos, la intervención de herramientas IA es más evidente. Pero la IA no solo ha revolucionado la forma en que gestionamos y optimizamos sistemas de todos los ámbitos de la movilidad, sino que también está abriendo nuevas oportunidades para mejorar la eficiencia, la seguridad y la sostenibilidad en el entorno urbano. Así, el camino recorrido es importante, pero el avance de este conjunto de tecnologías plantea nuevos retos cada día. Como se ha podido observar a través de los diferentes ejemplos mostrados, la IA está transformando la manera en que las personas y los bienes se desplazan dentro de las ciudades, con soluciones cada vez más eficientes, rápidas y humanizadas. A medida que estas tecnologías continúen evolucionando, es esencial que se implementen de manera ética y sostenible, asegurando que los beneficios de la IA sean accesibles y equitativos para todos los ciudadanos.

Referencias

- AMINI, S., GEROSTATHOPOULOS, I. y PREHOFER, C. Big data analytics architecture for real-time traffic control. In *2017 5th IEEE international conference on models and technologies for intelligent transportation systems (MT-ITS)* (710–715). IEEE.
- ANDRES, A., LAÑA, I., BRAVO, N., ECHEVERRIA, I. (2024). Single agent formulation for reinforcement learning based routing of urban last mile logistics with platooning vehicles. En *2024 IEEE 27th International Conference on Intelligent Transportation Systems (ITSC)*, page TBA. IEEE.
- ANDRIENKO, G., ANDRIENKO, N., CHEN, W., MACIEJEWSKI, R. y ZHAO, Y. (2017). Visual analytics of mobility and transportation: State of the art and further research directions. *IEEE Transactions on Intelligent Transportation Systems*, 18(8),2232–2249.
- CABILDO DE TENERIFE. (2024). *Transporte a la demanda en tenerife, 2024*. <https://www.tenerife.es/portalcabtfe/es/noticias-cabtfenews/177-transportes/16667-el-cabildo-mejora-la-movilidad-de-mas-de-13-000-personas-con-la-puesta-en-marcha-del-transporte-a-la-demanda-en-fasnia-arico-y-guimar#: :text=paradaste>
- CAMPISI, T., SEVERINO, A., AL-RASHID, M. y PAU, G. (2021). The development of the smart cities in the connected and autonomous vehicles (cavs) era: From mobility patterns to scaling in cities. *Infrastructures*, 6(7),100.

- CHEN, C., MA, J., SUSILO, Y., LIU, Y. y WANG, M. (2016). The promises of big data and small data for travel behavior (aka human mobility) analysis. *Transportation research part C: emerging technologies*, 68, 285–299.
- COLADO, S., GUTIÉRREZ, A., VIVES, C. J. y VALENCIA, E. (2014). *Smart city: Hacia la gestión inteligente*. Marcombo.
- EU URBAN MOBILITY OBSERVATORY. (2024). *Mastering mobility with public transport 'microincentives', 2024*. https://urban-mobility-observatory.transport.ec.europa.eu/news-events/news/mastering-mobility-public-transport-microincentives-2024-08-02_en
- FONZONE, A., SCHMÖCKER, J-D. y VITI, F. (2016). *New services, new travelers, old models? directions to pioneer public transport models in the era of big data*.
- HENSHER, D. A. y PUCKETT, S. (2004). *Freight distribution in urban areas: The role of supply chain alliances in addressing the challenge of traffic congestion for city logistics*.
- JEONG, S., ZHANG, Y., O'CONNOR, S., LYNCH, J. P., SOHN, H., LAW, K. H. (2016). A nosql data management infrastructure for bridge monitoring. *Smart structures and systems*, 17(4), 669–690, 2016.
- KHATTAK, A. J. (2015). Integrating big data in metropolitan regions to understand driving volatility and implications for intelligent transportation systems. In *Information Technology and Intelligent Transportation Systems: Volume 1, Proceedings of the 2015 International Conference on Information Technology and Intelligent Transportation Systems ITITS 2015, held December 12-13, 2015, Xi'an China*, (3–4). Springer, 2017.
- KITCHIN, R. (2015). *Data-driven, networked urbanism*.
- LAUENSTEIN, S. y SCHANK, CH. (2022). Design of a sustainable last mile in urban logistics a systematic literature review. *Sustainability*, 14(9), 5501.
- LIU, X. y DIJK, M. (2022). The role of data in sustainability assessment of urban mobility policies. *Data & Policy*, 4, e2,.
- MANIBARDO, E. L., LAÑA, I. y DEL SER, J. (2021). Deep learning for road traffic forecasting: Does it make a difference? *IEEE Transactions on Intelligent Transportation Systems*, 23(7), 6164–6188.
- MANIBARDO, E. L., LAÑA, I., VILLAR-RODRIGUEZ, E. y DEL SER, J. (2023). A graph-based methodology for the sensorless estimation of road traffic profiles. *IEEE Transactions on Intelligent Transportation Systems*, 24(8), 8701–8715.
- MEEKAN, M. G., DUARTE, C. M., FERNÁNDEZ-GRACIA, J., THUMS, M., SEQUEIRA, A. M. M., HARCOURT, R. y EGUILUZ, V. M. (2017). The ecology of human mobility. *Trends in ecology & evolution*, 32 (3), 198–210.
- RUSITSCHKA, S. y CURRY, E. (2016). Big data in the energy and transport sectors. *New Horizons for a Data-Driven Economy: A Roadmap for Usage and Exploitation of big data in Europe*, 225–244.
- STATHOPOULOS, A., CIRILLO, C., CHERCHI, E., BEN-ELIA, E., LI, Y-T. y SCHMÖCKER, J-D. (2017). Innovation adoption modeling in transportation: New models and data. *Journal of choice modelling*.
- SU, J-M., ERDENEBAT, N., HO, L_H. y TING ZHAN, Y. (2016). Integration of transit demand and big data for bus route design in taiwan. En *Bridging the East and West* (19–26). American Society of Civil Engineers.
- SUH, W., HENCLEWOOD, D., GUIN, A., GUENSLER, R., HUNTER, M. y FUJIMOTO, R. Dynamic data driven transportation systems. *Multimedia Tools and Applications*, 76, 25253–25269.
- TECNALIA. (2024). *Aerotaxi. vehículo volador para el transporte urbano, una alternativa al transporte terrestre*. <https://www.tecnalia.com/proyectos/aerotaxi-vehiculo-volador-para-el-transporte-urbano-una-alternativa-al-transporte-terrestre>
- WANG, S., HOMEM DE ALMEIDA CORREIA, G. y LIN, H. X. (2020). Effects of coordinated formation of vehicle platooning in a fleet of shared automated vehicles: An agent-based model. *Transportation Research Procedia*, 47, 377–384.

- WANG, W. y GUO, F. (2016). Roadlab: Revamping road condition and road safety monitoring by crowdsourcing with smartphone app. *Technical report, Transportation Research Board*.
- ZANELLA, A., BUI, N., CASTELLANI, A., VANGELISTA, L. y ZORZI, M. (2014). Internet of things for smart cities. *IEEE Internet of Things journal*, 1(1), 22–32.
- ZHANG, L., FU, K., JI, T. y LU, CH. T. (2022). Granger causal inference for interpretable traffic prediction. En *2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)* (1645–1651). IEEE.