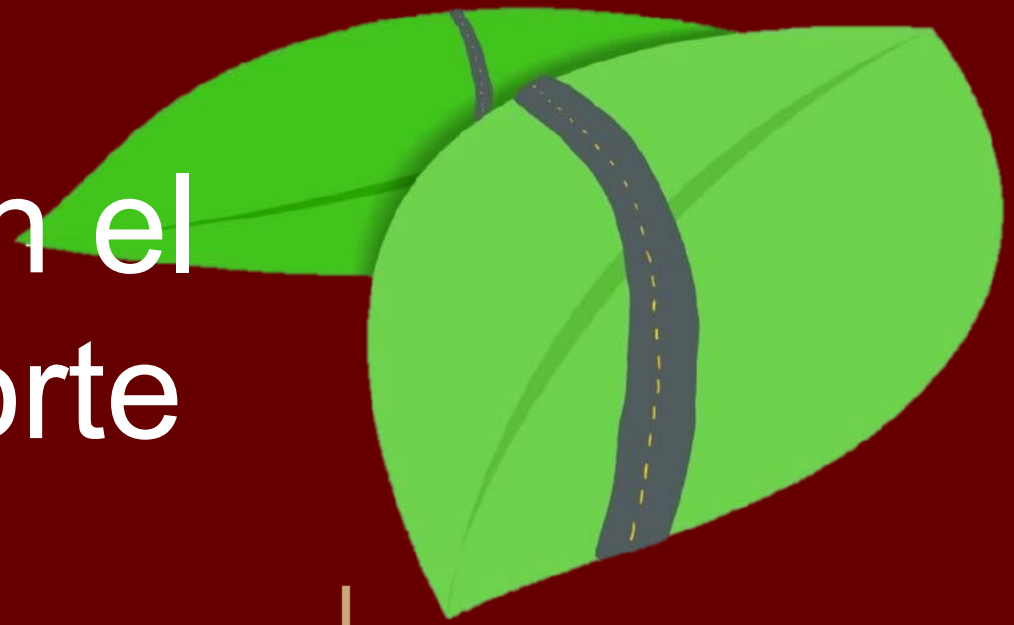
La IA en el transporte



Cathy Wu

Profesora asociada | MIT LIDS, CEE e IDSS

Lecturas previas

- Panorama del sector del transporte ante el cambio climático
  - Jaramillo, Paulina, et al. Climate Change 2022: Mitigation of Climate Change. Contribution of *Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change (Chapter 10: Transport). IPCC, 2023. (IPCC Executive Summary)*
- IA para el transporte
  - Transportation Research Board Executive Committee, Transforming Transportation: *Leveraging the Power of Artificial Intelligence, Digitalization, and Automation . Washington, D.C.: National Academies Press, 2026. doi: 10.17226/29350. (PDF)*
- IA para el clima (enfoque en el transporte)
  - Sandalow, David B. et al., Artificial Intelligence for Climate Change Mitigation Roadmap (Chapter 6: Road Transport), 2nd Ed. Academic Commons, 2024. (PDF)
  - D. Rolnick et al., “Tackling climate change with machine learning” (Section 2: Transportation), Jun. 2019. Available: http://arxiv.org/abs/1906.05433v2

Objetivos de aprendizaje

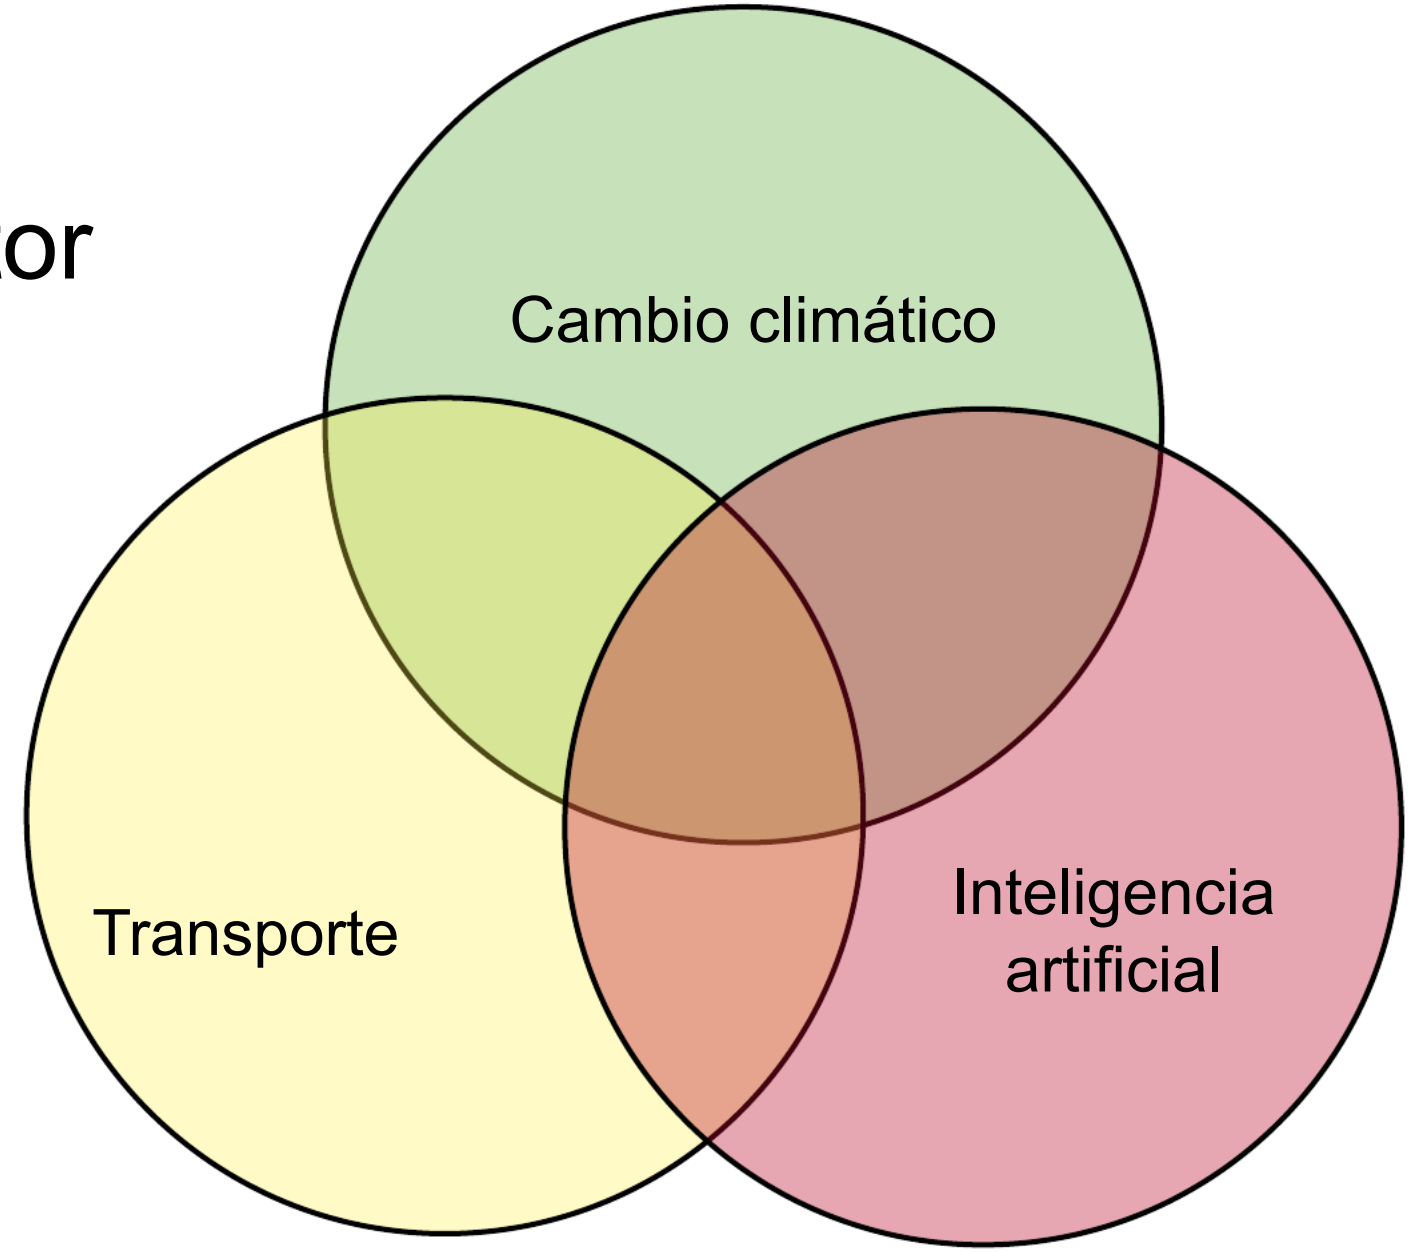
Esta clase busca aclarar las siguientes preguntas:

- ¿Por qué es difícil descarbonizar el transporte?
- ¿Qué intervenciones son importantes para la mitigación?
- ¿Dónde ayuda realmente la IA y dónde es una distracción?
- ¿Cuáles son los riesgos éticos y de equidad de las estrategias de mitigación?

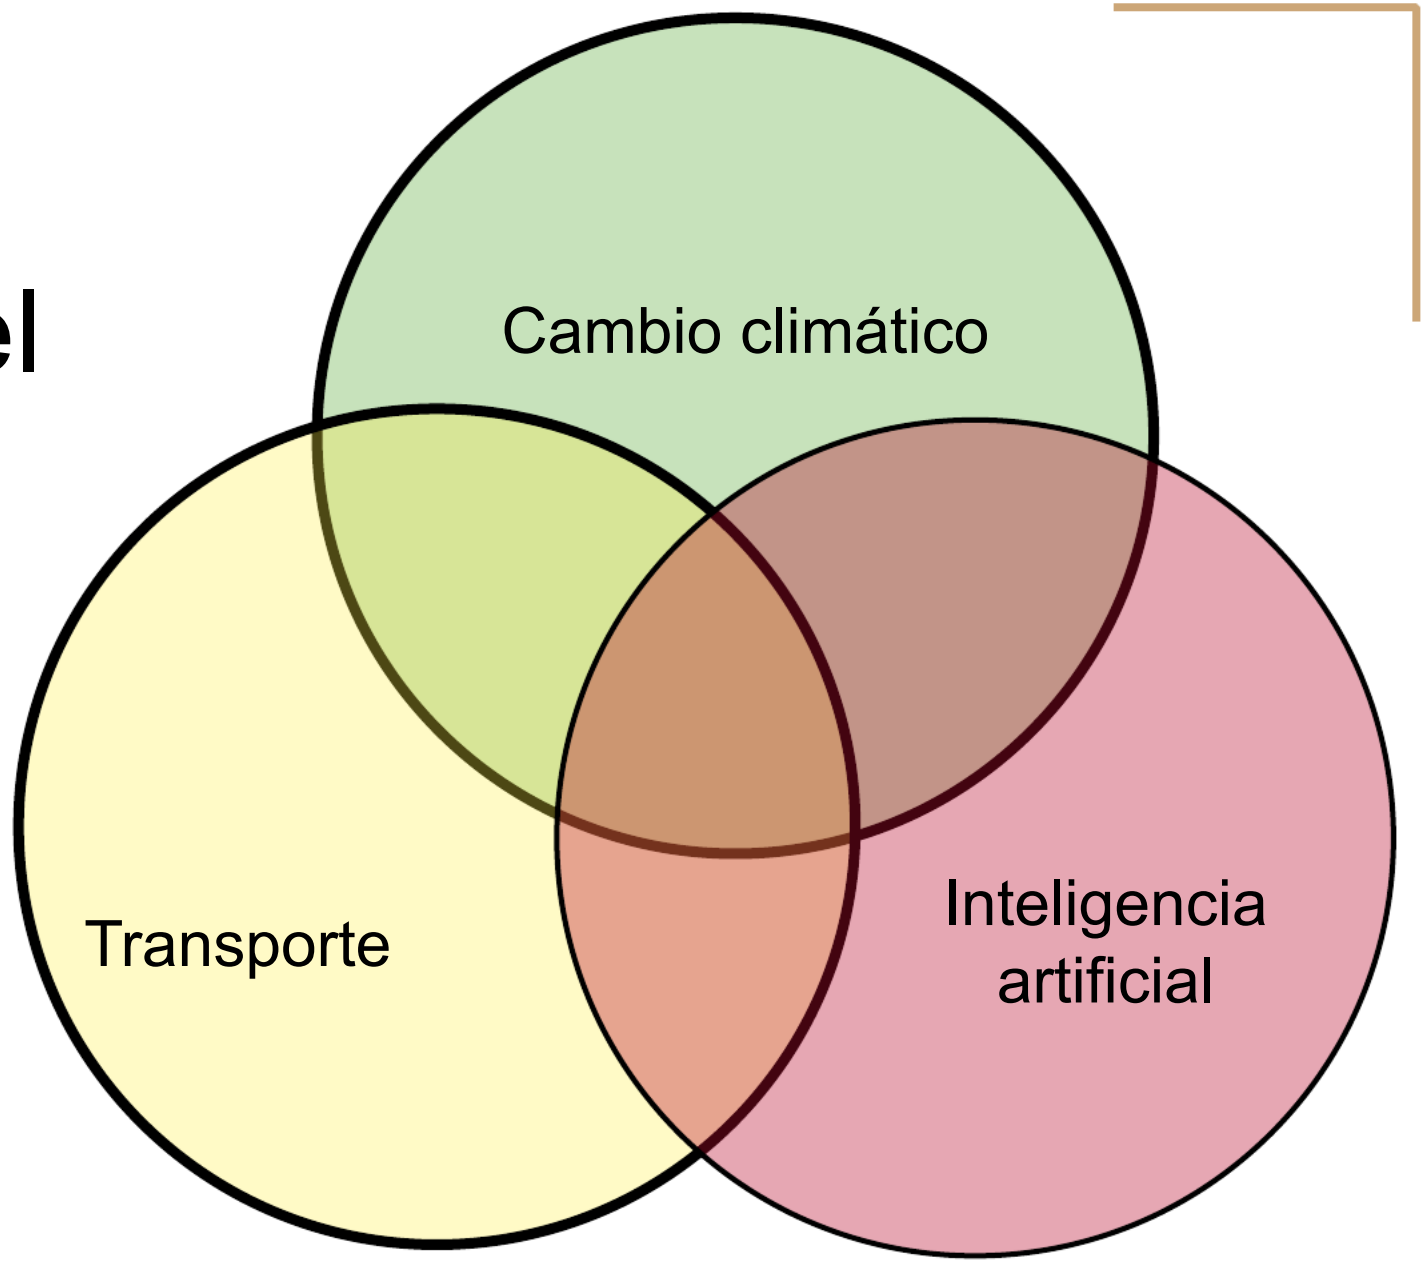
Índice

- Panorama del sector
  - Emisiones del transporte: situación y objetivos
  - Por qué es difícil descarbonizar el transporte
  - Marco de descarbonización
  - Panorama de la IA en el transporte
  - IA para la mitigación del cambio climático en el transporte
- Análisis en profundidad
  - Mejorar: IA para la electrificación
  - Cambiar: IA para el cambio modal
  - Mejorar: IA para la eficiencia del transporte
- Reflexiones finales
  - Síntesis, puntos de entrada y próximos pasos

Panorama del sector Transporte, cambio climático e IA



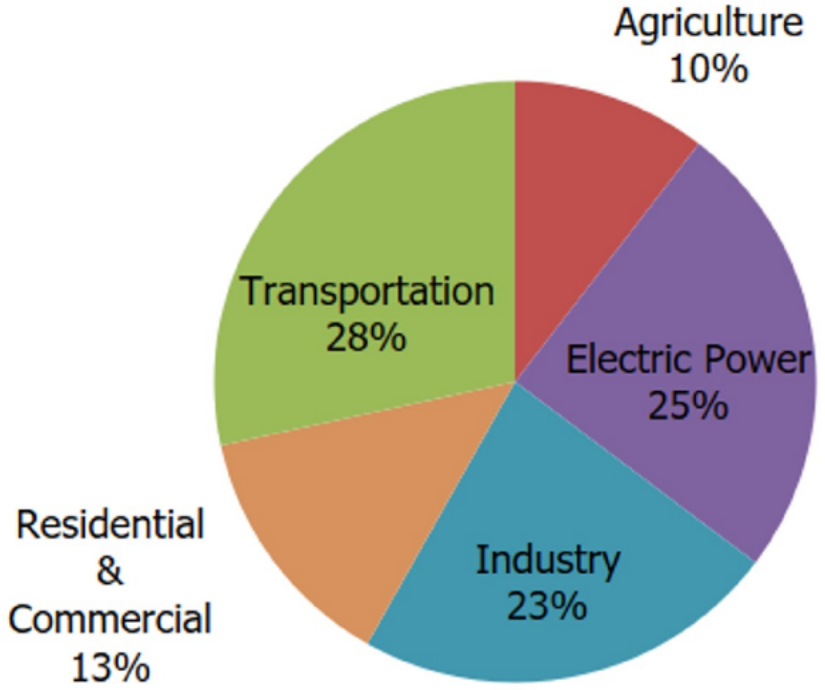
Emisiones del transporte: situación y objetivos



Estados Unidos: situación y objetivos de GEI

- Objetivos del Acuerdo de París [1]
  - Reducción del 45 % respecto a 2010 para 2030
  - Cero neto para 2050
- Estados Unidos [2]
  - Pico nacional de GEI en 2005
  - Objetivo: −50-52 % respecto a 2005 para 2030
  - 2025: GEI un 18 % por debajo de 2005.
- El transporte es el mayor sector emisor de GEI en EE. UU. [3]

Emisiones totales de GEI de EE. UU. por sector económico en 2022



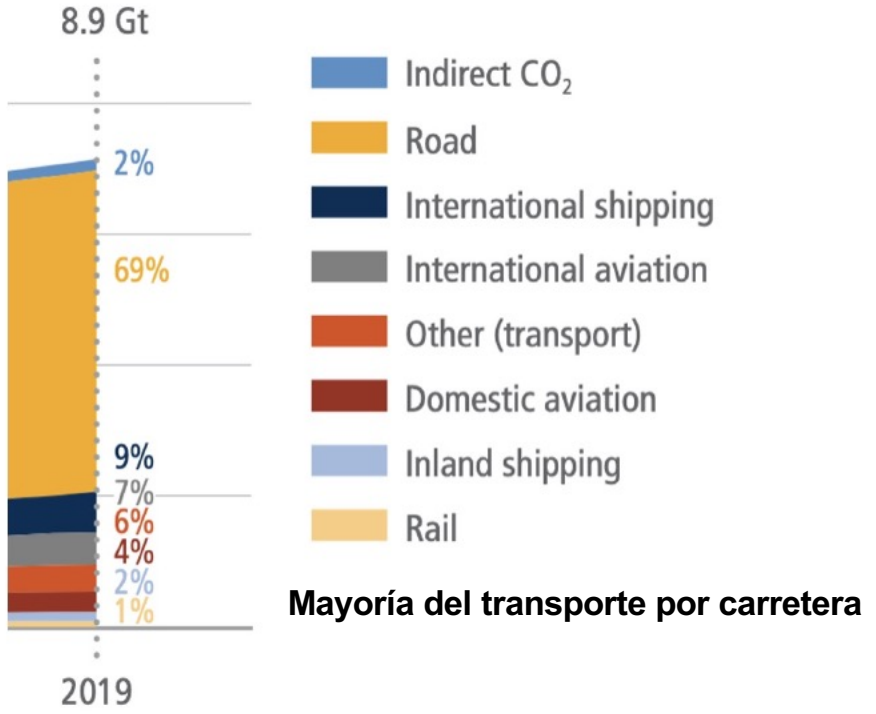
Fuente: Inventory of U.S. Greenhouse Gas Emissions and Sinks, US EPA, 2026.

[1] Rogelj, J., D. et al, 2018: Mitigation Pathways Compatible with 1.5°C in the Context of Sustainable Development. In: Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty. Cambridge University Press, Cambridge, UK and New York, NY, USA, pp. 93-174, doi:10.1017/9781009157940.004.
[2] U.S. Department of State. (2021). The United States of America's Nationally Determined Contribution: Reducing Greenhouse Gases in the United States: A 2030 Emissions Target. Submitted to the United Nations Framework Convention on Climate Change (UNFCCC) in 2021.
[3] "Inventory of U.S. Greenhouse Gas Emissions and Sinks." US EPA, 10 June 2026, url .

Contribución del sector del transporte al cambio climático



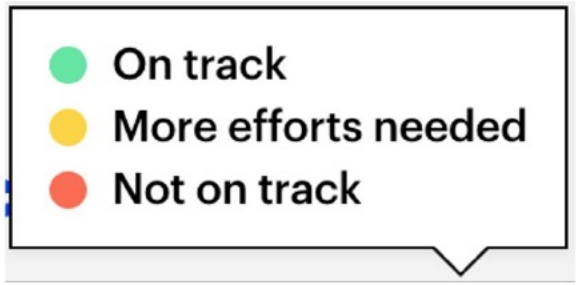
23 % de las emisiones mundiales de CO_2 relacionadas con la energía, en aumento



Mayoría del transporte por carretera

Jaramillo, P., et al., 2022: Transport. In IPCC, 2022: Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press. doi: 10.1017/9781009157926.012

¿Cómo vamos?



Tracking Transport

Not on track

In 2022, the rebound in passenger and cargo transport activity following the coronavirus (Covid-19) pandemic led to a 3% increase in transport CO_2 emissions compared to the previous year. Transport emissions grew at an annual average rate of 1.7% from 1990 to 2022, faster than any other end-use sector except for industry (which also grew at around 1.7%). To get on track with the Net Zero Emissions (NZE) by 2050 Scenario, CO_2 emissions from the transport sector must fall by more than 3% per year to 2030. Strong regulations and fiscal incentives, as well as considerable investment in infrastructure to enable low- and zero-emission vehicle operations, will be needed to achieve these emissions reductions.

- **Transport**
- **Cars and Vans**
- **Trucks and Buses**
- **Rail**
- **Aviation**
- **International Shipping**
- **Electric Vehicles**

Ver: informe de 2026

Tracking Transport. International Energy Agency (IEA), 2023

Emisiones conexas al transporte (las definiciones importan)

- «Sector del transporte» = emisiones operativas
  - Emisiones de GEI por el tubo de escape
- Excluidas: emisiones conexas al transporte, incluido el sector industrial (emisiones incorporadas)
  - Suministro de combustible y electricidad: extracción/refino de petróleo, producción de hidrógeno, generación de electricidad.
  - Ciclo de vida de los vehículos: fabricación, baterías, mantenimiento, desecho/reciclaje.
  - Ciclo de vida de las infraestructuras: carreteras, puentes, ferrocarril, aeropuertos, puertos, hormigón, asfalto, acero.
  - Efectos del uso del suelo: expansión urbana, aparcamiento, tráfico inducido, trayectos más largos.
  - Efectos digitales/de automatización: cómputo, sensores, centros de datos, reposicionamiento en vacío, tráfico inducido.

Por qué es difícil descarbonizar el transporte

Numerosos mecanismos de inercia y resistencia:

- **La demanda crece con los ingresos, la urbanización y el comercio electrónico;**
- **Los viajes están condicionados por el uso del suelo, la vivienda, el empleo y la logística**
- **Los activos se renuevan lentamente (décadas): vehículos, carreteras, depósitos, puertos, cargadores, redes**
- **Las decisiones están fragmentadas entre hogares, empresas, ciudades, eléctricas y gobiernos**
- **Beneficios y perjuicios se reparten de forma desigual**
- **Las mejoras de eficiencia pueden generar más viajes, más km o trayectos más largos (paradoja de Jevons)**

Los distintos sistemas de transporte tienen estructuras de decisión diferentes:

Factor	**Transporte de pasajeros**	**Mercancías / transporte pesado**
Principal cuello de botella	Uso del suelo + opciones de movilidad → coste/comodidad → comportamiento	Densidad energética + logística → coste operativo
Estructura de decisión	Miles de millones de hogares y viajeros	Menos empresas, flotas, cargadores, transportistas, puertos
Vía de electrificación	Más fácil para viajes ligeros	Más difícil para el transporte pesado y de larga distancia
Riesgo de demanda inducida	Viajar más barato/fácil → más km recorridos	Logística/bienes más baratos → más mercancías

La descarbonización no es el único objetivo (multiobjetivo)

Reflexione: ¿son objetivos que compiten o se complementan? ¿Hasta qué punto pueden alinearse?

Objetivos del transporte, sin un orden particular:

- Descarbonización
- Acceso
- Asequibilidad
- Movilidad
- Seguridad vial
- Eficiencia / coste
- Salud pública
- Confort / habitabilidad
- Calidad del aire
- Seguridad pública
- Privacidad
- Resiliencia
- Seguridad energética
- Economía local

Marcos de descarbonización

Enfoque 1: marco Evitar-Cambiar-Mejorar (ASI)

Evitar: reducir los km recorridos

- urbanismo compacto,
- teletrabajo,
- encadenamiento de viajes,
- reforma del aparcamiento,
- tarificación vial,
- consolidación de mercancías.

Cambiar: trasladar viajes de modos más emisores a modos menos emisores

- planificación multimodal y navegación (a pie, bicicleta, tren, transporte público),
- diseño de calles completas,
- transporte intermodal,
- prioridad a vehículos de alta ocupación,
- movilidad como servicio (MaaS).

Mejorar: reducir las emisiones por kilómetro

- electrificación,
- vehículos eficientes,
- conducción eficiente y anti-ralentí,
- gestión del tráfico,
- programas de achatarramiento de vehículos contaminantes,
- combustibles más limpios y bajos en carbono.

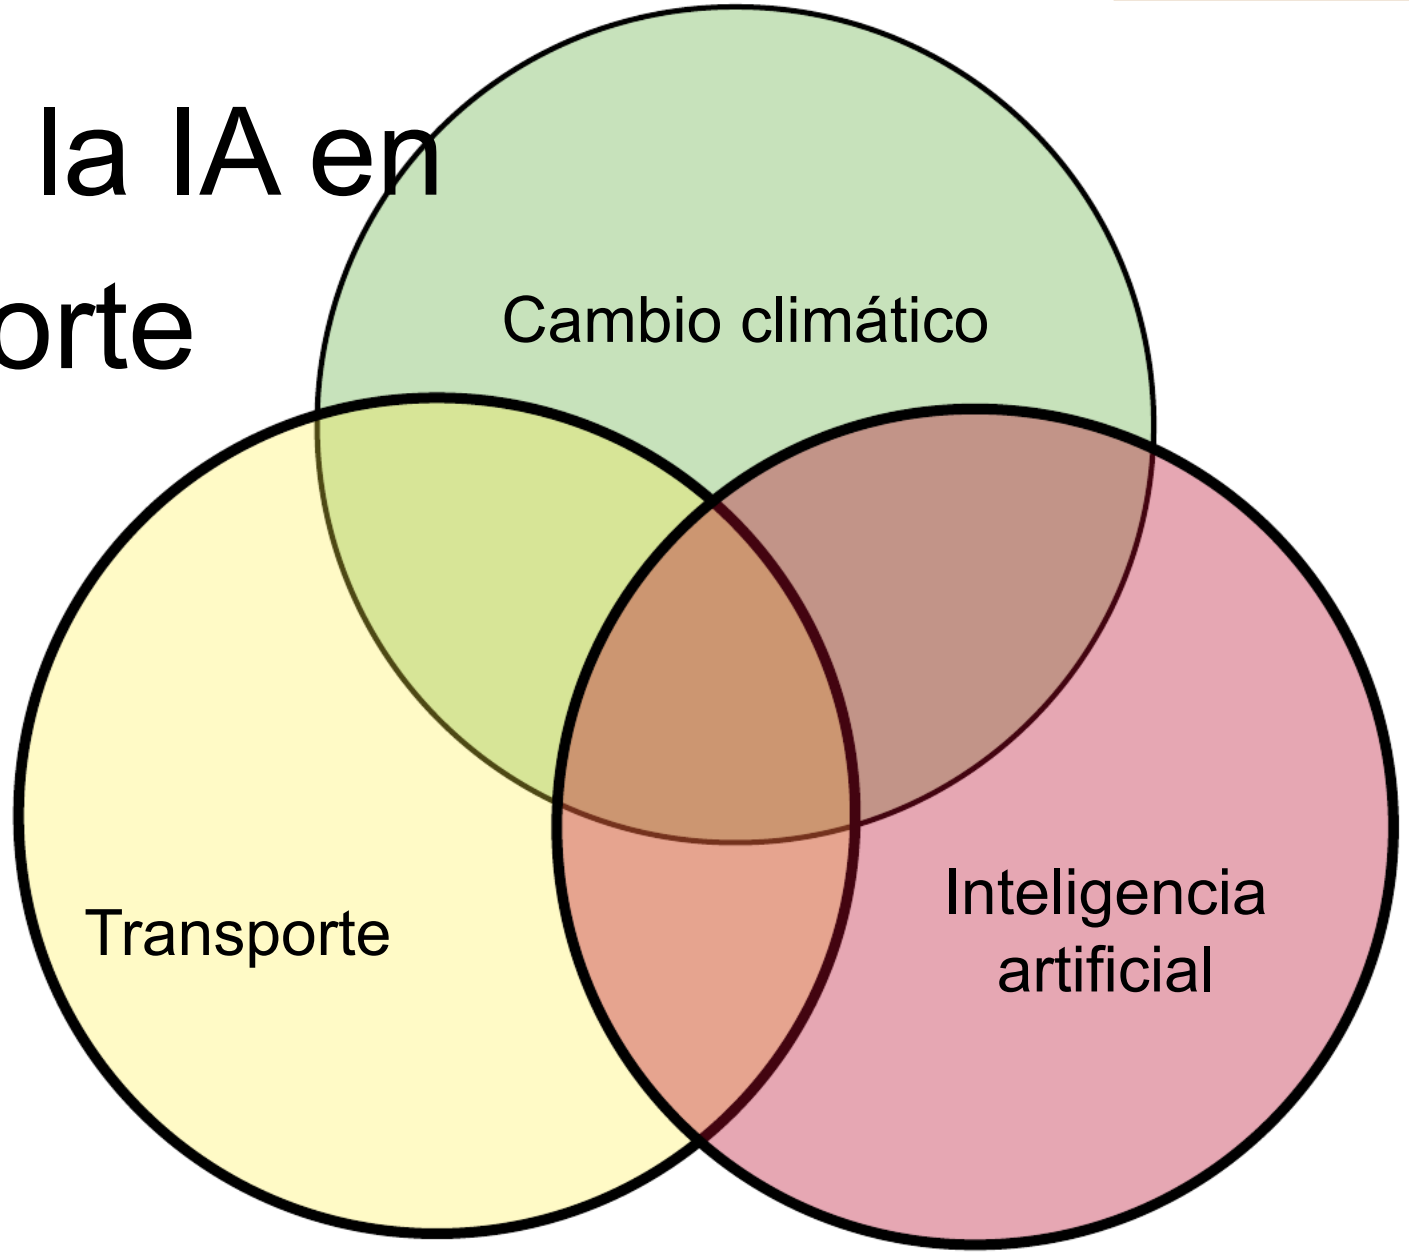
[1] P. Jaramillo and et al., “Transport,” in Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change, 2024. doi: 10.1017/9781009157926.012.

Enfoque 2: una transición rápida, justa y equitativa

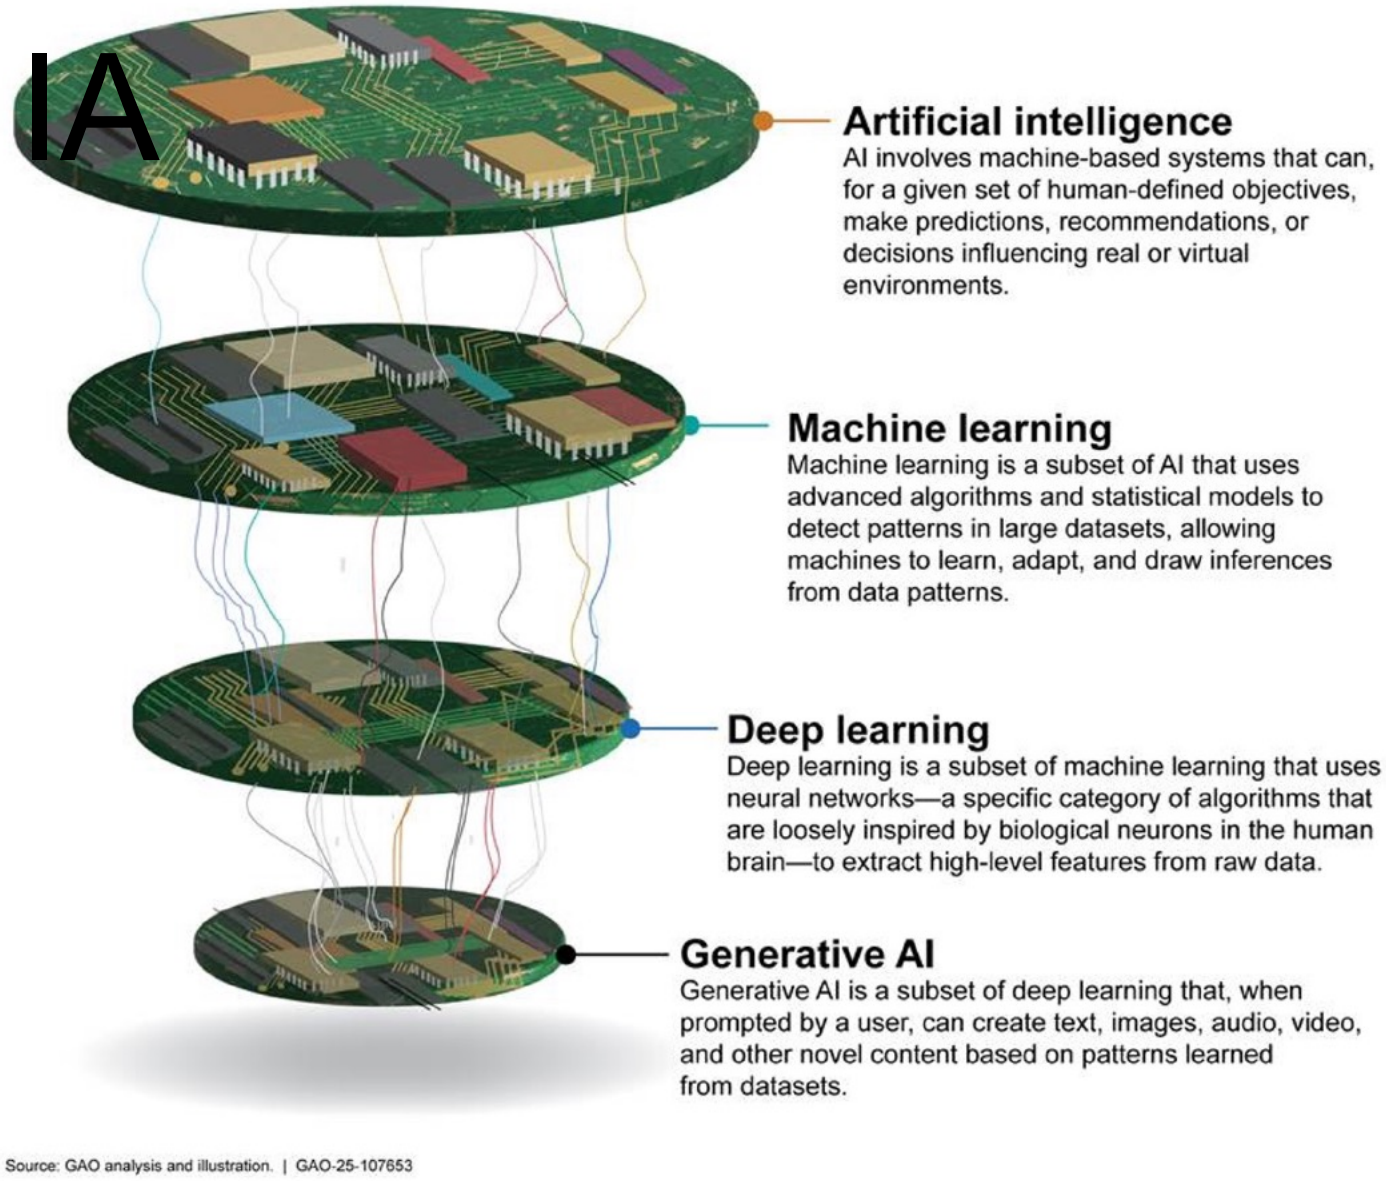


United Nations Economic Commission for Europe (UNECE), "About Just Transition," 2025, unece.org/sustainable-energy/just-transition/about-just-transition.

Panorama de la IA en el transporte



Definición de IA



[1] C. Wright and K. Walsh, “Artificial intelligence: Generative AI use and management at federal agencies,” United States Government Accountability Office, Report to Congressional Requesters GAO-25-107653, 2025. [Online]. Available: https://files.gao.gov/reports/GAO-25-107653/index.html

Aplicaciones habituales de la IA en el transporte



Fig. 1. Key applications of AI, ML, and DL in advanced transportation systems.

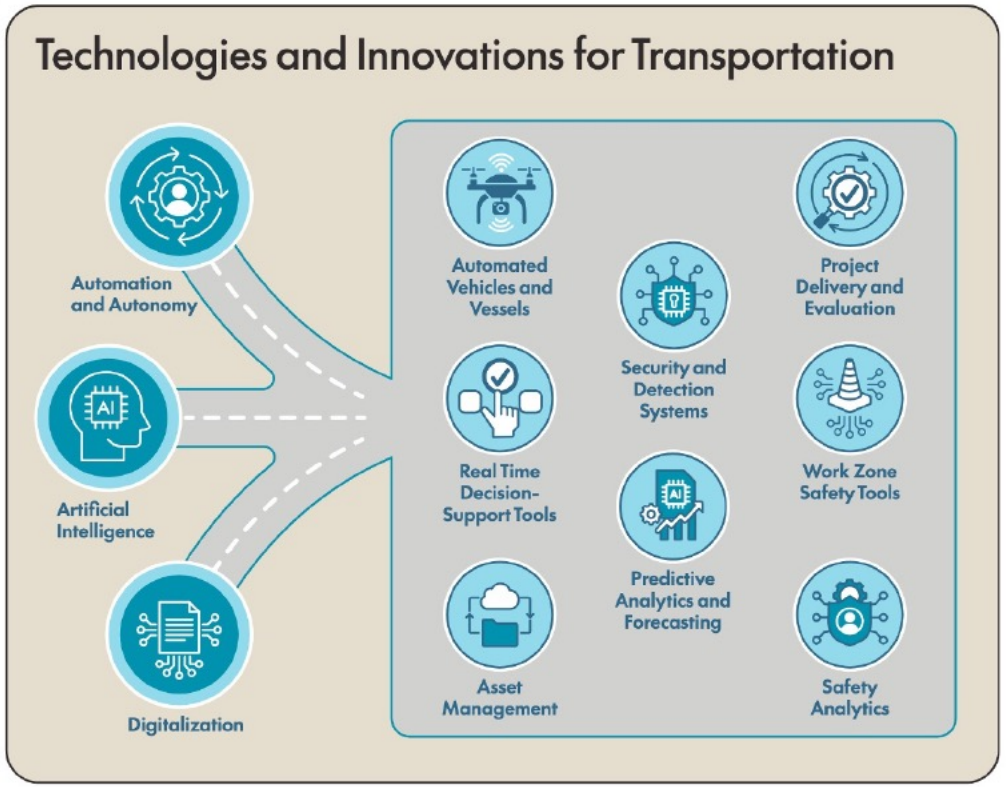


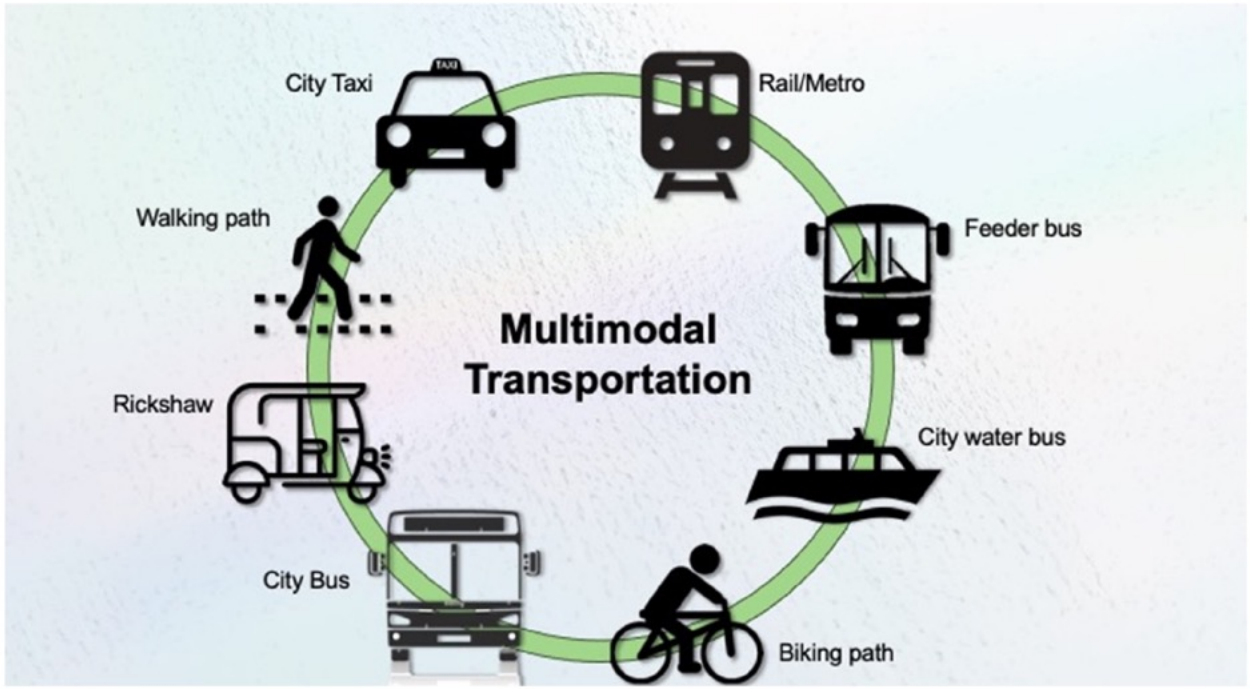
FIGURE 1. Artificial intelligence, advanced automation and autonomy, and digitalization are separately and jointly producing innovations in transportation.

[1] S. Saki and M. Soori, "Artificial intelligence, machine learning and deep learning in advanced transportation systems, a review," Multimodal Transportation, vol. 5, no. 1, p. 100242, Mar. 2026, doi: 10.1016/j.multra.2025.100242.
[2] Transportation Research Board Executive Committee, Transportation Research Board, and National Academies of Sciences, Engineering, and Medicine, Transforming Transportation: Leveraging the Power of Artificial Intelligence, Digitalization, and Automation. Washington, D.C.: National Academies Press, 2026, p. 29350. doi: 10.17226/29350.

Modos de transporte

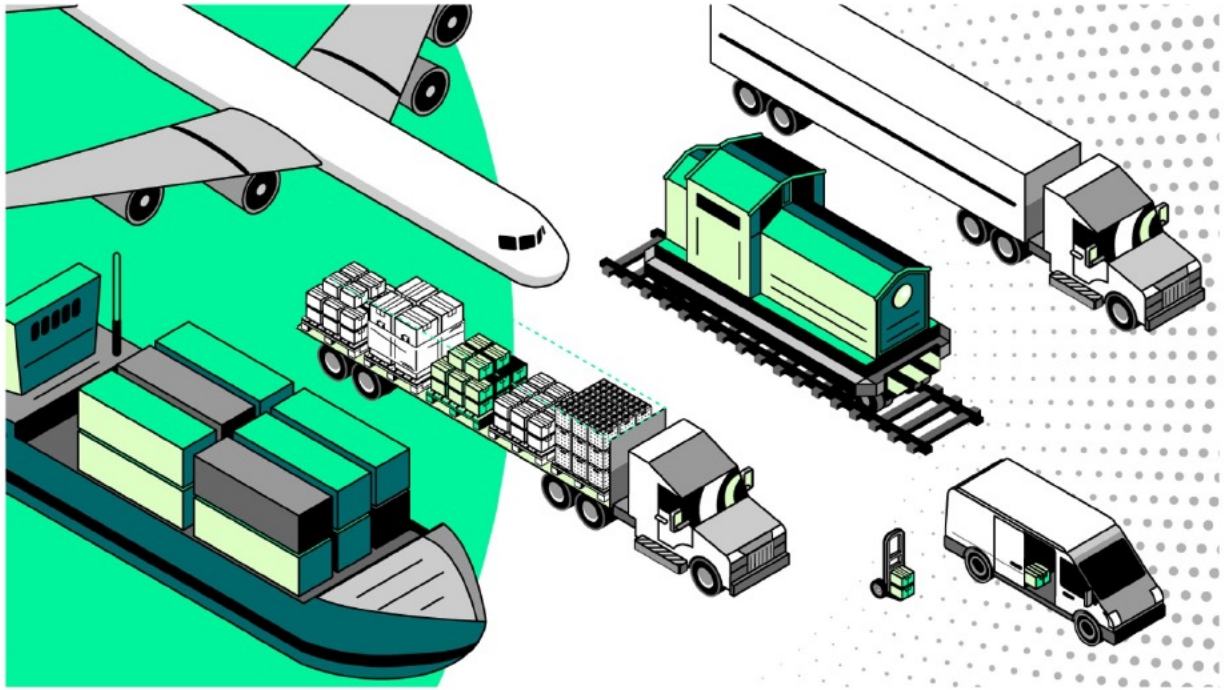
Camiones y autobuses: 8 % de los vehículos, pero 35 % de la energía del transporte por carretera (AIE, 2026)

Movimiento de personas



Fuente: Audirac, Ivonne, et al. "Transportation and Mobility Modes." 2024.

Movimiento de mercancías

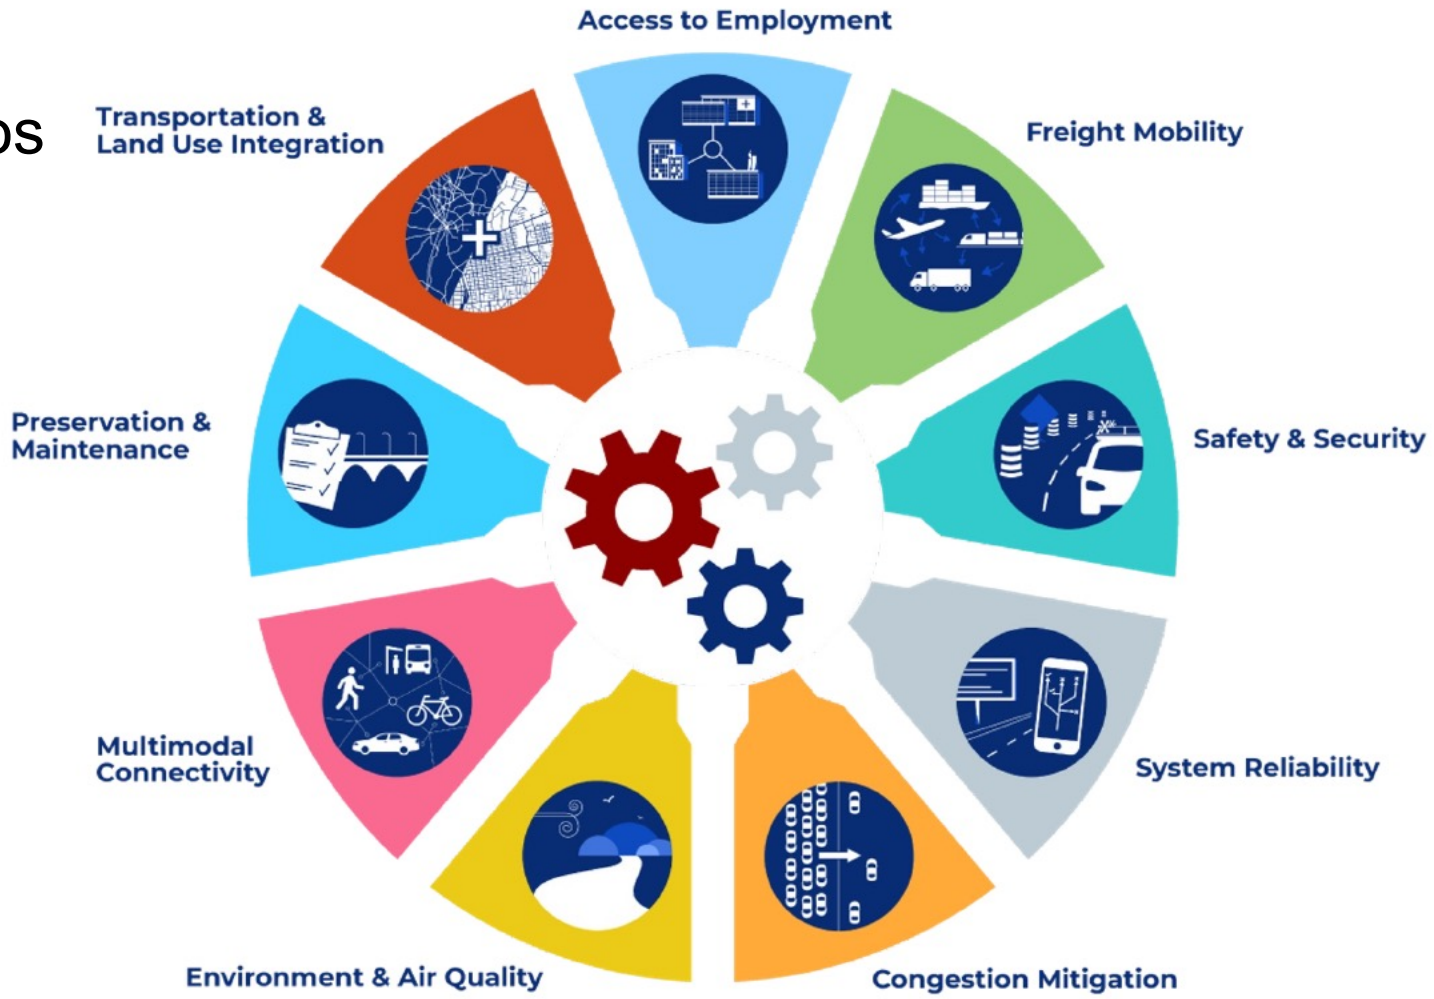


Fuente: RXO, 2026.

La IA puede aplicarse a distintos modos de transporte

Objetivos de los sistemas de transporte

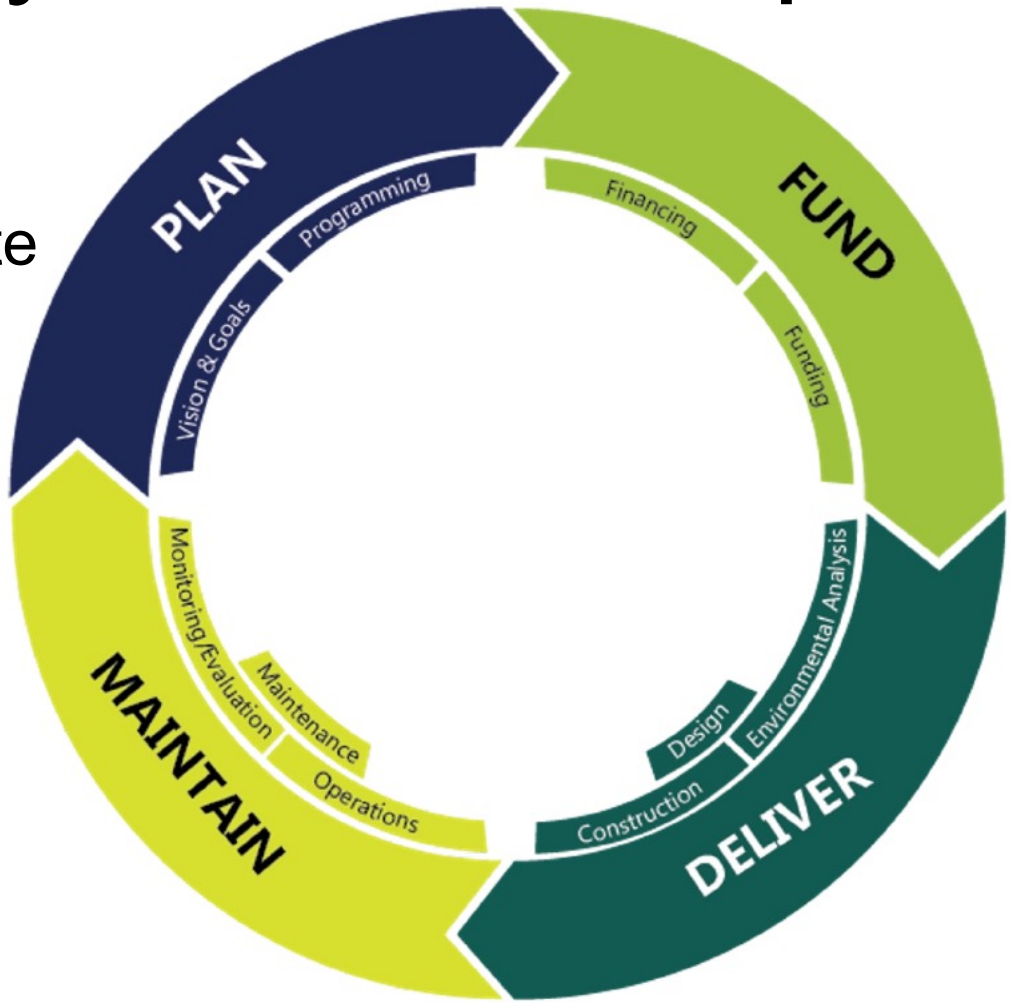
La IA puede aplicarse a distintos objetivos de transporte



Fuente: Plan RVA. "What is Transportation Planning?", 2019.

Ciclo de vida de un proyecto de transporte

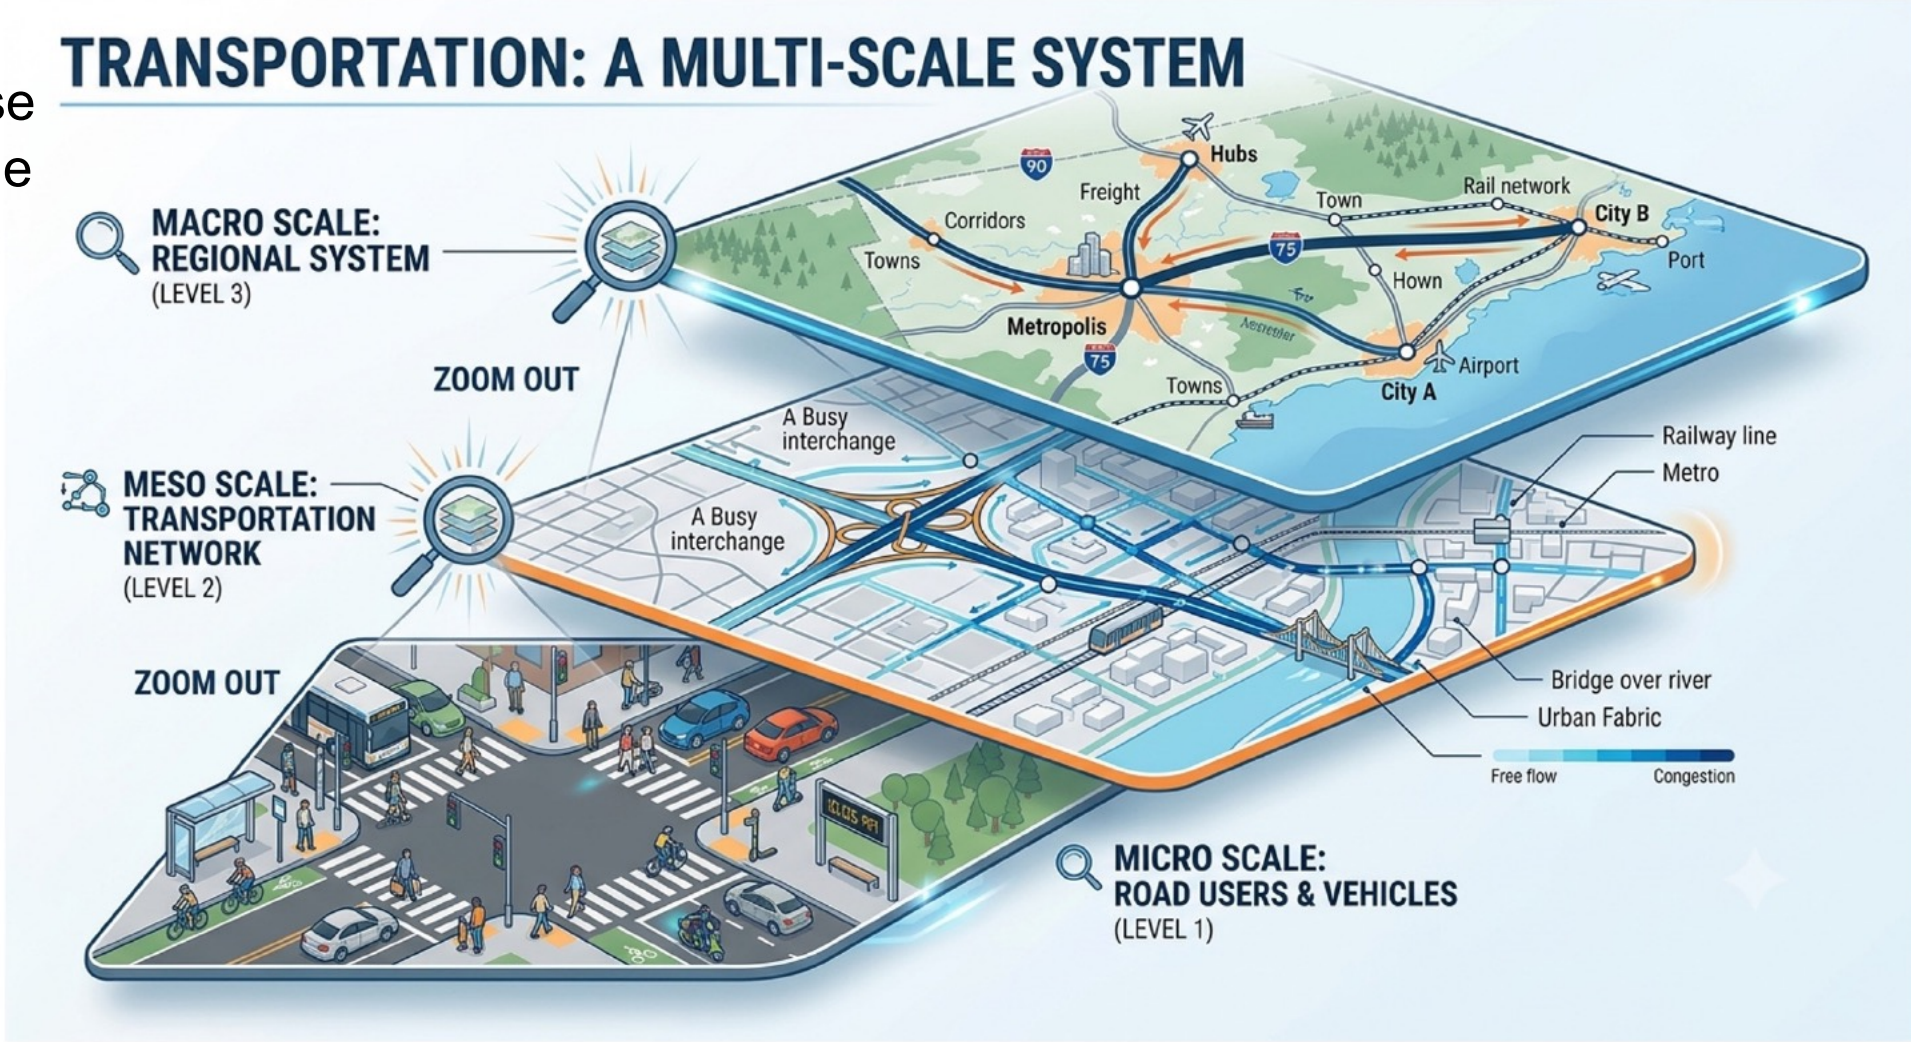
La IA puede aplicarse en distintas etapas del ciclo de vida de un proyecto de transporte



Fuente: US DOT. "Transportation Planning and Project Delivery." 2023.

El transporte como sistema multiescala

La IA puede aplicarse a distintas escalas de un sistema de transporte



Fuente: generado con Gemini 3 (Nano Banana), 13/07/2026.

IA y niveles de madurez tecnológica (TRL)

- Compara la madurez de las tecnologías
- Desarrollado por la NASA en los años setenta para tecnologías de exploración espacial

Categorías de casos de uso:

- Evaluar la madurez de tecnologías de IA (LLM, RL profundo, etc.)
- Usar la IA para evaluar la madurez de otras tecnologías (VA, VE, etc.)



Fuente: TWI Global.

US DOT Federal Highway Administration, What Is A Trl? - Technology Readiness Level Guidebook , 2017, www.fhwa.dot.gov/publications/research/ear/17047/001.cfm.

La visibilidad y las decisiones están fragmentadas

Reto: la IA debe aplicarse desde la perspectiva de un grupo de actores

Adaptado de S. S. R. Bonthu, et al., 2022.

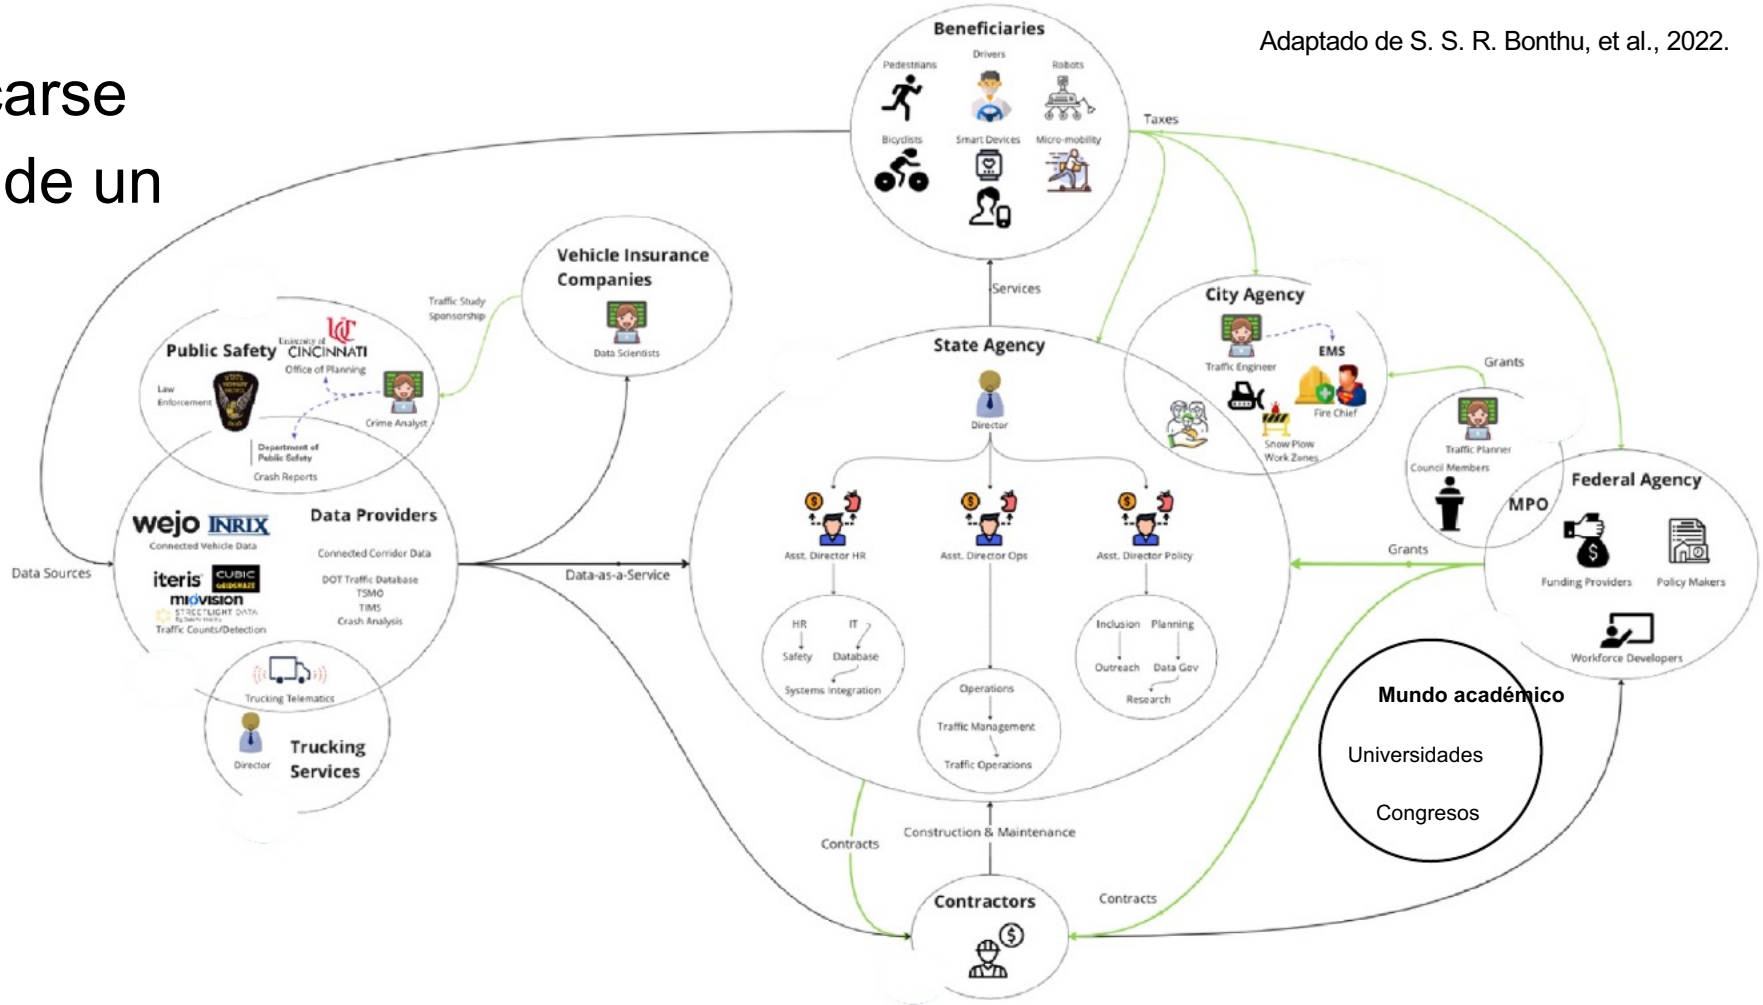


Figure 2. Complex transportation ecosystem with interview count highlighted across government agencies, data providers, and contractors.

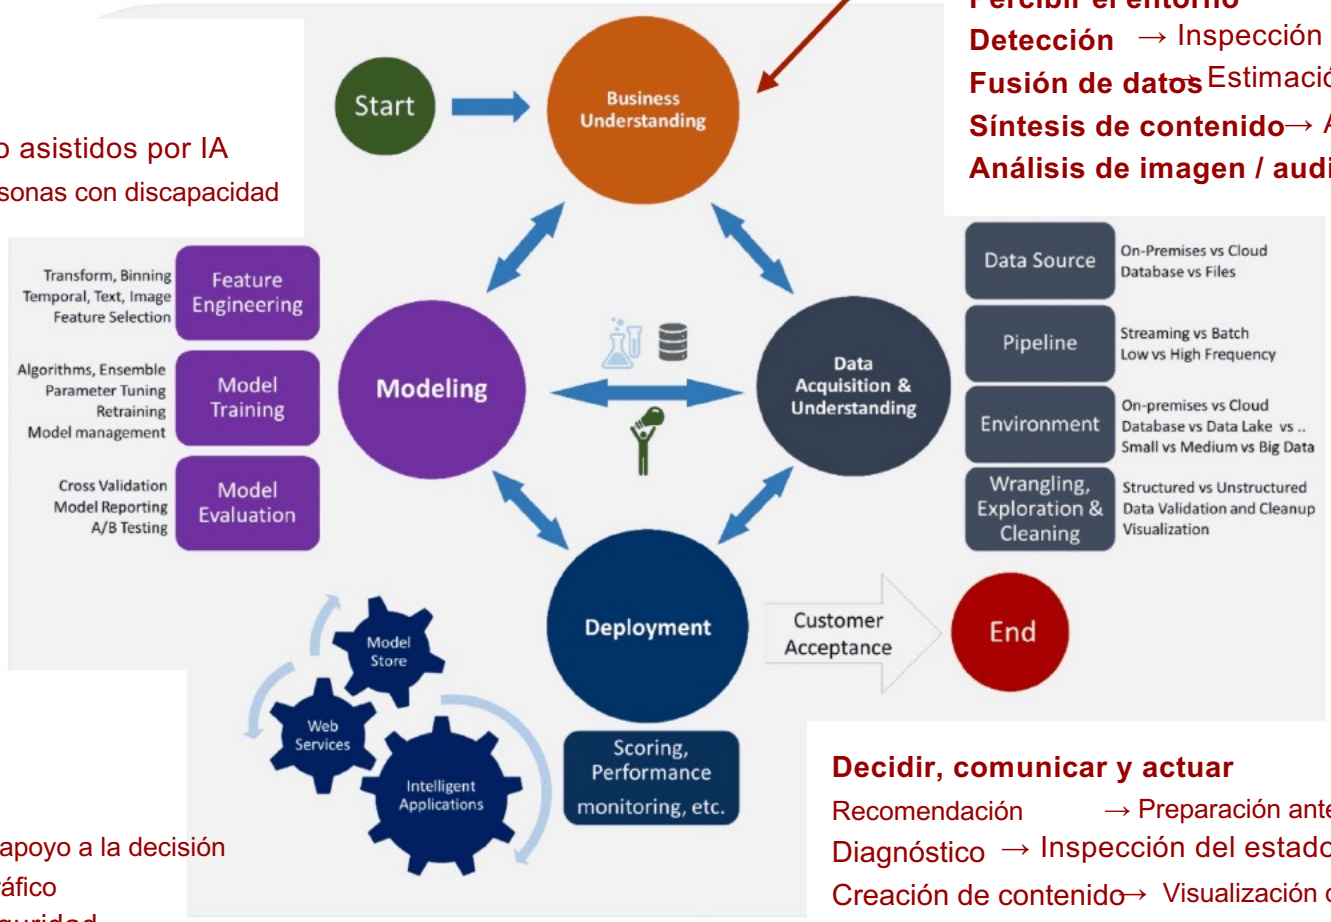
Ciencia de datos en el transporte

Elija un modo, una etapa del ciclo de vida, una medida de rendimiento, una escala, un TRL, un grupo de actores, etc.

Percibir el entorno
Detección → Inspección del estado de la infraestructura
Fusión de datos → Estimación del estado del tráfico
Síntesis de contenido → Análisis de la participación pública
Análisis de imagen / audio → Análisis de seguridad

Razonar y analizar información
Predicción → Previsiones de viajes
Simulación → Gemelos digitales del tráfico asistidos por IA
Personalización → Planificación de viajes para personas con discapacidad

La IA en distintas etapas de un flujo de ciencia de datos en un caso de uso de transporte



Fuente: Eric Mihail. "What is the Data Science Life Cycle?" 2026.

Aprender de la experiencia
Optimización → Rutas para emergencias
Descubrimiento → Materiales innovadores
Recuperación de información → Herramientas de apoyo a la decisión
Mejora del rendimiento → Gestión del tráfico
Monitorización → Cámaras o sensores de seguridad

Decidir, comunicar y actuar
Recomendación → Preparación ante fenómenos meteorológicos extremos
Diagnóstico → Inspección del estado de la infraestructura
Creación de contenido → Visualización de datos de viajes
Asistencia digital → Atención al cliente

[1] Transportation Research Board Executive Committee, Transportation Research Board, and National Academies of Sciences, Engineering, and Medicine, Transforming Transportation: Leveraging the Power of Artificial Intelligence, Digitalization, and Automation. Washington, D.C.: National Academies Press, 2026, p. 29350. doi: 10.17226/29350.
[2] M. Vasudevan et al., "Identifying Real-World Transportation Applications Using Artificial Intelligence (AI)- Real-World AI Scenarios in Transportation for Possible Deployment," FHWA-JPO-20-810, Jul. 2020. Accessed: Jan. 07, 2024. [Online]. Available: https://rosap.ntl.bts.gov/view/dot/50752.

La IA apoya distintos tipos de automatización en el transporte

Automatización en el transporte

- Automatización de vehículos → coche o autobús de nivel 4 SAE
- Automatización robótica → actividades de mantenimiento
- Automatización de procesos → registro de accidentes sobre el terreno



El transporte público recurre a la robótica | Fuente: Sandalow, David B. et al., 2024.



Robot móvil de limpieza y desinfección | Fuente: Fraunhofer IFAM, 2022.

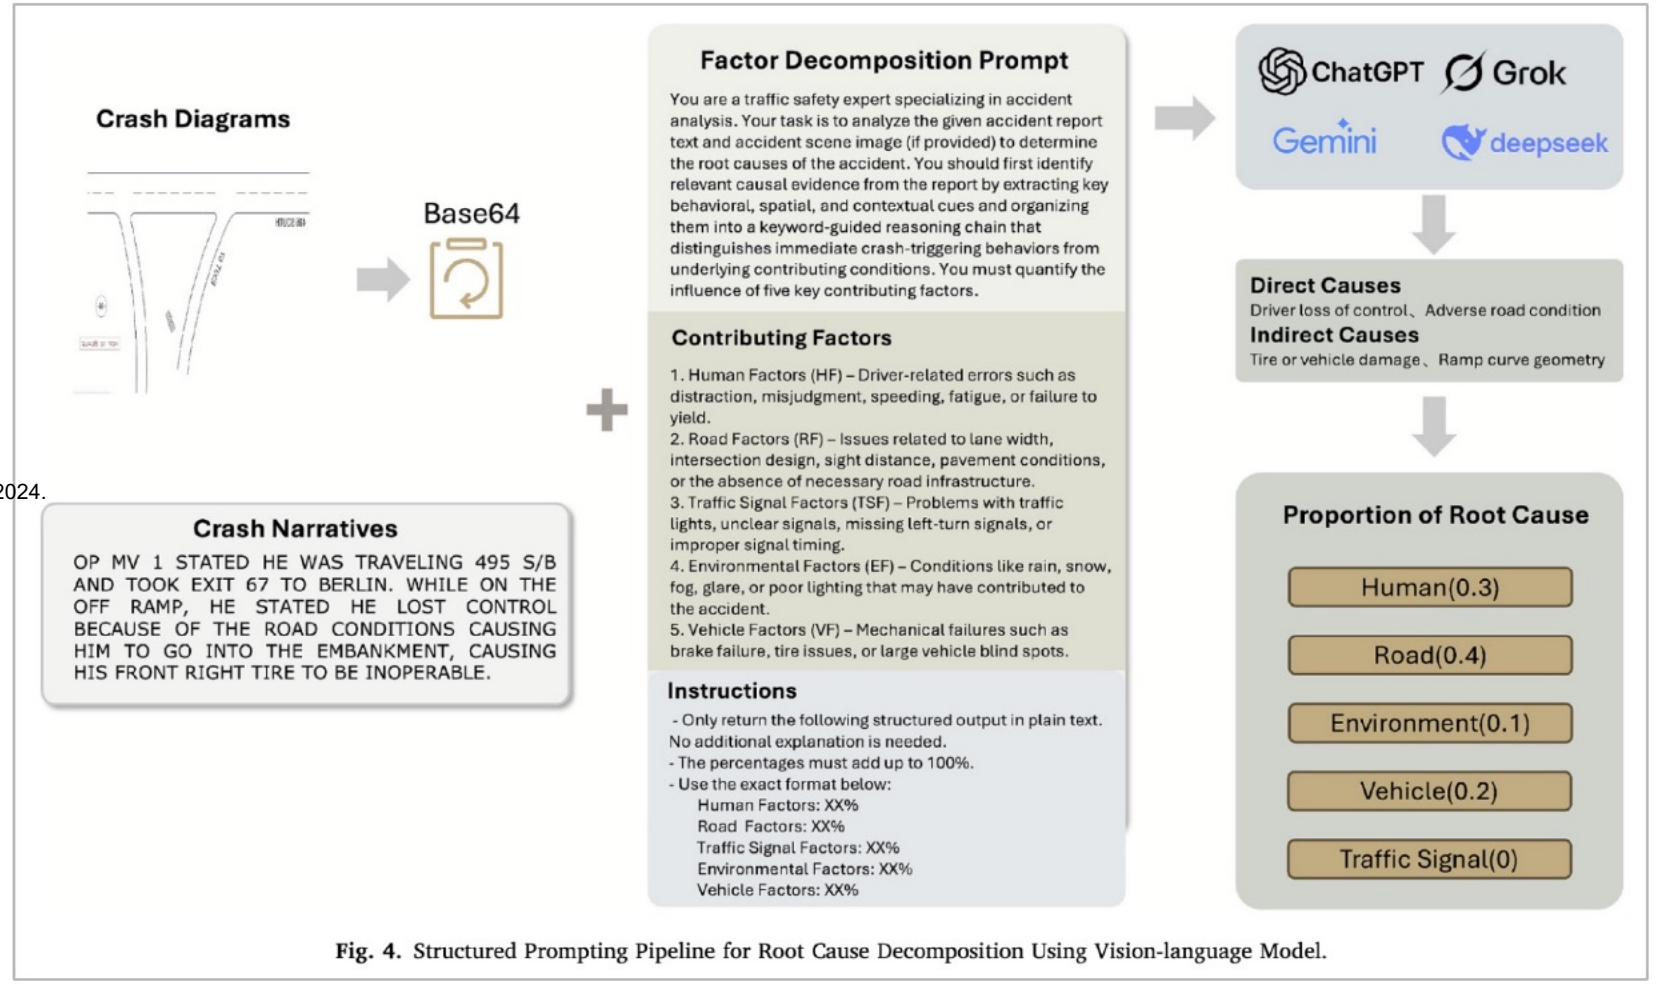
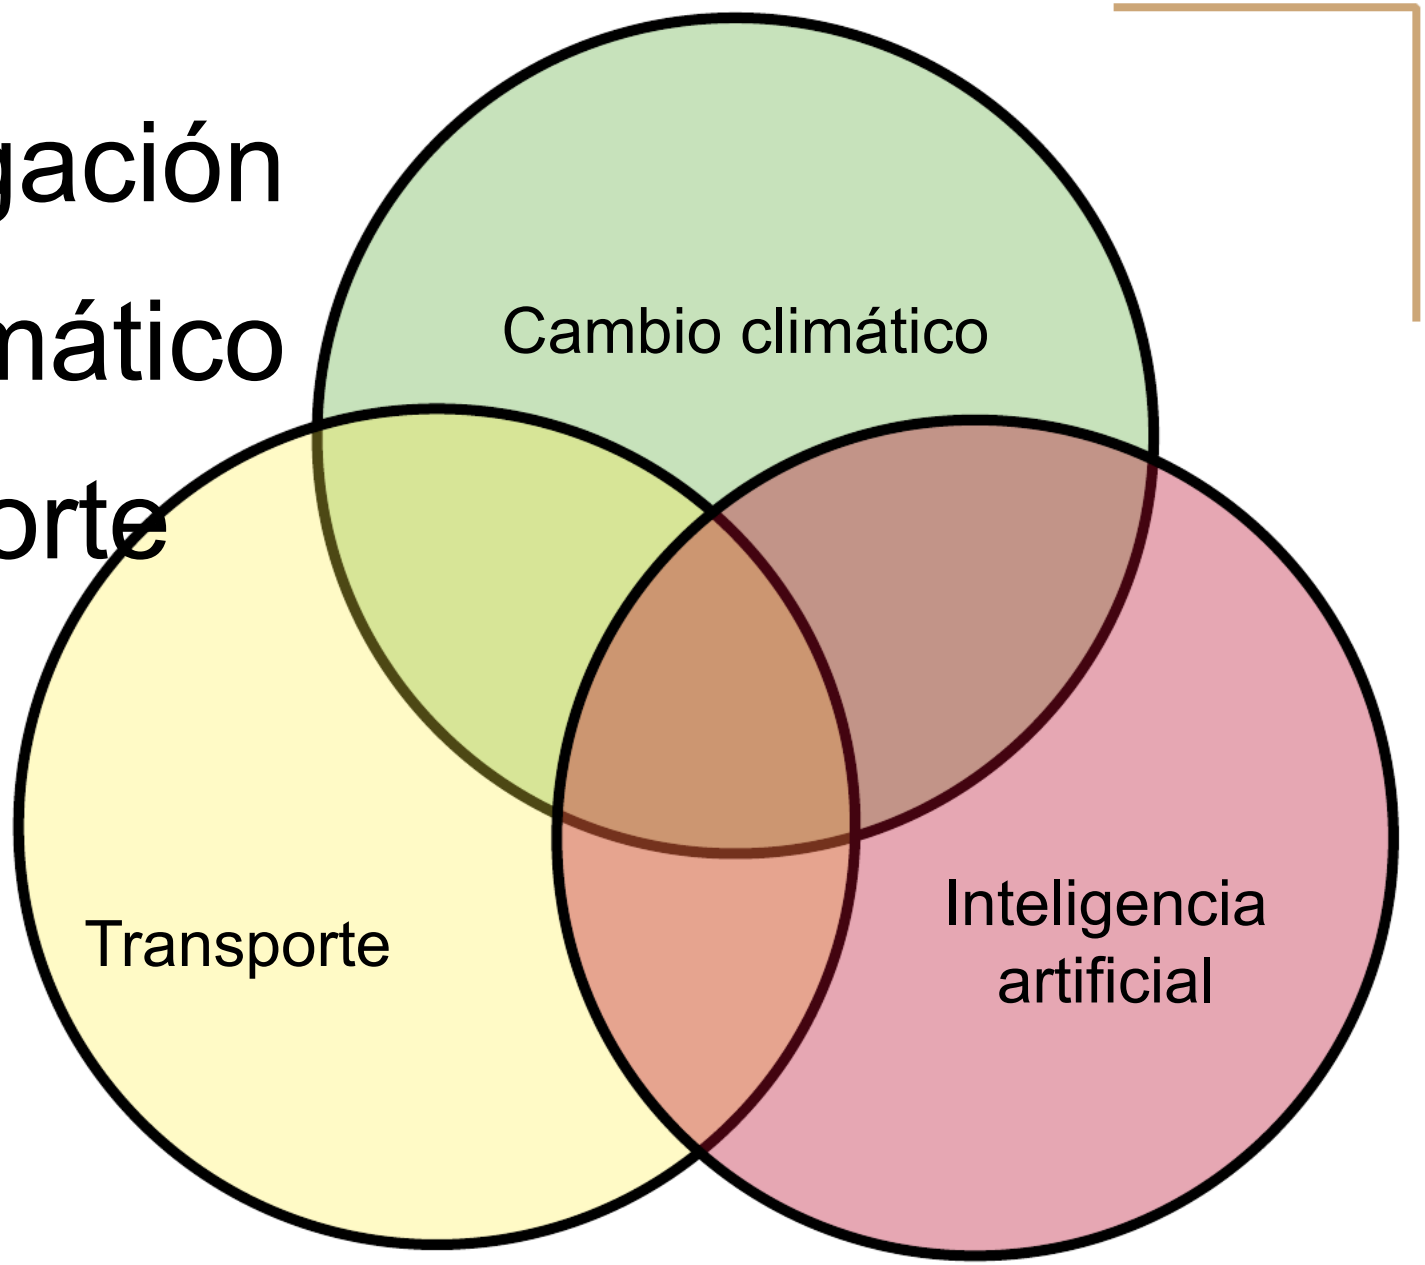


Fig. 4. Structured Prompting Pipeline for Root Cause Decomposition Using Vision-language Model.

Fuente: Wu, G., et al., "From crash reports to safer roads: a multimodal framework integrating vision-language models and streetview analysis," 2026.

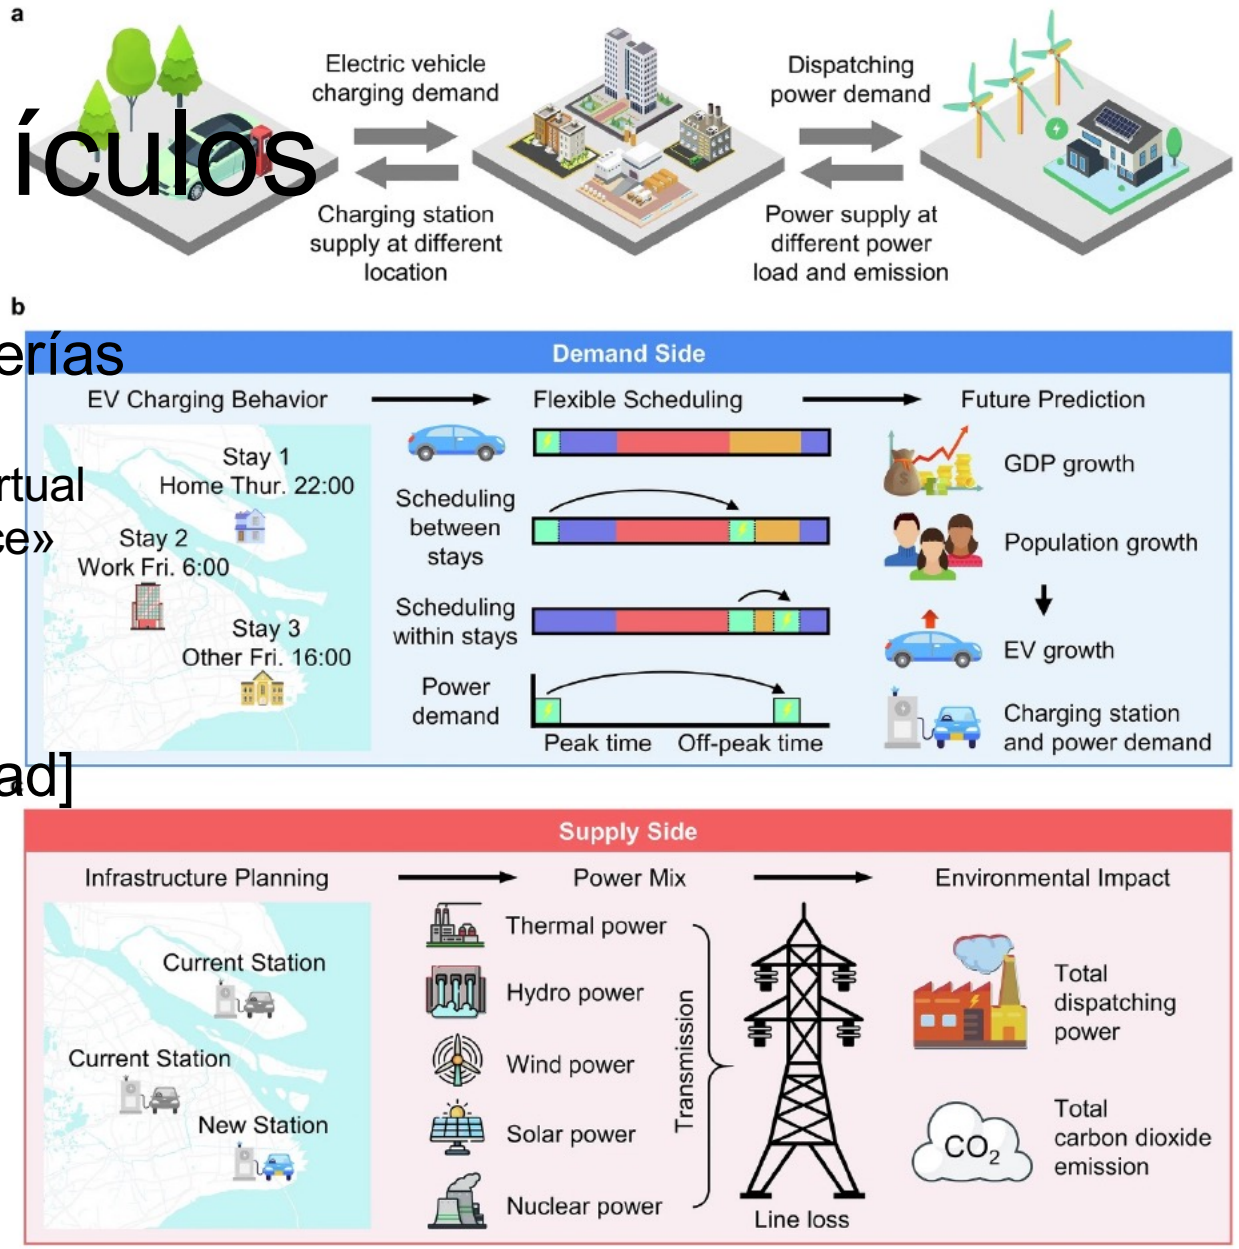
[1] Transportation Research Board Executive Committee, Transportation Research Board, and National Academies of Sciences, Engineering, and Medicine, Transforming Transportation: Leveraging the Power of Artificial Intelligence, Digitalization, and Automation. Washington, D.C.: National Academies Press, 2026, p. 29350. doi: 10.17226/29350.

IA para la mitigación del cambio climático en el transporte



Electrificación de vehículos

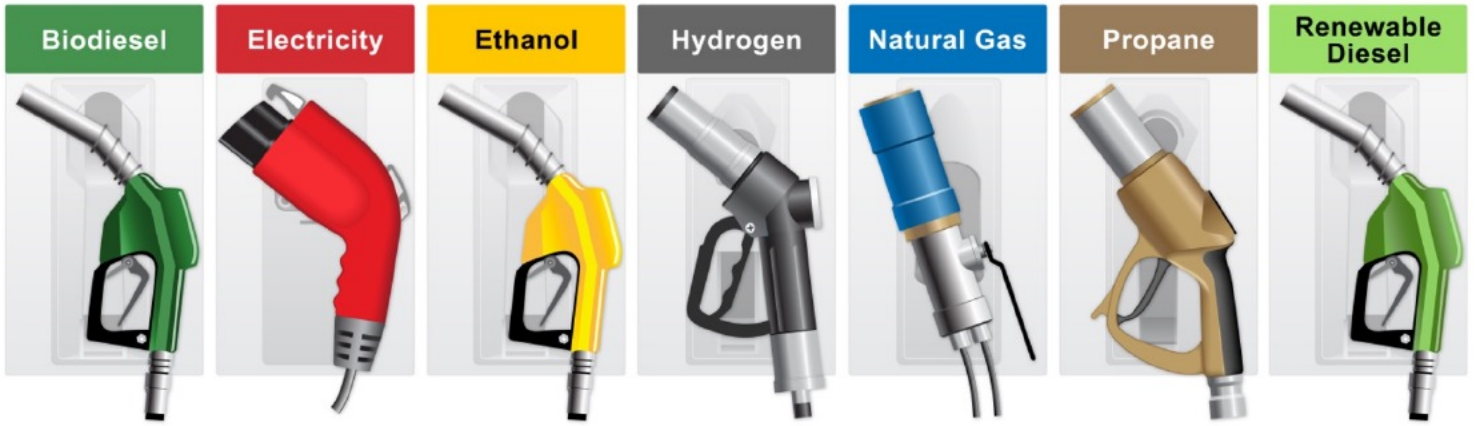
- Descubrimiento de materiales para baterías y motores
  - Véase la clase de la Escuela de verano virtual CCAI «AI for Accelerated Materials Science» de Francisco Martin-Martinez, jue. 13 de agosto, 14:00–16:00 UTC
- Carga/descarga asistida por IA para la gestión de la energía [en profundidad]
  - Vehículo (gestión de la batería)
  - Red (carga bidireccional, V2G/V2H/V2B)
- Predicción/gemelos digitales para la salud, el reciclaje y la reutilización de baterías



[1] Sandalow, David B. et al., “Artificial Intelligence for Climate Change Mitigation Roadmap (Second Edition),” Nov. 2024, doi: 10.7916/2J4P-NW61.
[2] Liao, Chenlei, et al. "Optimizing electric vehicle charging patterns and infrastructure for grid decarbonization." Commun. Sustain., 2026, doi:10.1038/s44458-026-00037-7.

Combustibles alternativos

- Mejor uso: vehículos pesados, larga distancia, casos afines a la aviación/marítimo
- Combustibles: biocombustibles, combustibles sintéticos, hidrógeno, gas natural comprimido/licuado (GNC/GNL)
- Papel de la IA: optimizar la producción de combustible, catalizadores, electrólisis, pilas de combustible, la combustión, la logística y la planificación de infraestructuras
- Advertencia: los biocombustibles pueden tener impactos por cambio de uso del suelo; el gas natural es transitorio, no cero carbono



Fuente: US Department of Energy. "Federal Fleet Alternative Fuel Resources." Energy, 2026.

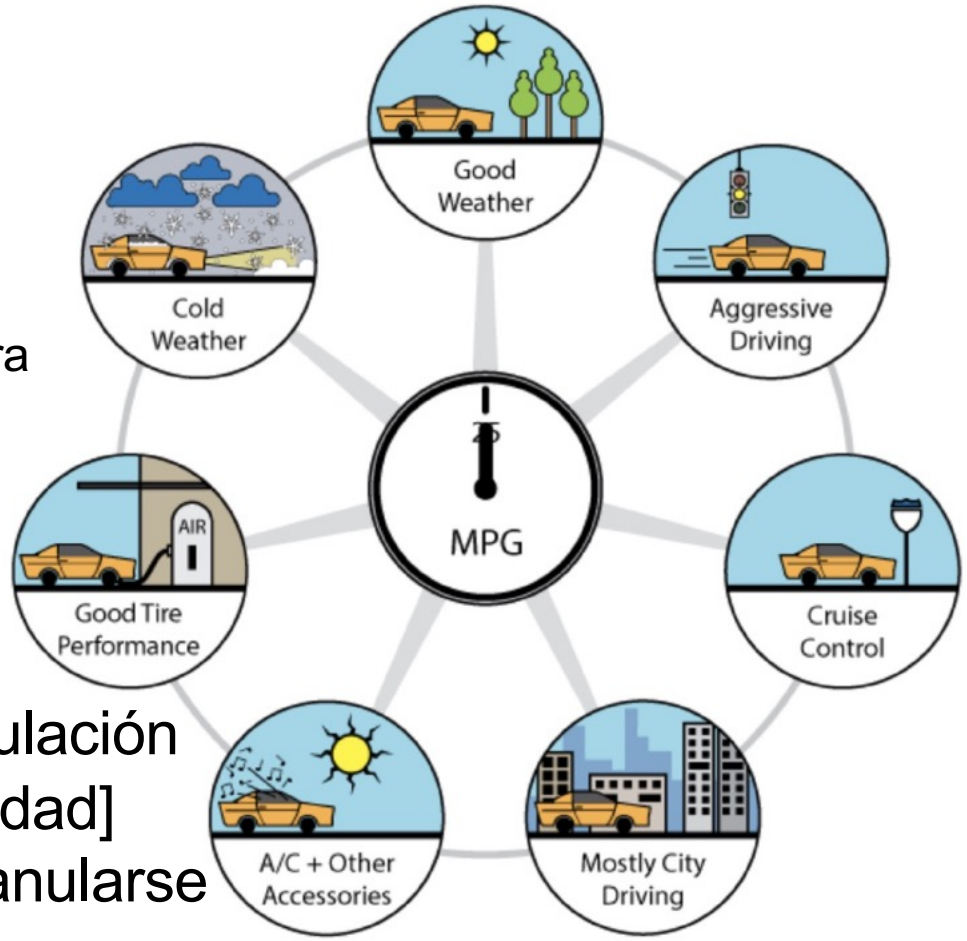
[1] Sandalow, David B. et al., “Artificial Intelligence for Climate Change Mitigation Roadmap (Second Edition),” Nov. 2024, doi: 10.7916/2J4P-NW61.

Eficiencia de los vehículos

IA para el diseño y la operación

- En diseño, la IA puede apoyar:
  - el diseño de motores de combustión
  - la reducción del peso o de la resistencia a la rodadura
  - estrategias de gestión de energía híbrida
  - aerodinámica: modelos sustitutos y carga ineficiente en trenes de mercancías
  - fabricación asistida por IA
- En operación, la IA puede apoyar la conducción eficiente, un tráfico más fluido, la circulación en pelotón y el control energético [en profundidad]
- Advertencia: las mejoras de eficiencia pueden anularse por el tráfico inducido, sobre todo con VA

Factores que afectan al consumo



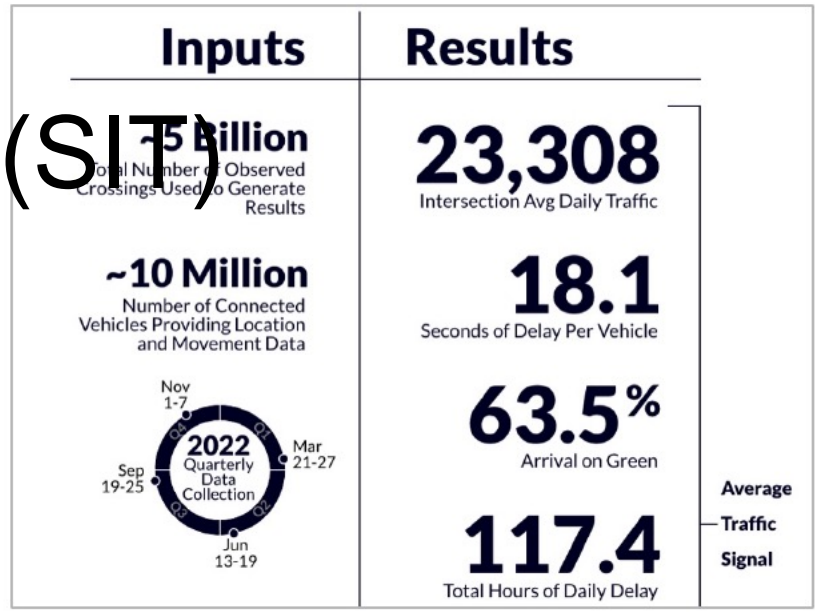
Fuente: US EPA, “Your Mileage May Vary,” 2026.

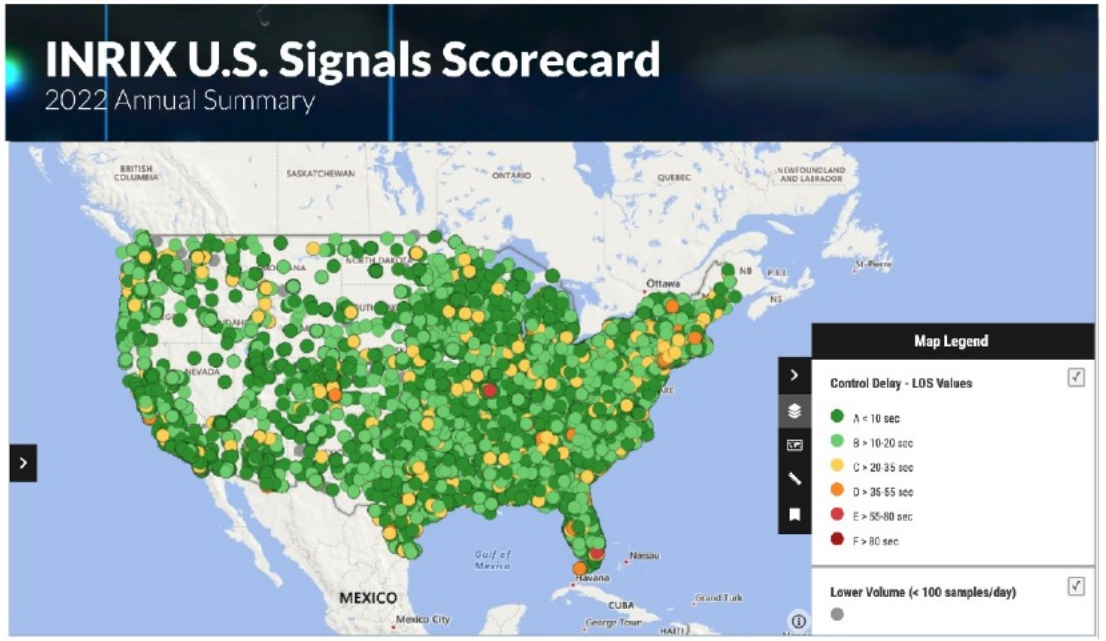
[1] D. Rolnick et al., “Tackling climate change with machine learning,” Jun. 2019, [Online]. Available: http://arxiv.org/abs/1906.05433v2

Sistemas inteligentes de transporte (SIT)

IA para infraestructuras y operación

- Predecir congestión y anomalías a partir de sensores, GPS, cámaras y datos de tráfico.
- Optimizar semáforos, rutas, respuesta a incidentes, horarios del transporte público y mantenimiento para reducir demoras, congestión, combustible y emisiones.
- La simulación con IA puede evaluar la ubicación de cargadores, carriles bici, política de tráfico y demanda de energía.
- Retos: infraestructura de datos (sensores, V2V/V2I, análisis en el borde, integración en la nube)
- Advertencia: sensores y cómputo tienen costes en privacidad, sesgos y emisiones.



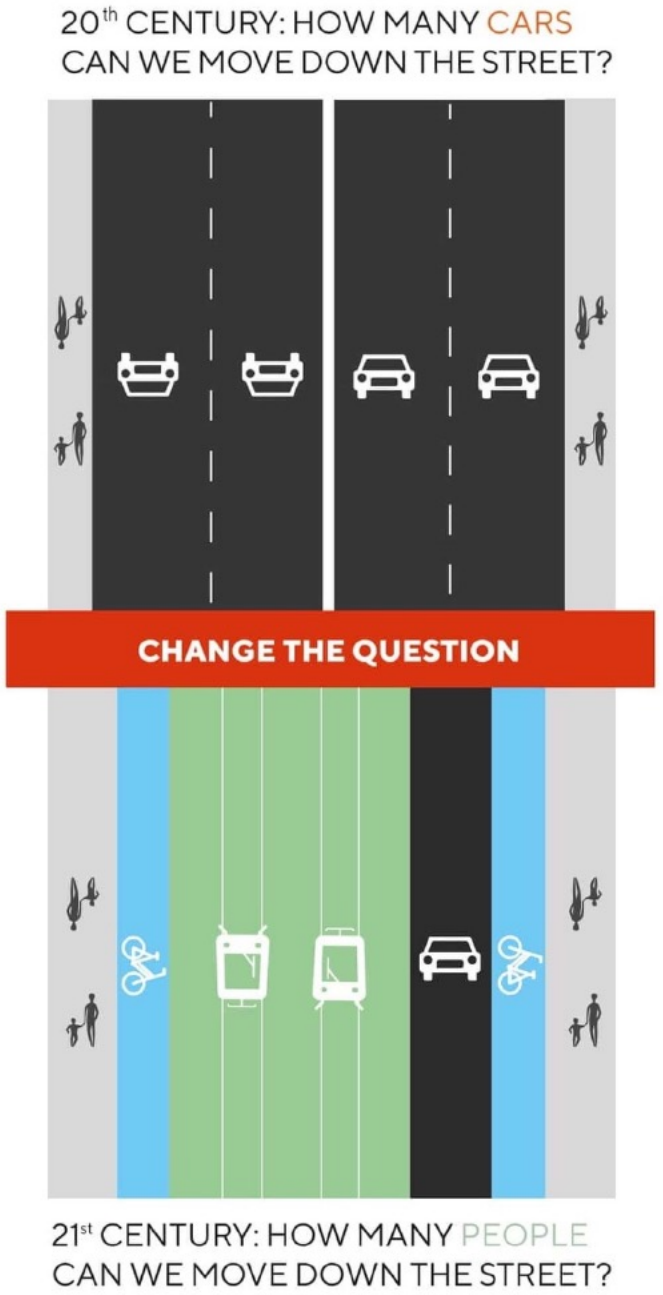


[1] Sandalow, David B. et al., “Artificial Intelligence for Climate Change Mitigation Roadmap (Second Edition),” Nov. 2024, doi: 10.7916/2J4P-NW61.
[2] INRIX U.S. Signals Scorecard: 2022 Annual Summary. INRIX. https://inrix.com/signals-scorecard/.

Cambio modal

La IA puede facilitar la elección de modos bajos en carbono

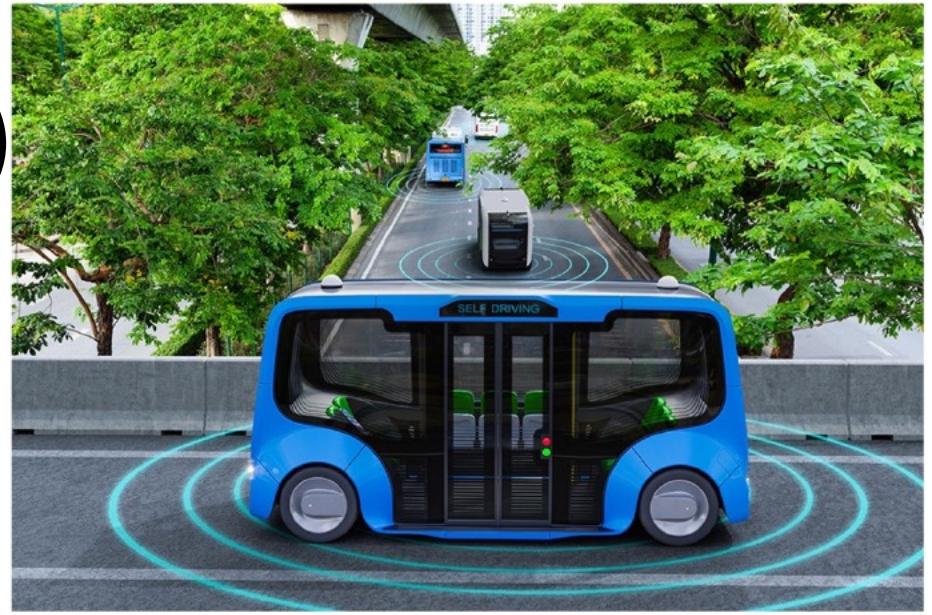
- Planificación de servicios y del sistema
  - a. Planificación del transporte público: predecir la demanda
  - b. Planificación multimodal: integrar caminar, bicicleta, transporte público, tren, movilidad compartida, transporte público autónomo y micromovilidad [en profundidad]
- Operación y mantenimiento
  - **a. Mantenimiento predictivo y predicción de la hora de llegada para** mejorar la fiabilidad
  - b. Rutas, tarificación y recomendaciones para trasladar viajes.



Fuente: Copenhagenize Design Company/Mikael Colville-Andersen, 2018.

[1] Sandalow, David B. et al., “Artificial Intelligence for Climate Change Mitigation Roadmap (Second Edition),” Nov. 2024, doi: 10.7916/2J4P-NW61.

Vehículos autónomos (VA)



¿Promesa climática o riesgo de rebote?

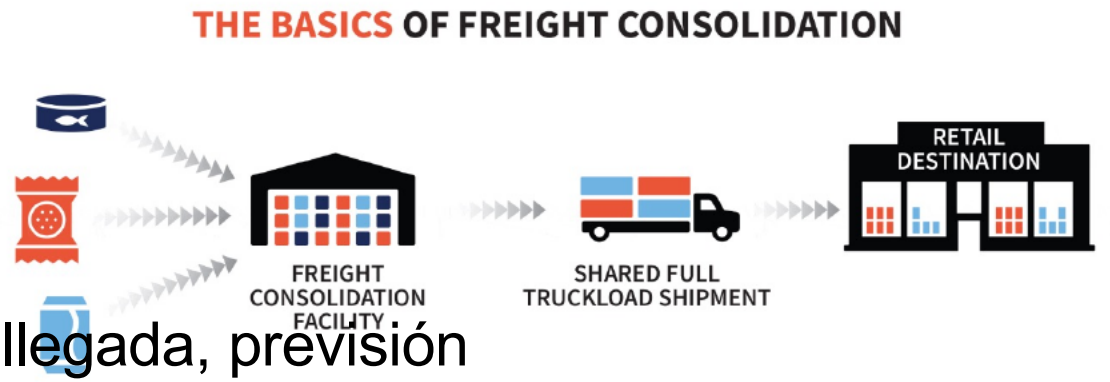
- Ventajas: conducción eficiente, pelotones, aparcamiento inteligente, tráfico más fluido, flotas eléctricas compartidas, transporte de primera/última milla.
- Riesgo: viajar más barato/fácil aumenta los km.
- Riesgo: los VA desplazan a caminar, la bicicleta y el transporte público.
- Mejor escenario climático: eléctricos + compartidos + **complementarios del transporte público + regulados.**
  - Hasta ahora, los usuarios no eligen compartir viajes
- En resumen: los VA no son intrínsecamente buenos para el clima.

[1] Sandalow, David B. et al., “Artificial Intelligence for Climate Change Mitigation Roadmap (Second Edition),” Nov. 2024, doi: 10.7916/2J4P-NW61.

Rutas y consolidación de mercancías

Un caso de uso IA + IO de gran impacto→ reduce km en vacío, vehículos más llenos

- La consolidación agrupa envíos parciales → menos viajes
- Mejores rutas reducen retornos en vacío, desvíos, ralentí y pérdidas por tiempo de espera [en profundidad]
- Casos de uso de IA: predicción de la hora de llegada, previsión de la demanda, predicción de interrupciones, agrupación de proveedores, eco-rutas, rutas dinámicas, aceleración de la optimización y apoyo a subastas de carga



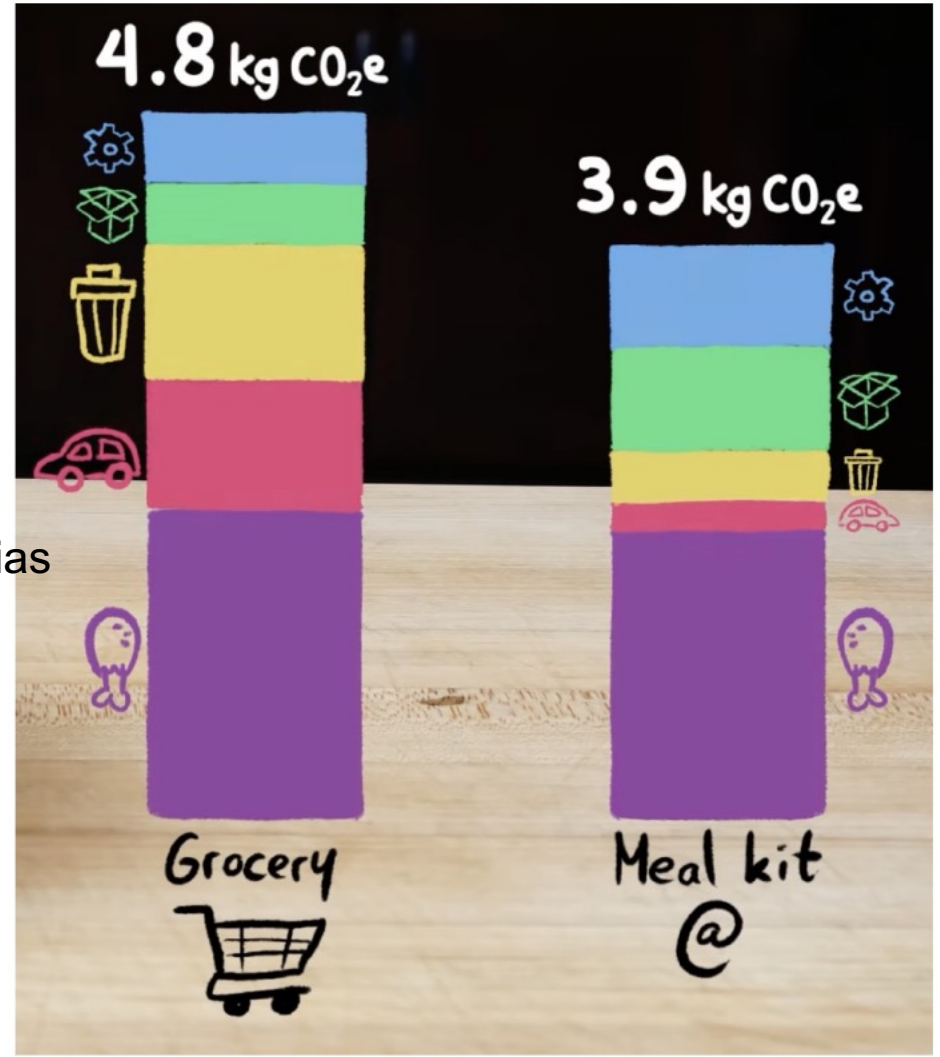
Fuente: Zipline Logistics, 2019.

[1] D. Rolnick et al., “Tackling climate change with machine learning,” Jun. 2019, [Online]. Available: http://arxiv.org/abs/1906.05433v2
[2] World Economic Forum, “Intelligent Transport, Greener Future: AI as a Catalyst to Decarbonize Global Logistics.” Jan. 2025.

Soluciones de inmovilidad

IA para estrategias de «Evitar»: reducir la necesidad de viajar

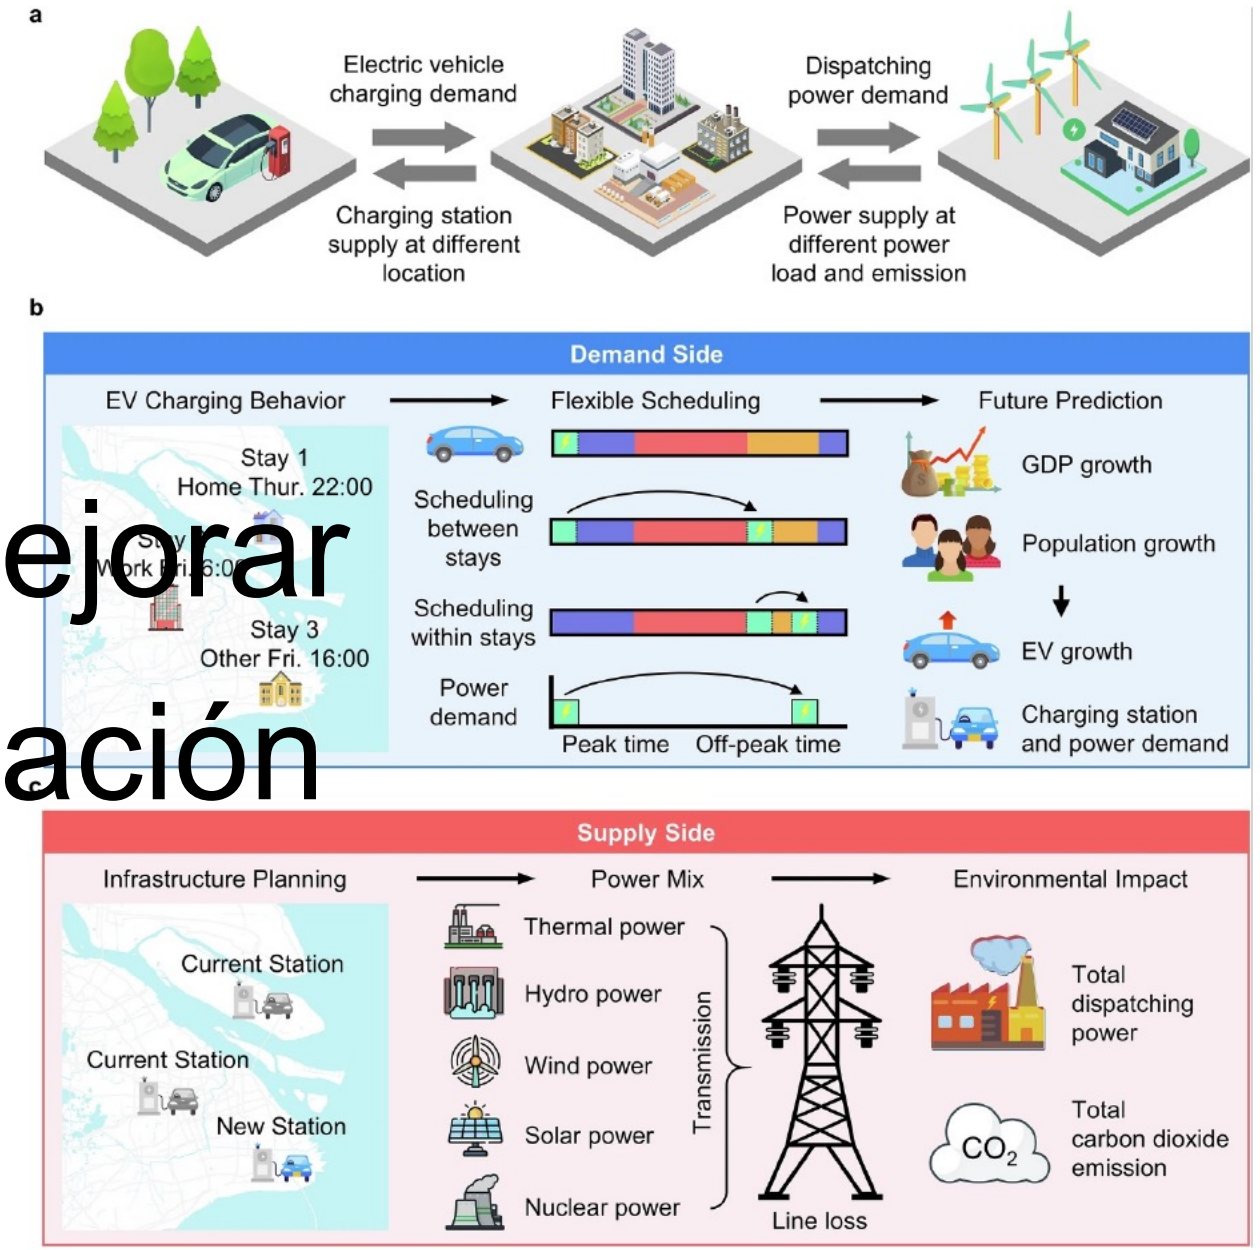
- La telepresencia puede sustituir algunos desplazamientos al trabajo y viajes de negocios
- Los modelos de accesibilidad identifican dónde las necesidades diarias son accesibles sin coche
- Las plataformas de reparto pueden consolidar viajes
- Papel de la IA: predicción de la demanda, mapas de accesibilidad, agrupación, rutas y programación según emisiones
- Advertencia: el tiempo ahorrado y la comodidad pueden traducirse en más viajes, más entregas o trayectos más largos



Los kits de comida pueden reducir emisiones cuando la logística de reparto sustituye viajes individuales de compra. Fuente: MinuteFood, 2023.

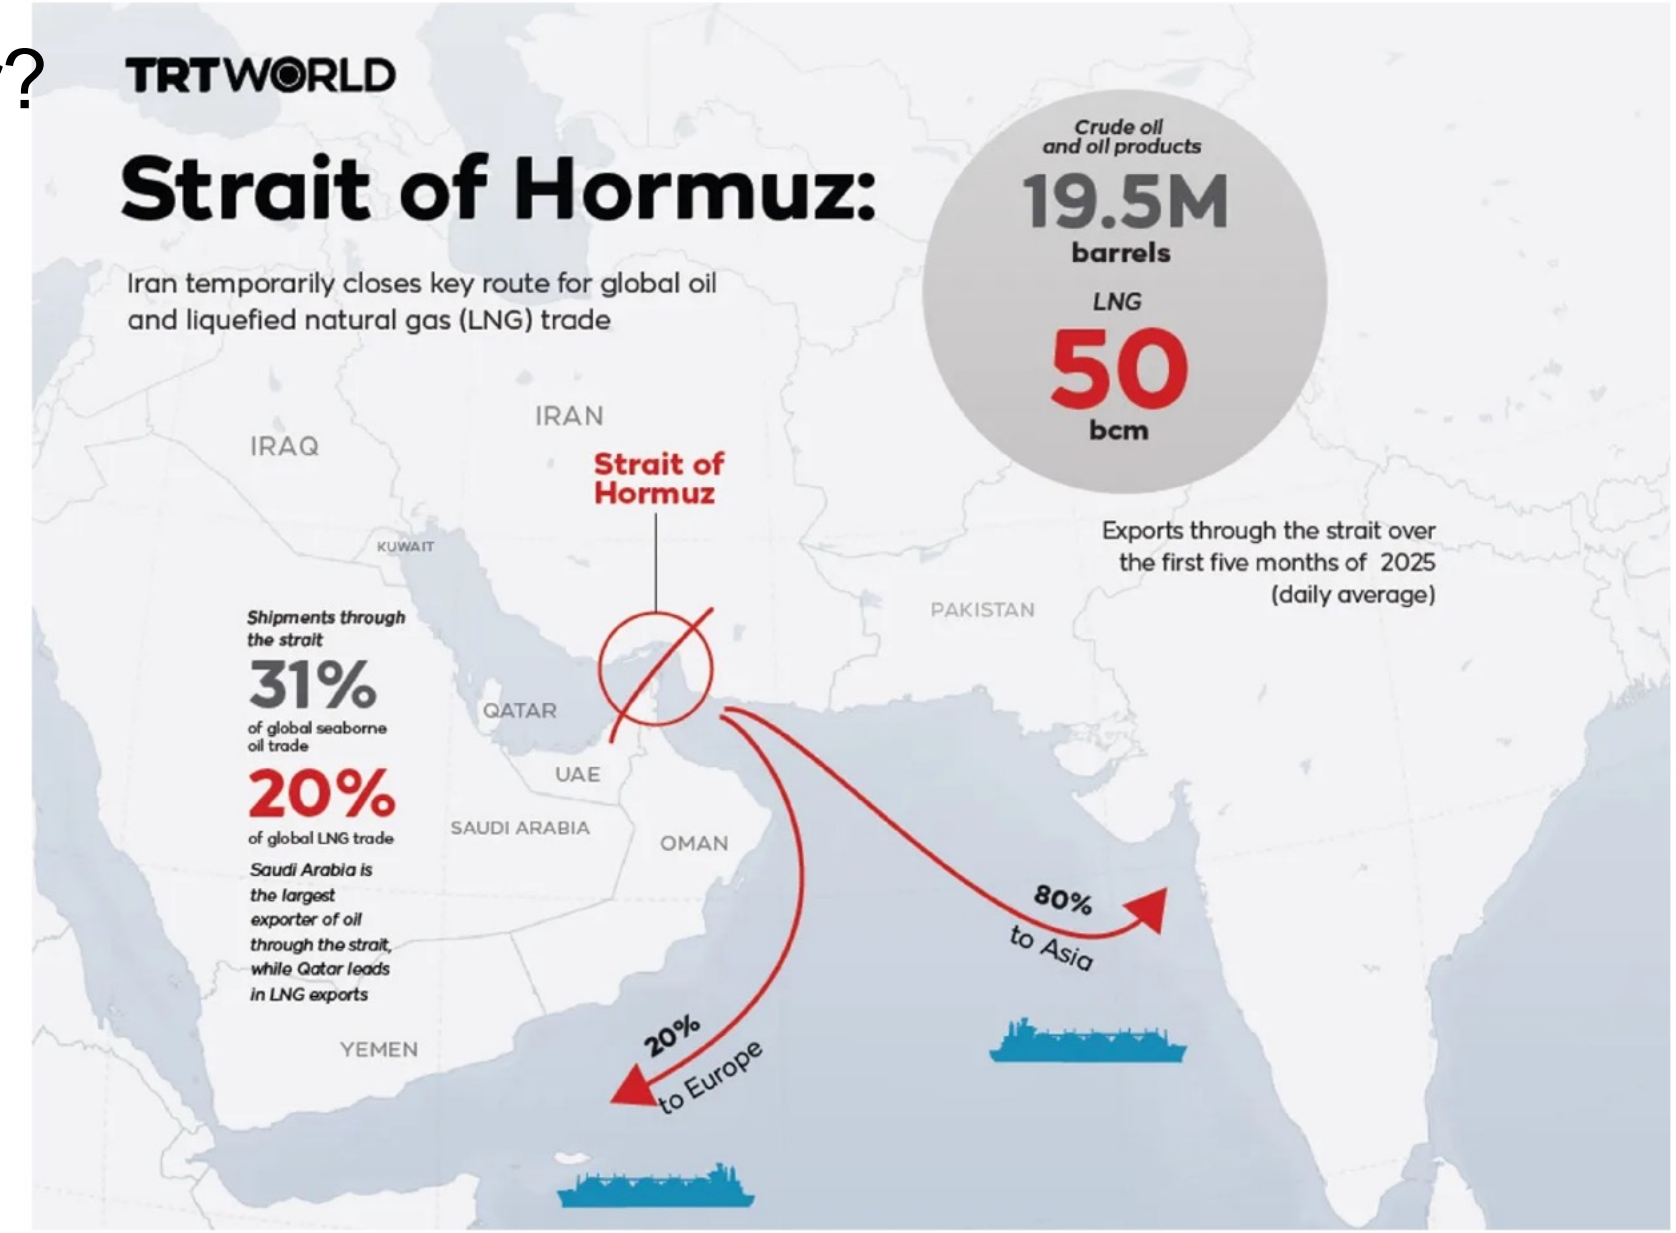
[1] P. Jaramillo and et al., “Transport,” in Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change, 2024. doi: 10.1017/9781009157926.012.
[2] A. Nikolaeva, Y.-T. Lin, S. Nello-Deakin, O. Rubin, and K. C. von Schönfeld, “Living without commuting: experiences of a less mobile life under COVID-19,” Mobilities, vol. 18, no. 1, pp. 1–20, Jan. 2023, doi: 10.1080/17450101.2022.2072231.

En profundidad: Mejorar IA para la electrificación



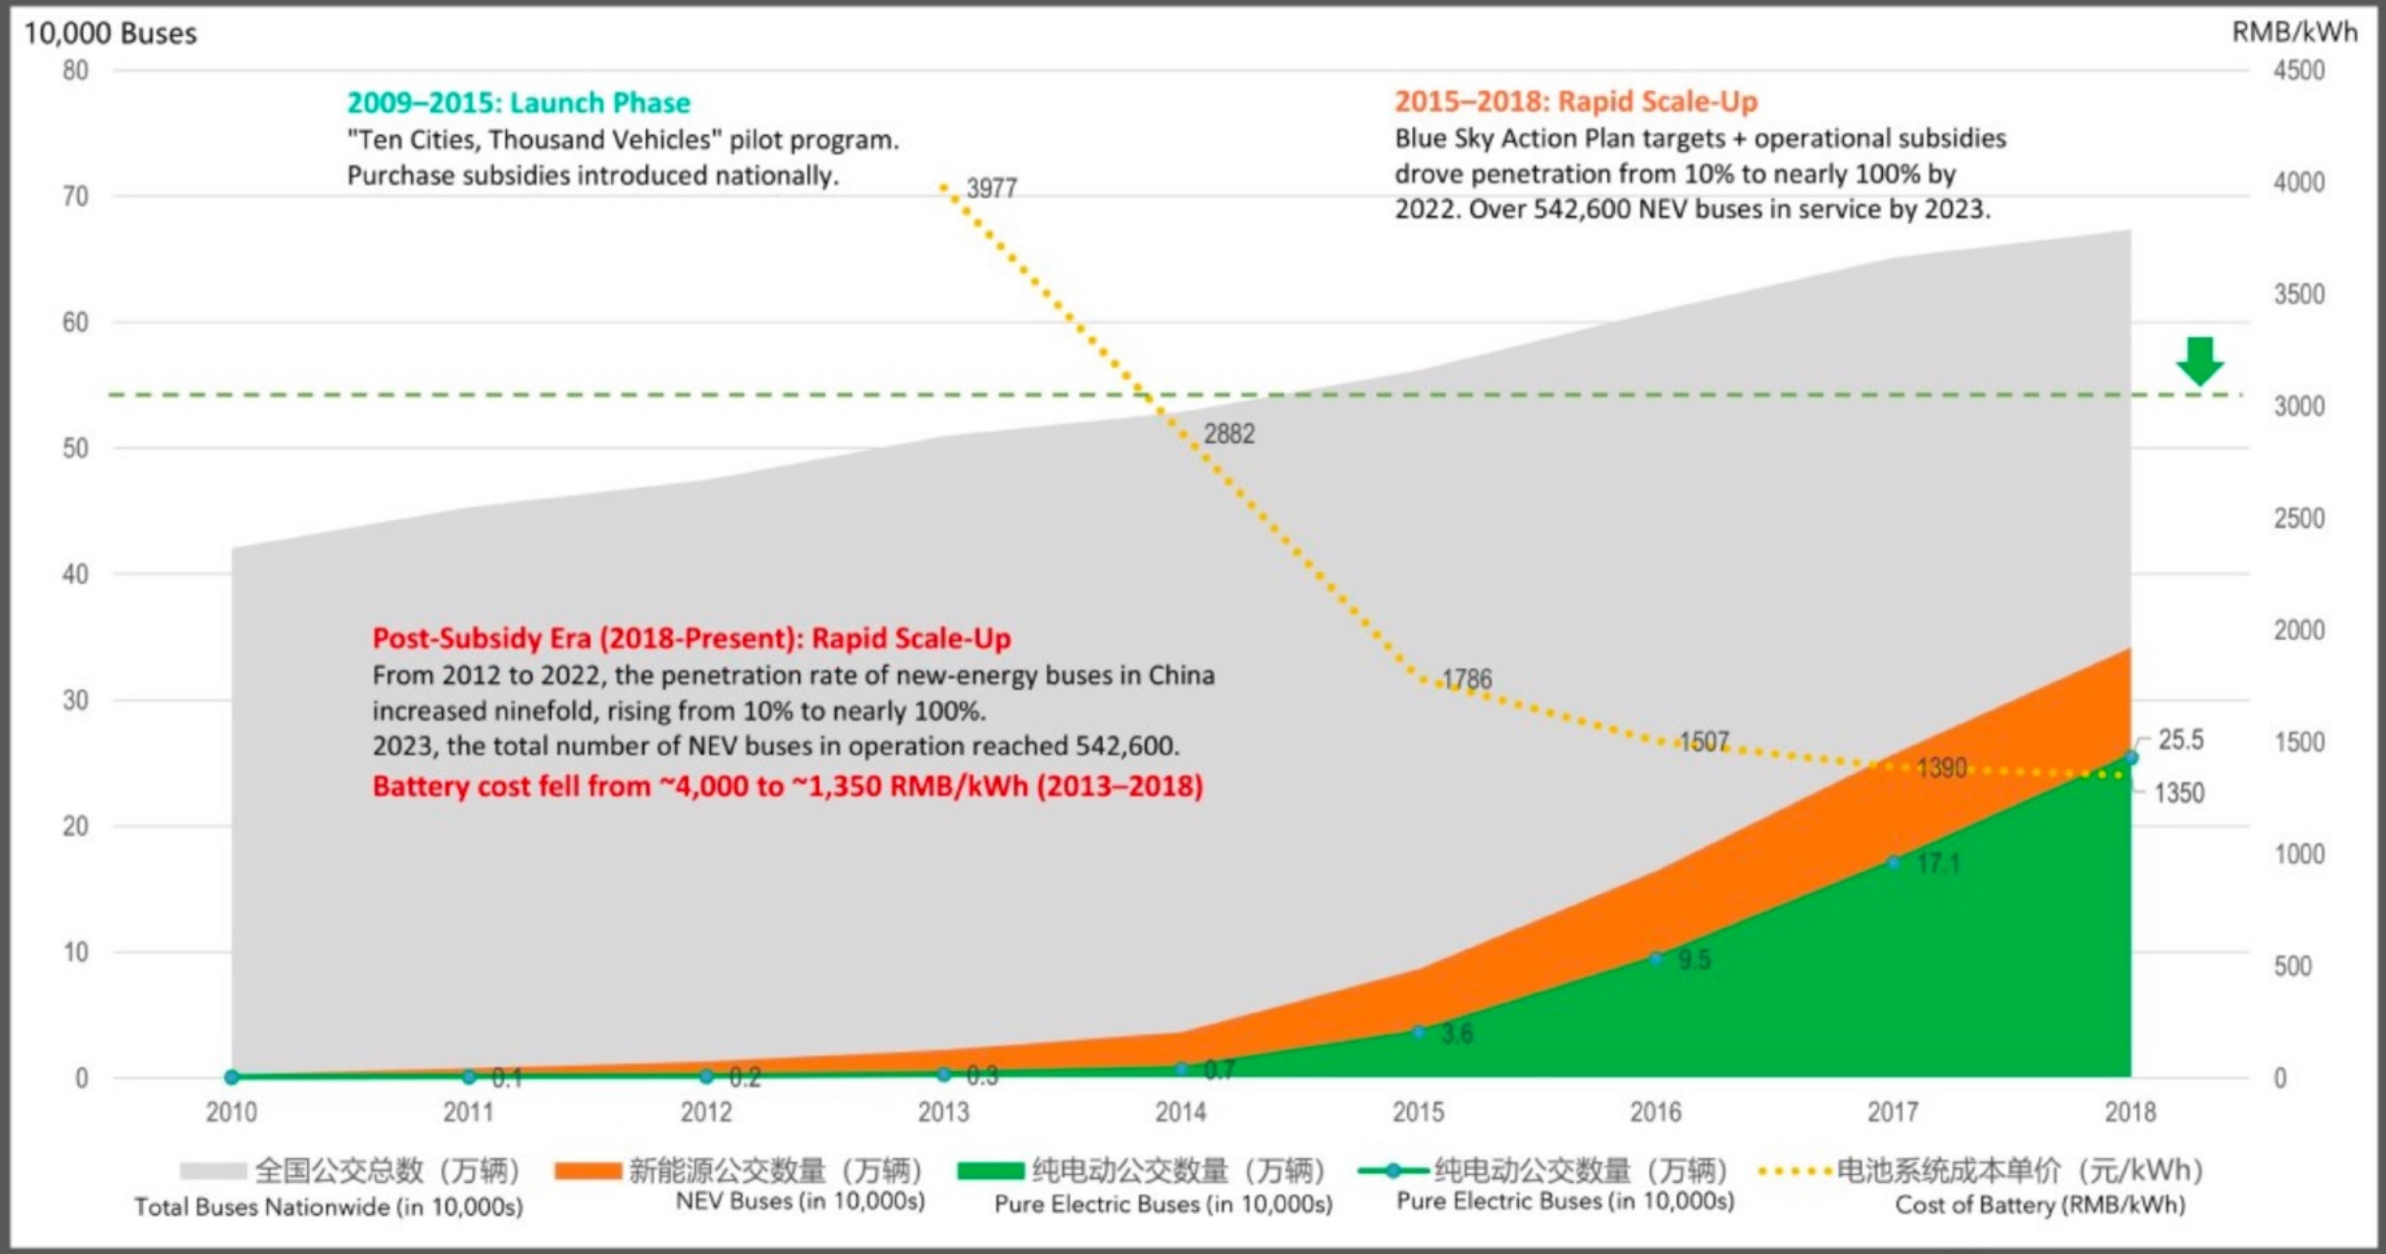
¿Por qué electrificar?

1. Seguridad energética



Fuente: TRT World, March 2, 2026

Electric Buses: Catalyzing China's Booming New Energy Vehicle Industry

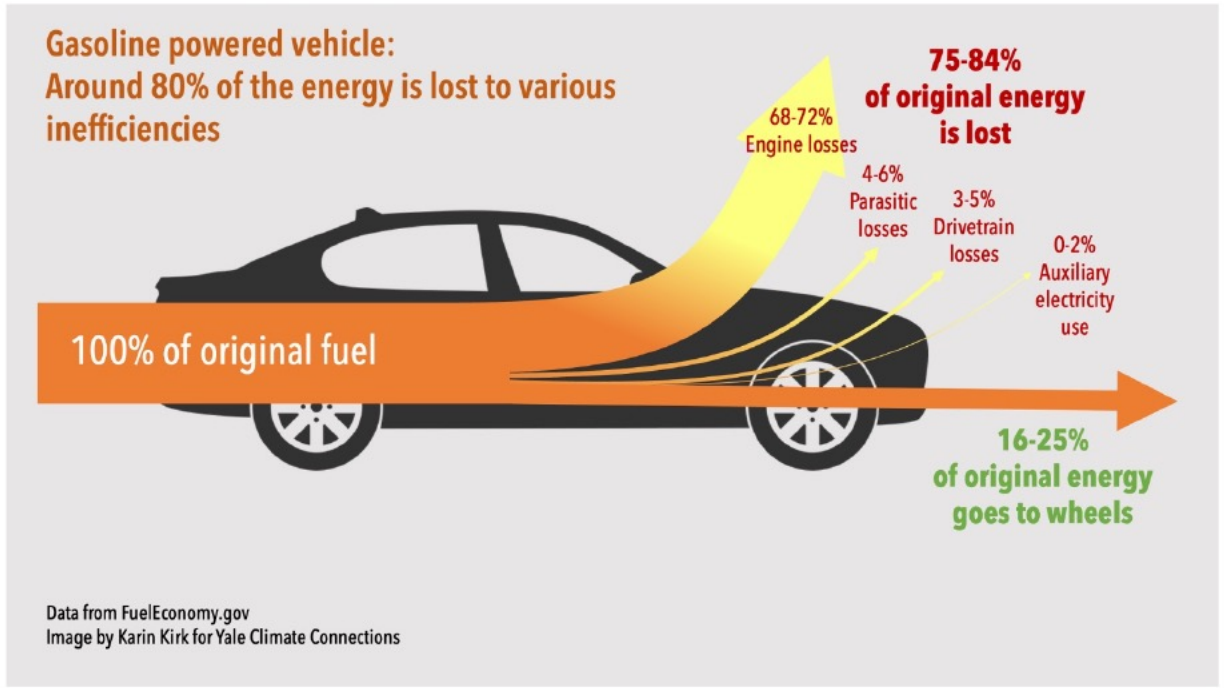


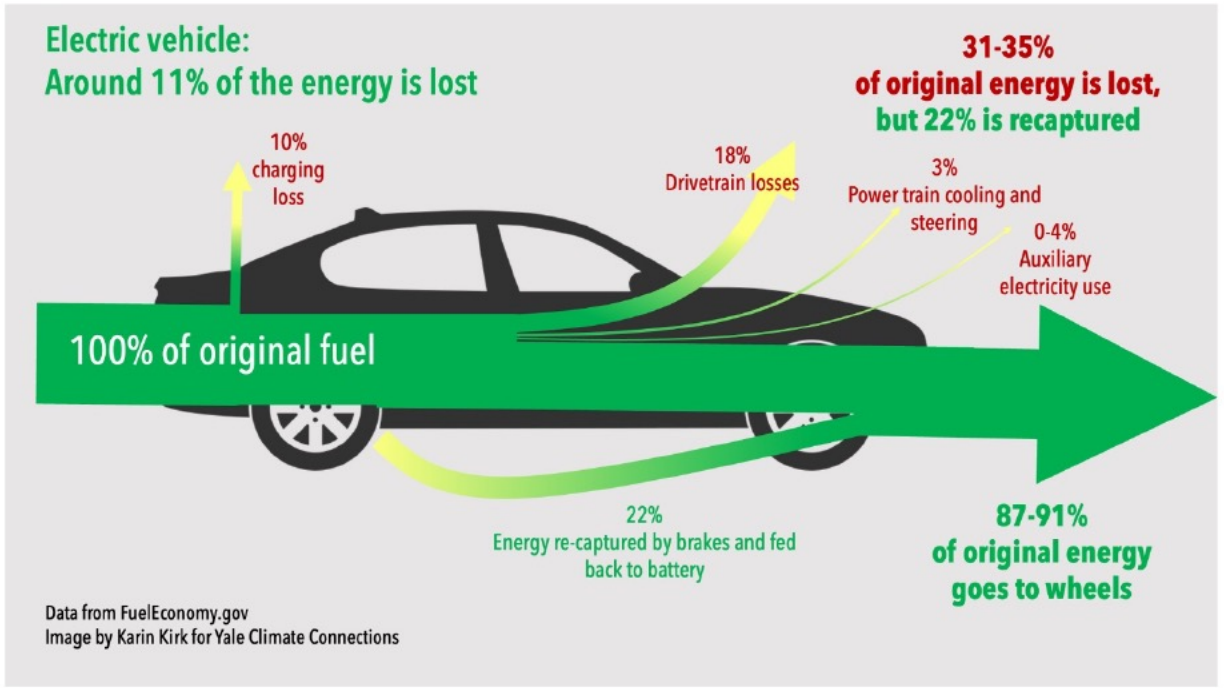
Crédito: Daizong Liu, ITDP

ITDP Institute for Transportation & Development Policy

¿Por qué electrificar?

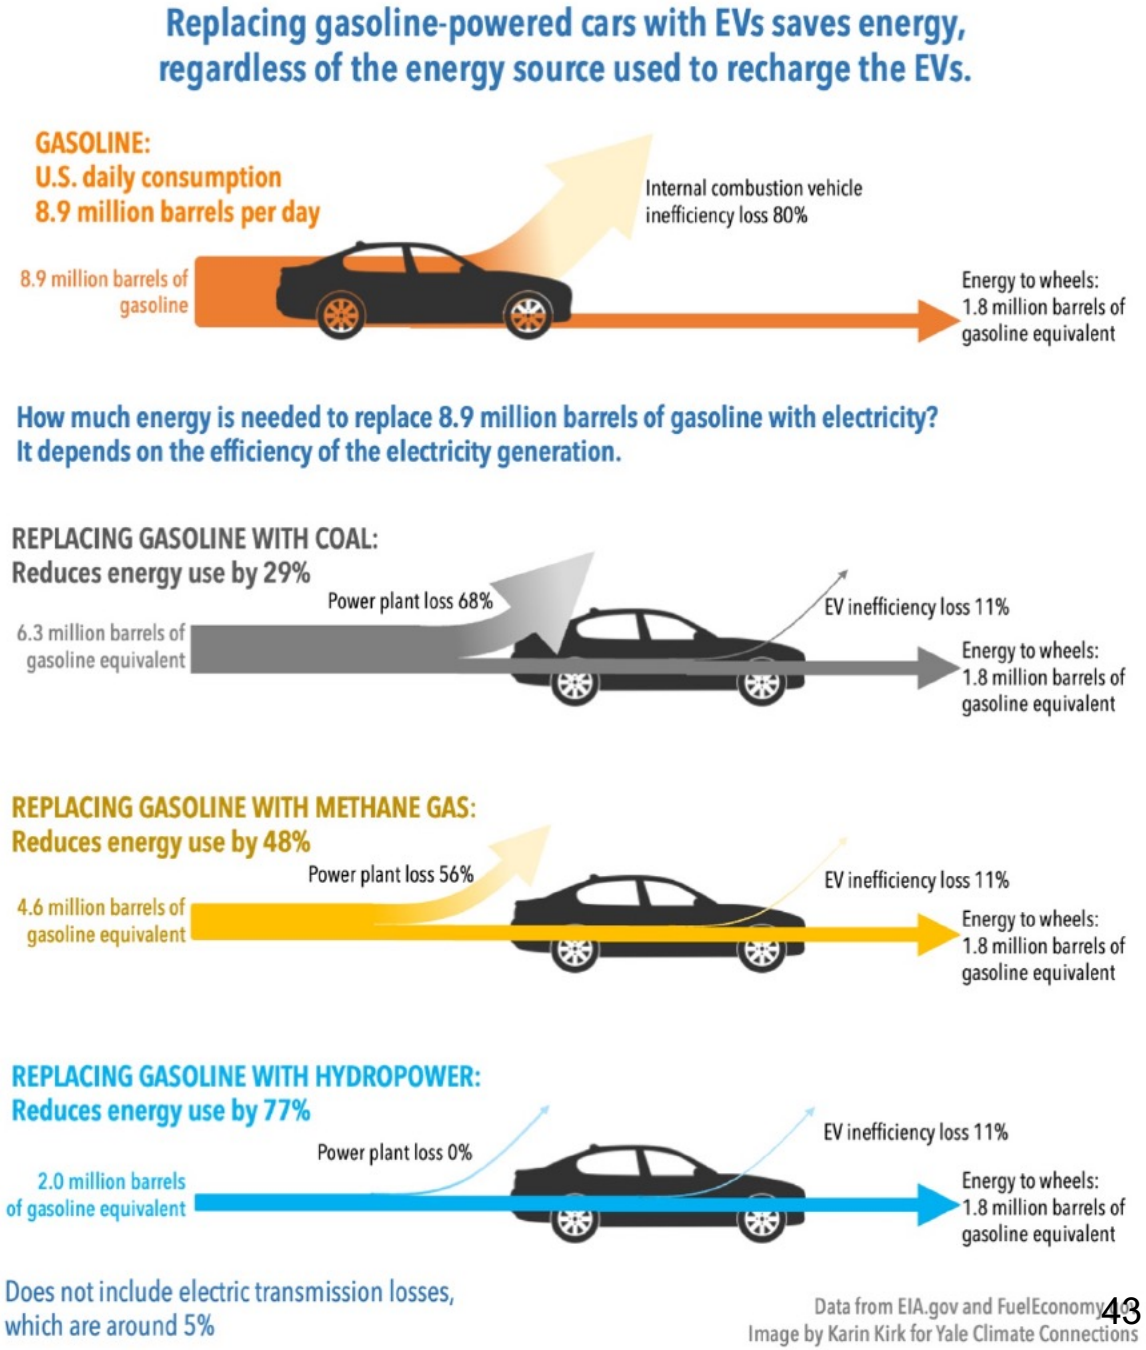
2. Reducir el consumo de energía





¿Por qué electrificar?

3. Aprovechar las renovables



Limitaciones de la electrificación

- Hasta un 92 % menos de emisiones en el ciclo de vida frente a vehículos de combustión [1]
  - Si se fabrican y alimentan con electricidad limpia y se reciclan
- Emisiones operativas
  - La red aún no está descarbonizada
  - El aumento previsto de la demanda de viajes puede anular la reducción
  - Congestión persistente, gran consumo de suelo para carreteras y aparcamiento
- Emisiones incorporadas e impactos
  - El parque mundial se renueva en ciclos de 15-20 años
  - El carbono incorporado de los VE y la infraestructura de carga traslada el problema a otro sector: la industria
  - Hace falta mucha innovación y esfuerzo para una fabricación limpia
  - Gran demanda de minerales críticos (con sus propios problemas de sostenibilidad)

[1] "Lifecycle Emissions Study: EVs vs. Conventional Vehicles." Great Plains Institute, 1 July 2025, betterenergy.org/electric-vehicle-lifecycle-analysis.

Scenario projections

Current Policies Scenario | Stated Policies Scenario

EV market | EV charging | EV energy impact

Cars | 2 and 3 wheelers | Vans | Buses | Trucks

EV sales projections

EV sales, cars

2025
21
million sales

2035
49
million sales

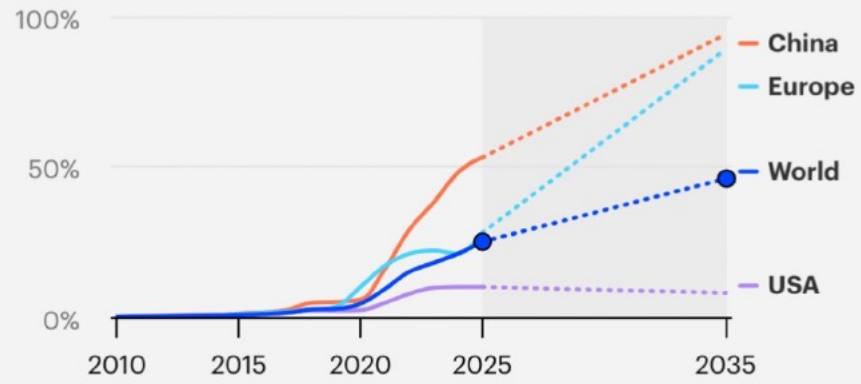
EV fleet projections

EV stock, cars

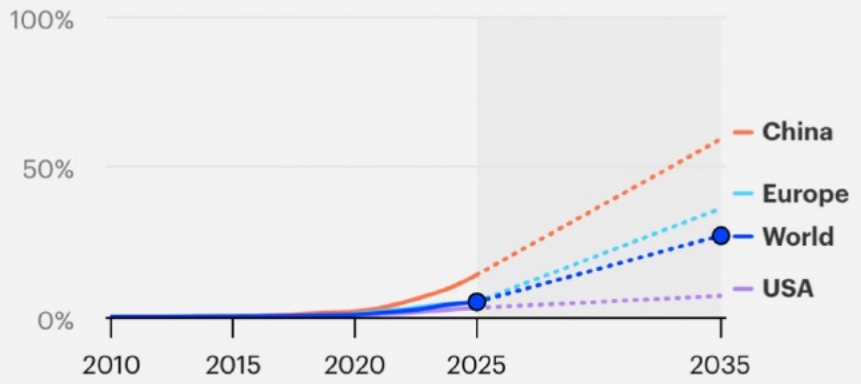
2025
75
million vehicles

2035
450
million vehicles

EV sales share, cars

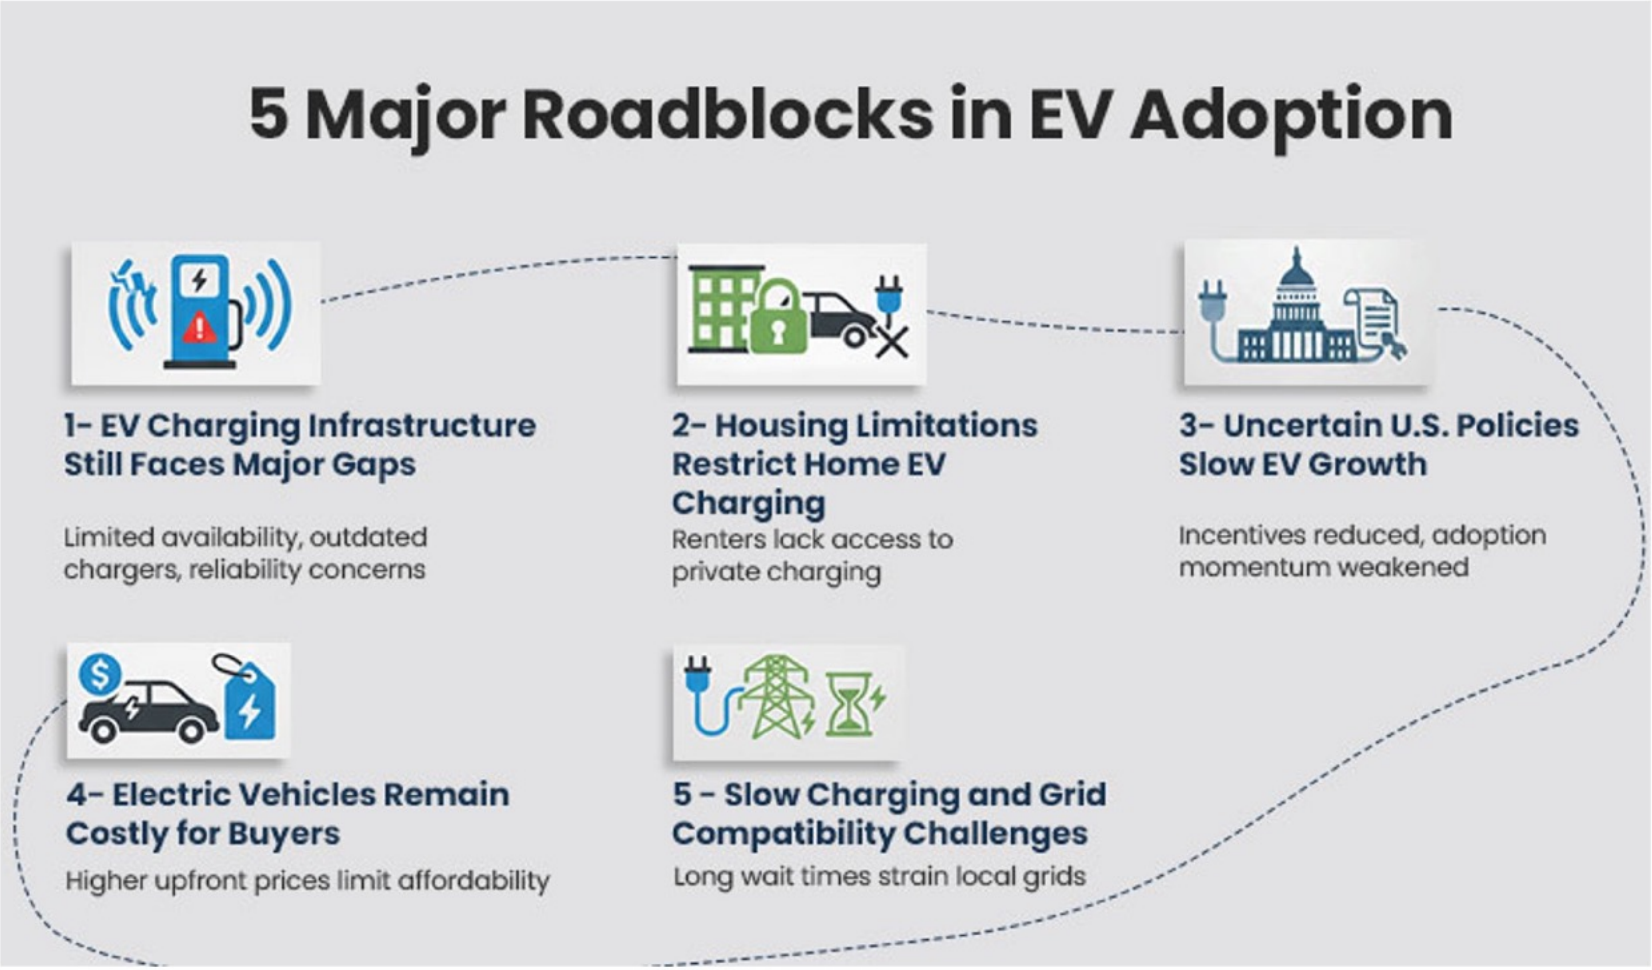


EV stock share, cars



"Global EV Data Explorer – Data Tools - IEA." IEA, May 2026, www.iea.org/data-and-statistics/data-tools/global-ev-data-explorer.

Retos de la electrificación de vehículos en EE. UU.

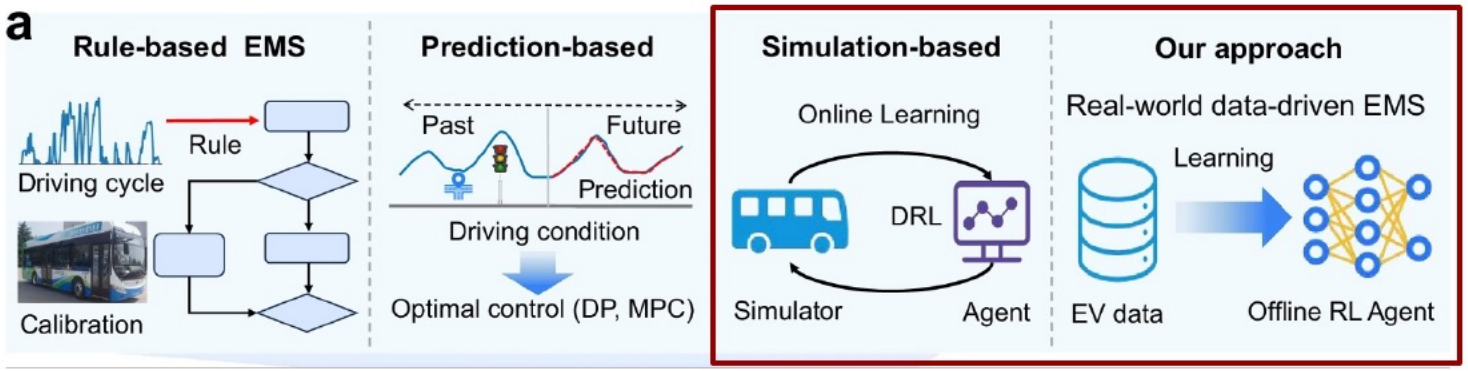


Fuente: SolarSME, 2026

[1] M. Liu et al., “Tariffs on electric vehicles deepen woes of U.S. electrification stagnation,” npj Clim. Action, 2026, doi: 10.1038/s44168-025-00330-6.

Eficiencia y vida útil de las baterías

- Aumentar la autonomía y la vida útil de la batería asignando energía con aprendizaje por refuerzo (RL)
- Este enfoque podría aprovechar la plataforma china de seguimiento de VE, que recoge en tiempo real datos operativos de más de 20 millones de VE



Por qué el problema es adecuado para RL profundo

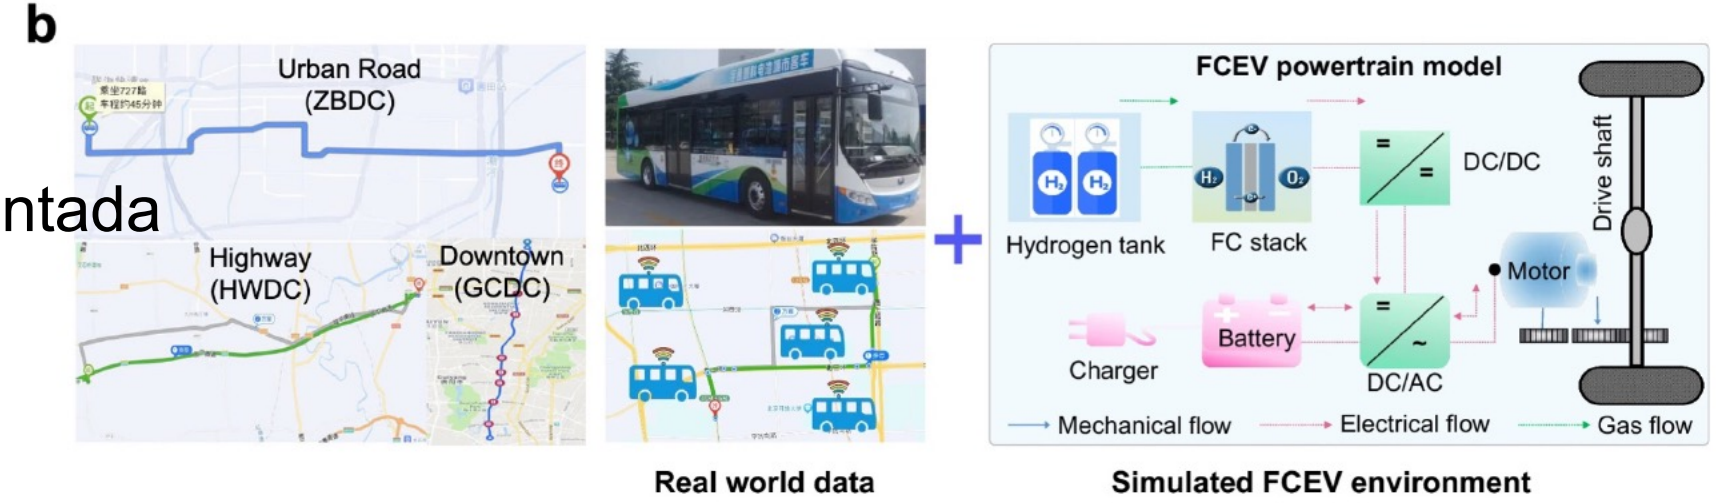
- Condiciones de tráfico dinámicas → decisiones secuenciales
- Trenes motrices híbridos complejos (batería, pila, combustión) → aprender de los datos
- Aplicación en tiempo real → inferencia rápida de modelos de AA

[1] X. Hu et al. Reinforcement Learning for Hybrid and Plug-In Hybrid Electric Vehicle Energy Management: Recent Advances and Prospects. IEEE Industrial Electronics Magazine 13, 16-25 (2019). https://doi.org/10.1109/MIE.2019.2913015 .

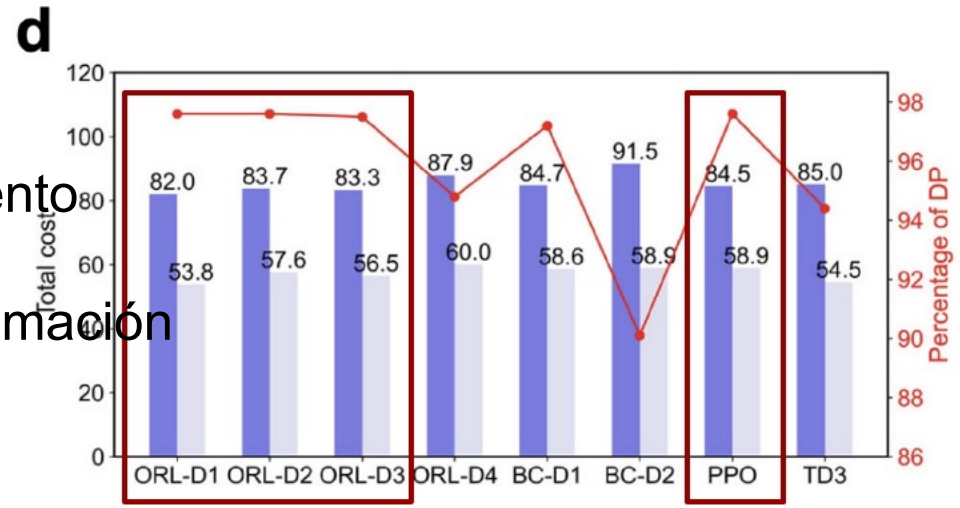
[2] Y. Wang, J. Wu, H. He, Z. Wei, and F. Sun, “Data-driven energy management for electric vehicles using offline reinforcement learning,” Nat Commun, vol. 16, no. 1, p. 2835, Mar. 2025, doi: 10.1038/s41467-025-58192-9.

Eficiencia y vida útil de las baterías

Simulación aumentada con datos



El RL logra un rendimiento casi óptimo (calculado mediante programación dinámica)

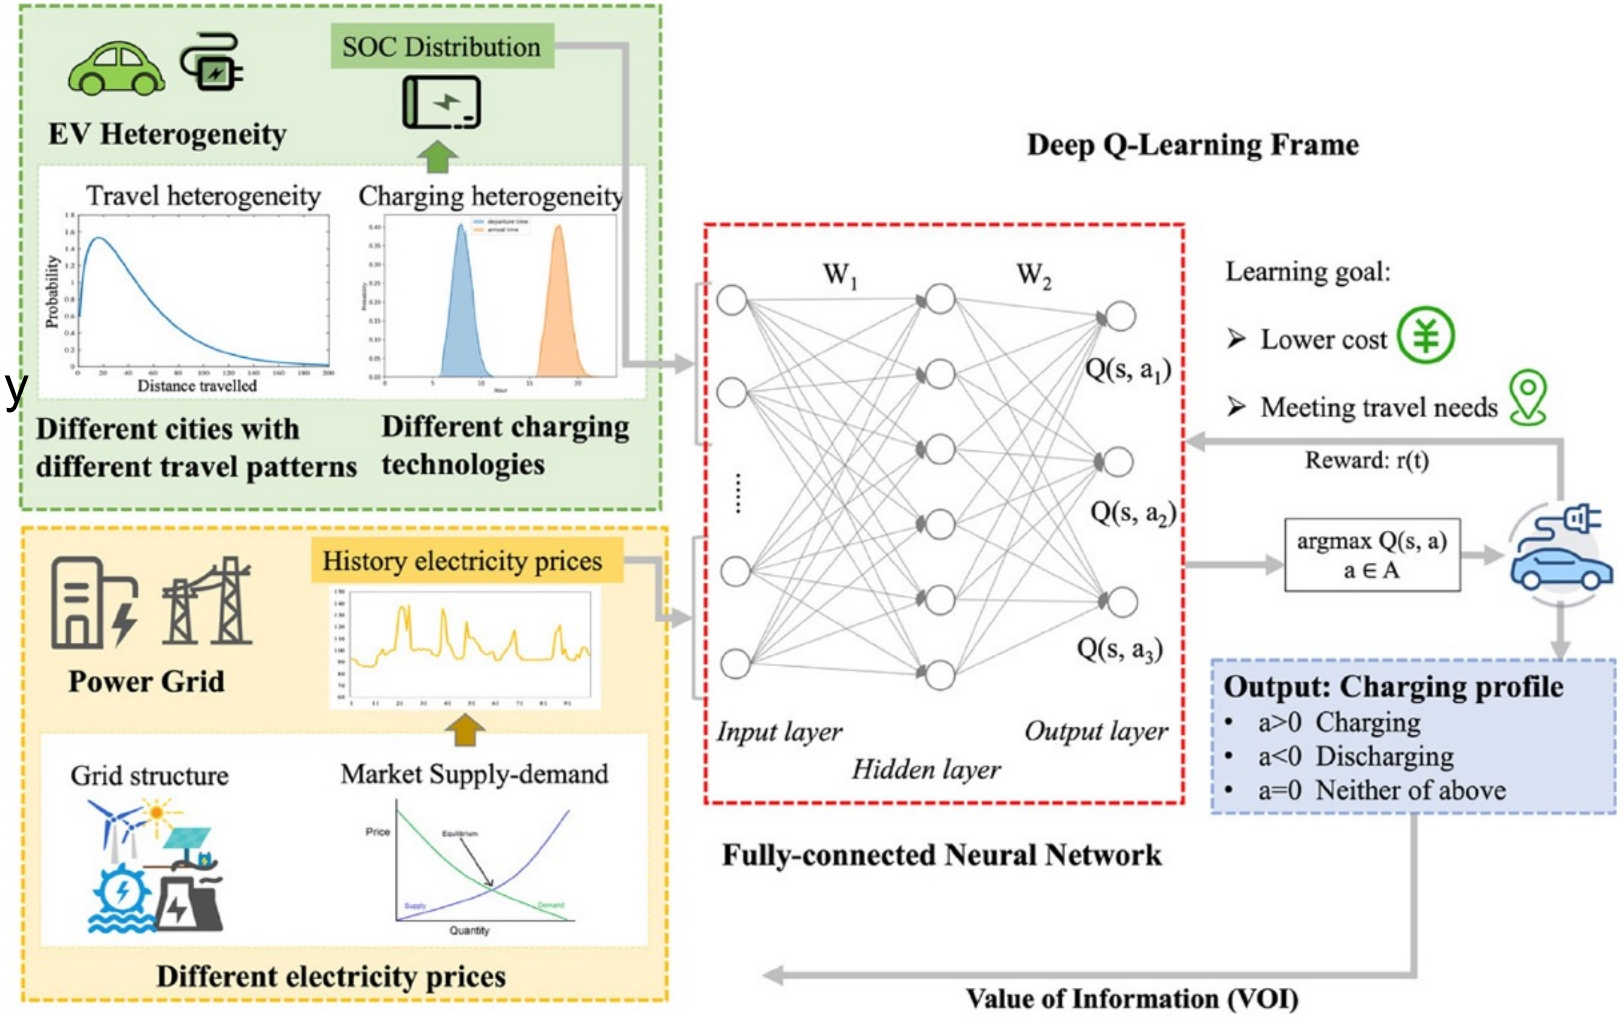


Resultado: el RL reduce el coste total un 13 % frente al controlador de serie
Advertencia: el método de serie no tiene en cuenta la vida útil de la batería, el RL sí (penaliza la pendiente de potencia)

[1] Y. Wang, J. Wu, H. He, Z. Wei, and F. Sun, “Data-driven energy management for electric vehicles using offline reinforcement learning,” Nat Commun, 2025.

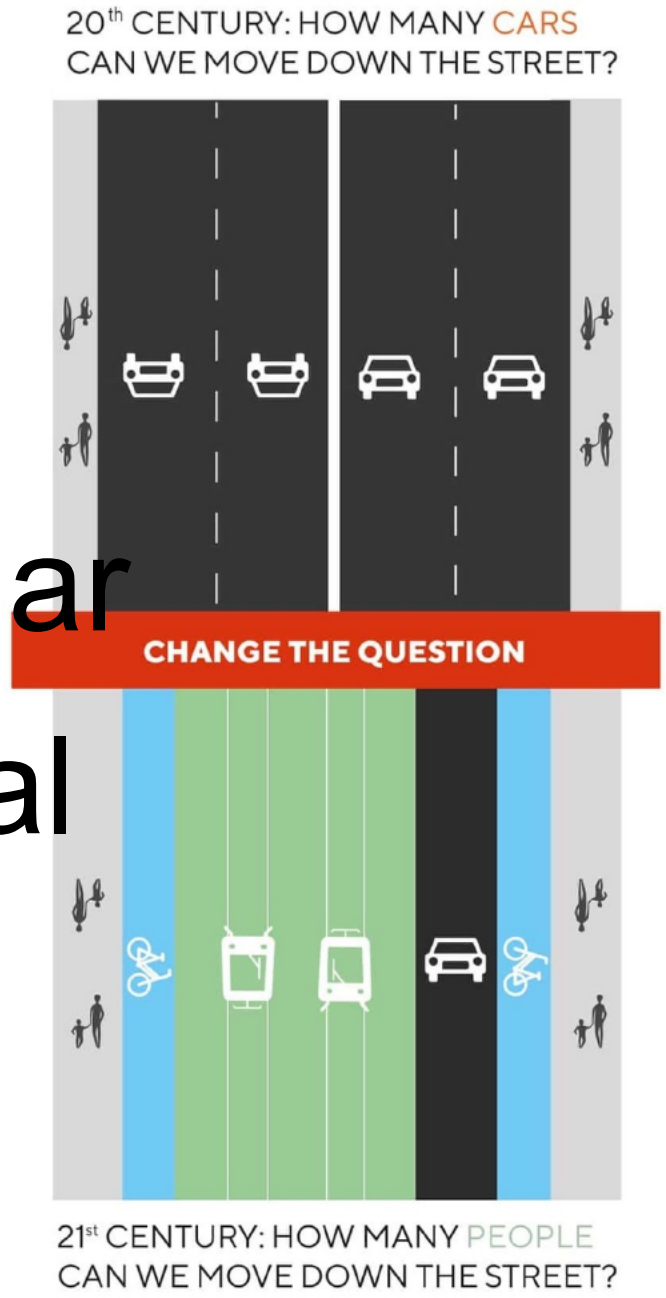
Carga inteligente / bidireccional (V2G)

- Los VE pueden actuar como almacenamiento distribuido para desplazar la carga urbana
- Q-learning profundo (DQN) para aprender políticas de carga/descarga según precios y restricciones de movilidad
- 1 millón de km de datos de conducción de VE chinos
- La política DQN ahorró un 98 % en electricidad frente a cargar lo antes posible (referencia débil)



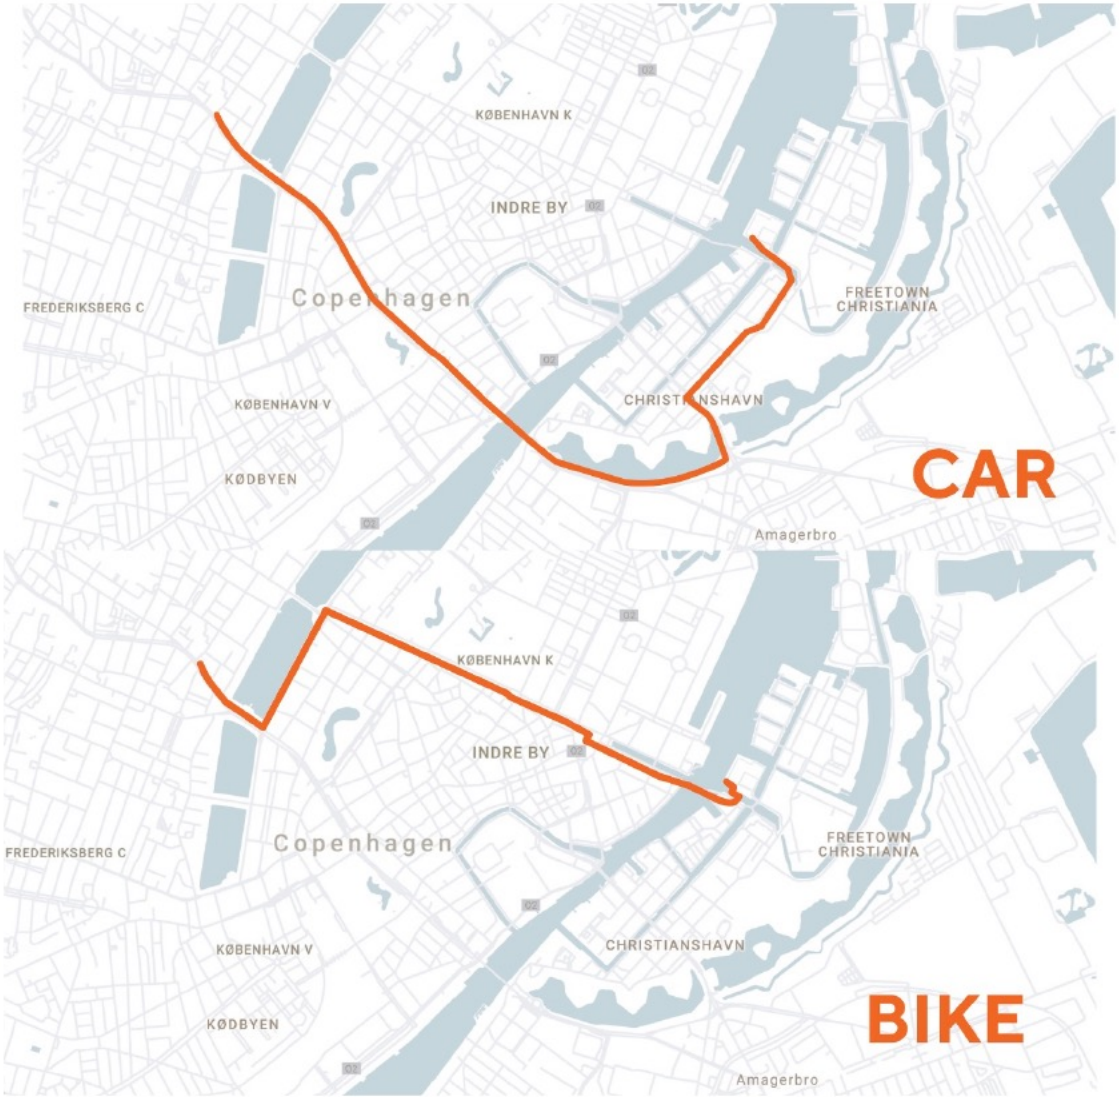
Hao, Xu, et al. "A V2G-oriented reinforcement learning framework and empirical study for heterogeneous electric vehicle charging management." Sustainable Cities and Society, vol. 89, 1 Feb. 2023, p. 104345, doi:10.1016/j.scs.2022.104345.

En profundidad: Cambiar IA para el cambio modal



Fuente: Copenhagenize Design Company/Mikael Colville-Andersen, 2018.

¿Por qué la bicicleta? (Copenhague, Dinamarca)





Fuente: Copenhagenize Design Company/Mikael Colville-Andersen, 2018.

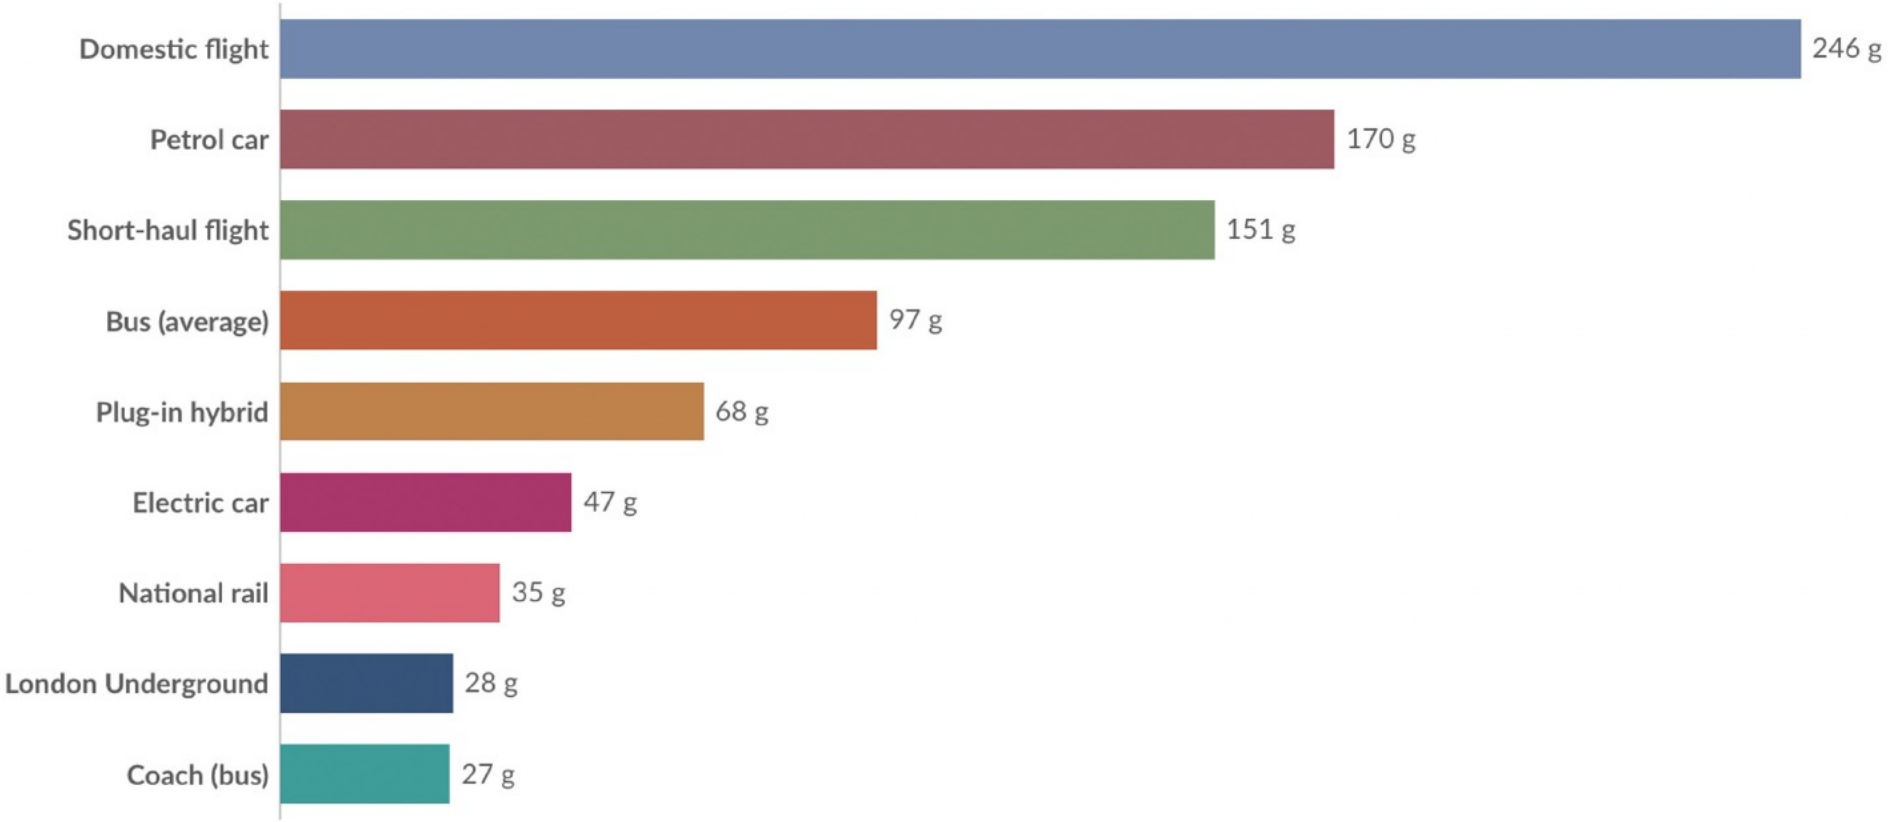
Carbon footprint of travel per kilometer, 2022

The carbon footprint of travel is measured in grams of carbon dioxide-equivalents per passenger kilometer. This includes the impact of increased warming from aviation emissions at altitude.

Our World in Data

Table | Bar

Edit countries and regions



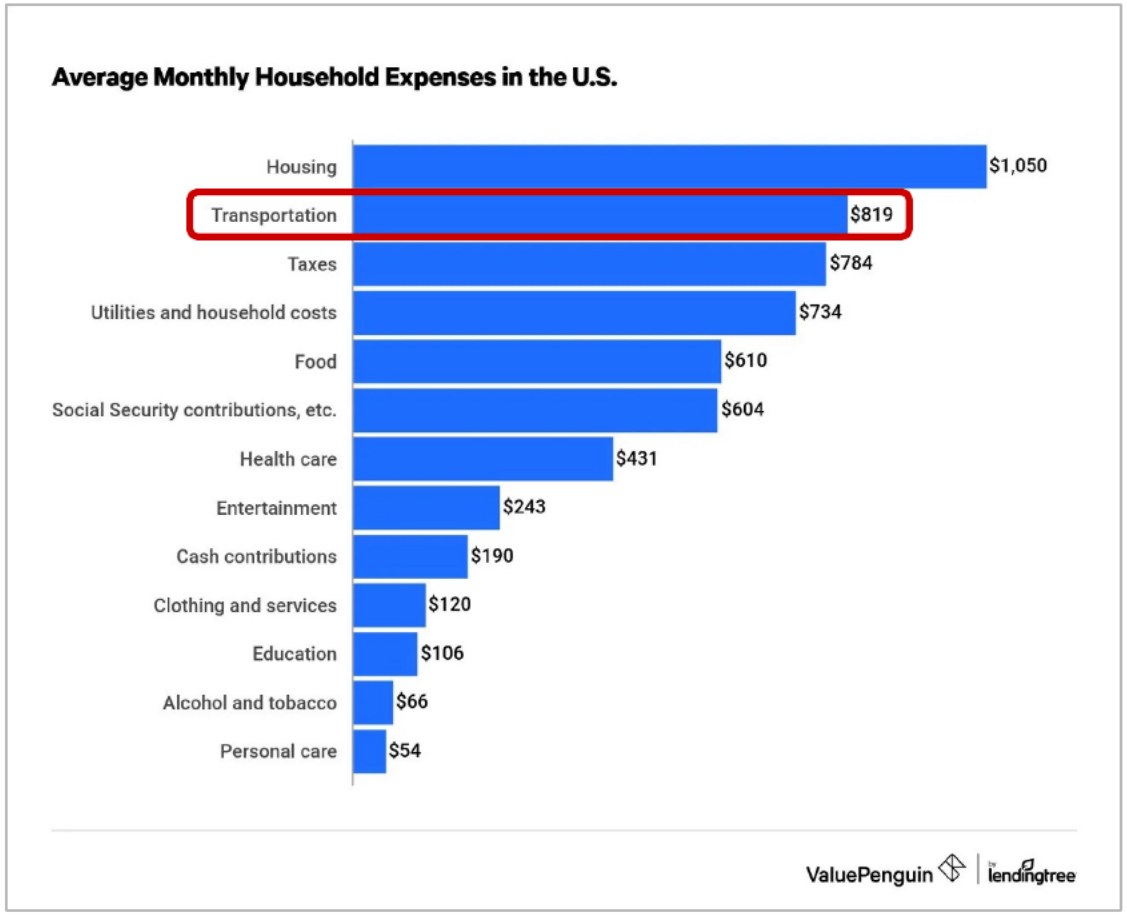
Data source: UK Government, Department for Energy Security and Net Zero (2022) – Learn more about this data

Note: Official conversion factors used in UK reporting. These factors will vary across countries depending on energy mix, transport technologies, and occupancy of public transport. Data for aviation is based on economy class.

OurWorldinData.org/transport | CC BY

Asequibilidad y acceso

En 2024, el 45,5 % de los hogares de EE. UU. no ganaba lo suficiente para llegar a fin de mes.



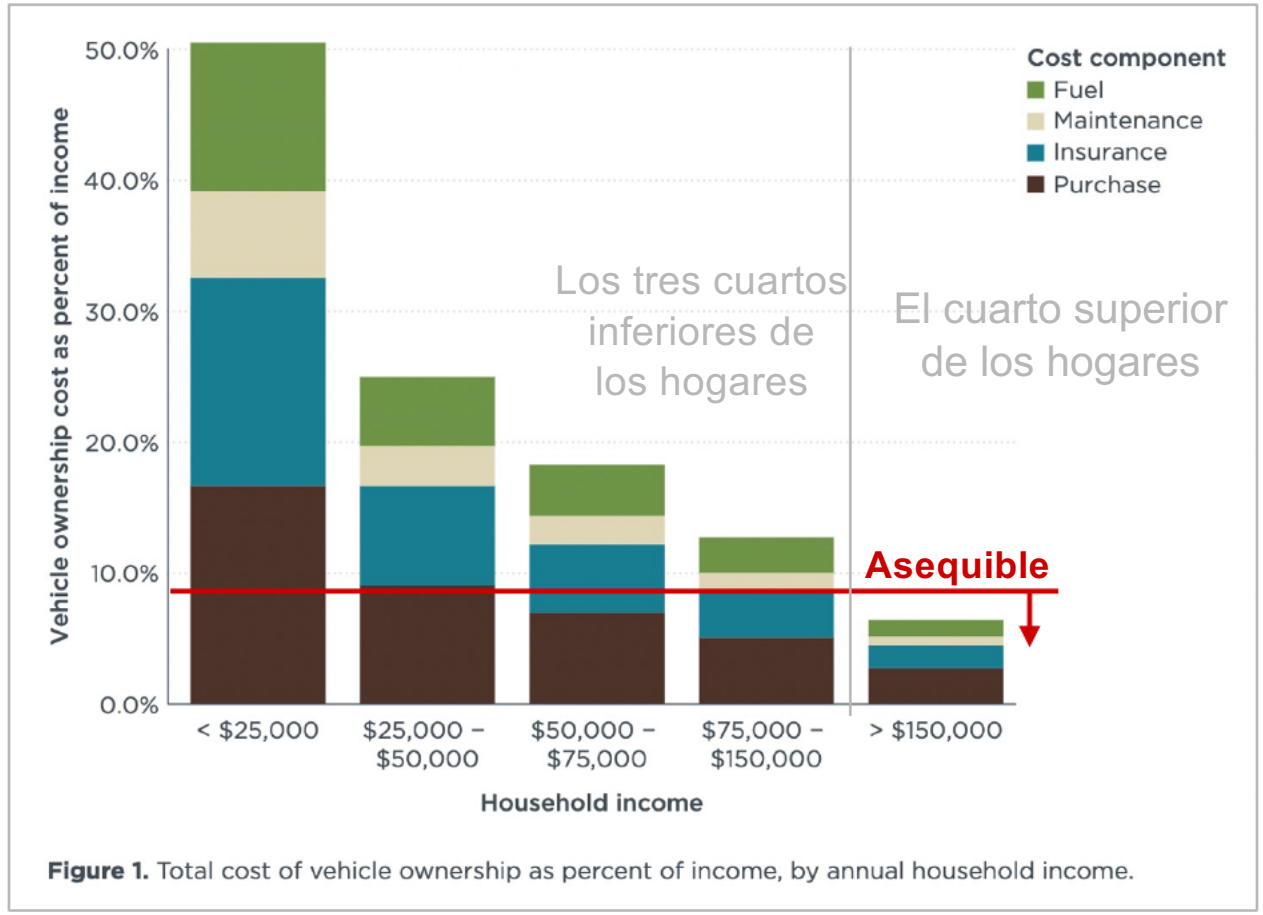


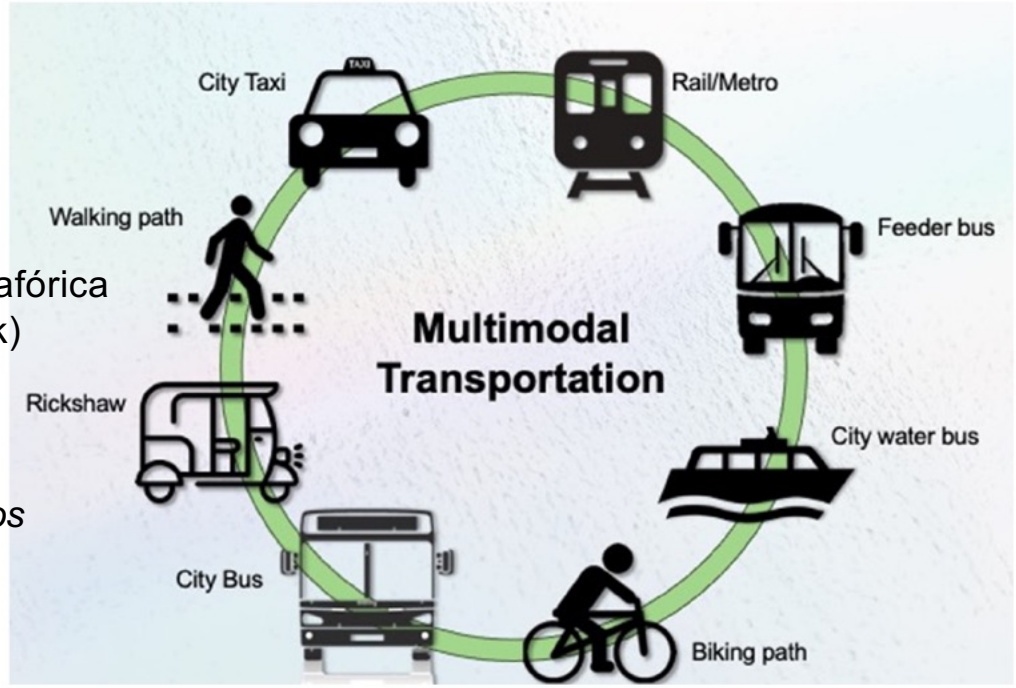
Figure 1. Total cost of vehicle ownership as percent of income, by annual household income.

[1] "States of Affordability: A series on where and why US households struggle to make ends meet | Brookings." Brookings, 24 June 2026, www.brookings.edu/articles/states-of-affordability-a-series-on-where-and-why-us-households-struggle-to-make-ends-meet .

[2] Bauer, Gordon, Chih-Wei Hsu, and Nic Lutsey. "When might lower-income drivers benefit from electric vehicles? Quantifying the economic equity implications of electric vehicle adoption." International Council on Clean Transportation. Working Paper 6 (2021).

Movilidad urbana multimodal

- Definición: un enfoque del transporte que apoya todos los modos que usa la gente (vehículos privados, a pie, bicicleta, transporte público, movilidad compartida, combinaciones de modos, etc.).
- Estrategias
  - Transporte público
  - Diseño de calles: carriles bici, reducción de carriles, prioridad semafórica
  - Tarificación vial (Bloomberg sobre la tarificación vial de Nueva York)
  - Planificación de viajes y orientación en tiempo real
  - Movilidad como servicio (MaaS), incl. pago integrado
- Por qué es difícil
  - *Integración física: los transbordos deben ser rápidos, seguros y cómodos*
  - *Coordinación institucional: muchos organismos públicos y operadores privados*
  - *Interoperabilidad de datos: horarios, tarifas, rutas y actualizaciones en tiempo real deben conectarse*
  - *Modelo de negocio: ¿quién paga, quién se beneficia, quién comparte los datos?*
  - *Equidad y privacidad: un servicio fluido no debe excluir a usuarios de bajos ingresos o con pocos datos*



Fuente: Audirac, Ivonne, et al. "Transportation and Mobility Modes." 2024.

[1] StreetLight, "Multimodal Transportation: What Is It, and How Does It Benefit Everyone?", 2024, www.streetlightdata.com/what-is-multimodal-transportation.

IA para la simulación del transporte basada en agentes

Previsión de la demanda de viajes

La previsión de la demanda de viajes es clave para evaluar y planificar los sistemas de transporte

- ¿Por qué, cuándo y cómo viaja la gente?

Por qué

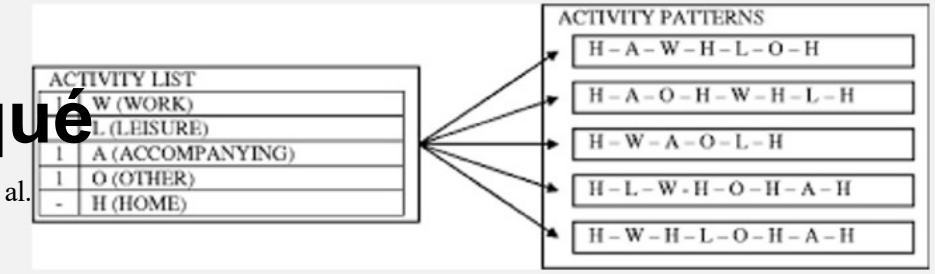


Imagen: Bifulco et al.

Cuándo

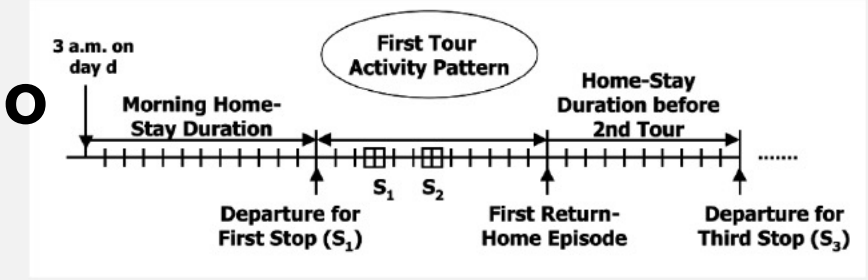


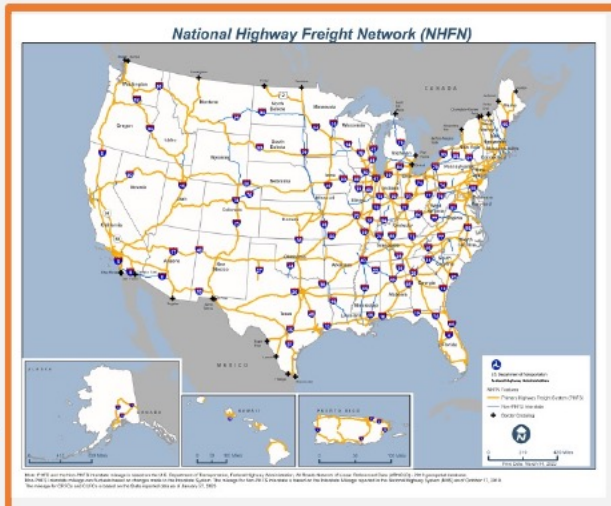
Imagen: Pinjari y Bhat

Cómo

$$U_c = \alpha T_c + \beta M_c + \varepsilon_c$$
$$U_b = \alpha T_b + \beta M_b + \theta_b Y + k_b + \varepsilon_b$$

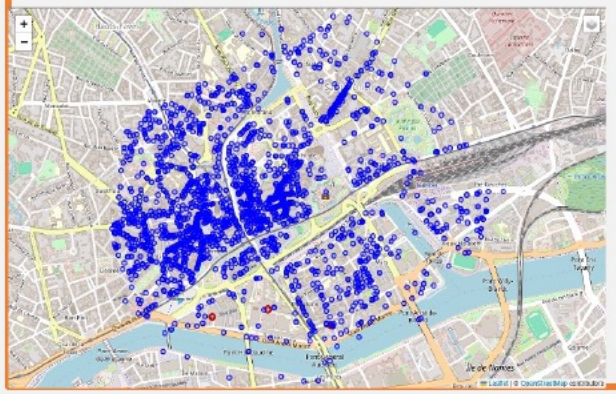
Imagen: Train

apoya



Modelización del sistema

Imagen: FHWA



Dinámica Simulación

Imagen: Matsim

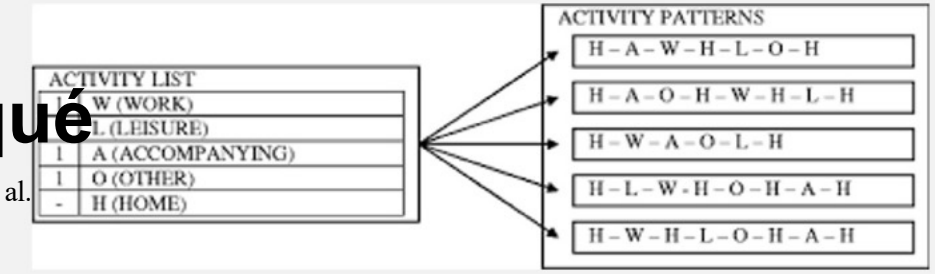
Diapositivas adaptadas de Tianming Liu (tianmliu@umich.edu)

Impacto de la previsión de la demanda de viajes

La previsión de la demanda impulsa decisiones clave de planificación e inversión de los organismos públicos, del nivel federal al local.

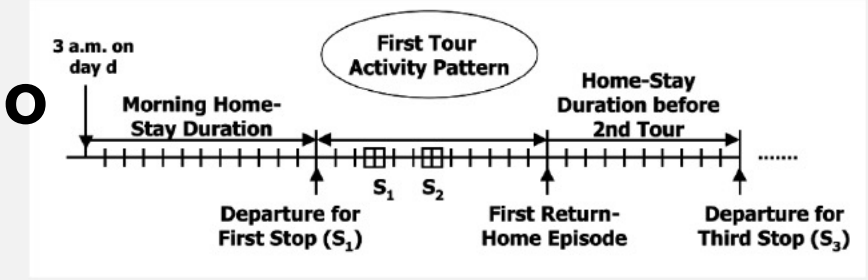
Por qué

Imagen: Bifulco et al.



Cuándo

Imagen: Pinjari y Bhat



Cómo

Imagen: Train

$$U_c = \alpha T_c + \beta M_c + \varepsilon_c$$
$$U_b = \alpha T_b + \beta M_b + \theta_b Y + k_b + \varepsilon_b$$

Impulsa

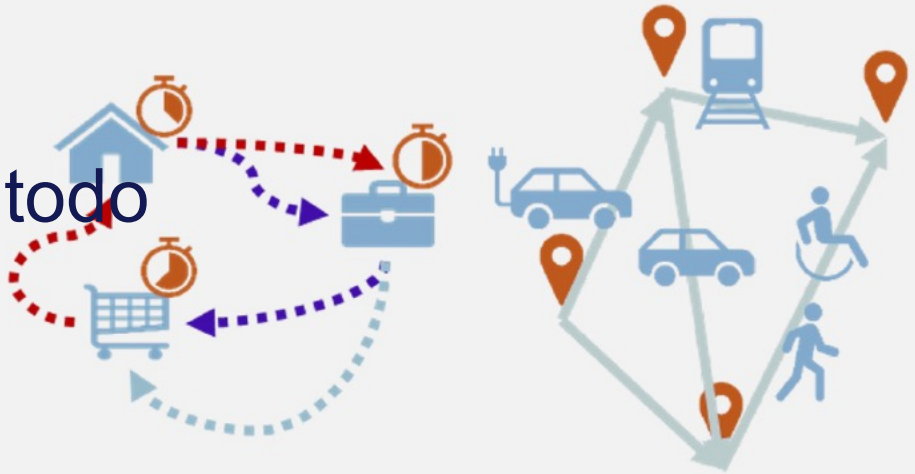


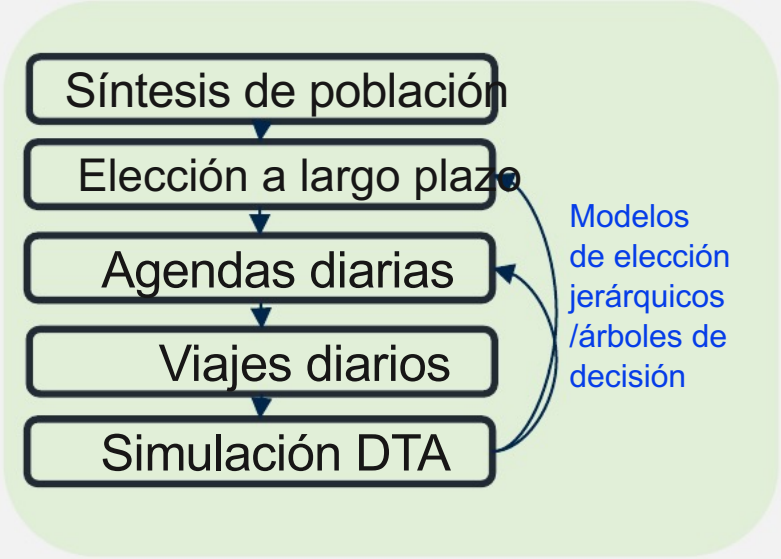


Diapositivas adaptadas de Tianming Liu (tianmliu@umich.edu)

Modelización de la demanda basada en actividades

- El paradigma más avanzado de modelización de la demanda
- Los trabajos recientes usan sobre todo simulación basada en agentes





Los agentes siguen reglas condición-acción codificadas para planificar actividades y viajes. Pueden aprender, adaptarse y mejorar sus interacciones con otros agentes y con su entorno dinámico.

Limitaciones de los enfoques existentes

- Las limitaciones se deben sobre todo a los supuestos y a la **complejidad de construir un buen modelo**

Supuestos de modelo necesarios

Ejemplo: modelo MNL

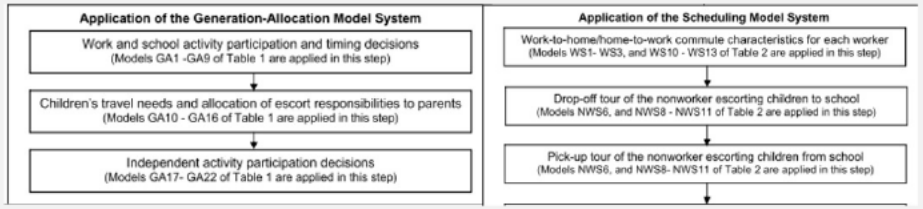
Assumption 1:
- We assume that the error terms each follow the Type-2 extreme value distribution (Gumbel distribution):
  - $\epsilon_{1n} \sim Gumbel(\eta, \mu)$
  - $\epsilon_{2n} \sim Gumbel(\eta, \mu)$

Assumption 2:
- We assume that ϵ_{1n} and ϵ_{2n} are independent and identically distributed (i.i.d.) across individuals, and independent of the attributes x_n.

Los modelos requieren supuestos a priori para funcionar

Calibración compleja

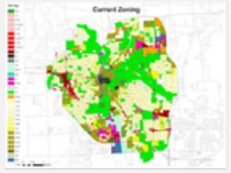
Ejemplo: un ABM típico



En total, hay que calibrar 49 modelos para modelizar el comportamiento de viaje

Necesidad de datos compleja











Se necesitan muchos datos para construir el modelo (si no, se toman prestados parámetros)

Agentes LLM y sus aplicaciones en simulación

Simulacros de comportamiento humano

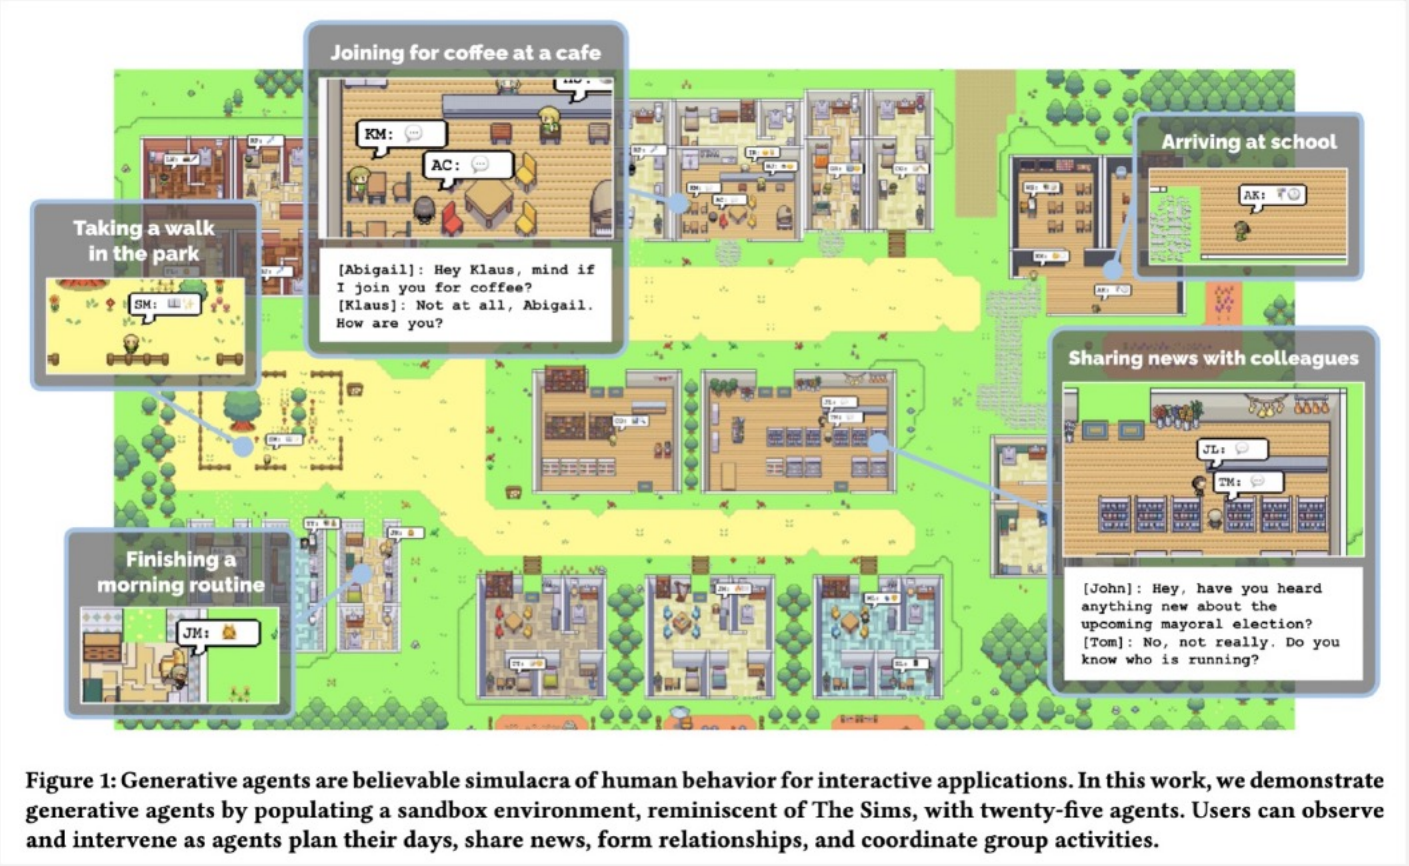


Figure 1: Generative agents are believable simulacra of human behavior for interactive applications. In this work, we demonstrate generative agents by populating a sandbox environment, reminiscent of The Sims, with twenty-five agents. Users can observe and intervene as agents plan their days, share news, form relationships, and coordinate group activities.

Gemini

Qwen3

juego de rol



J. S. Park, et al., "Generative agents: Interactive simulacra of human behavior," in Proceedings of the 36th annual acm symposium on user interface software and technology, 2023.
Grossmann, et al., AI and the transformation of social science research, Science, 2023, 380 (6650).

El LLM como sustituto del comportamiento humano

- Hipótesis clave: los LLM podrían actuar como «muestras de silicio»
- La razón principal es que los LLM tienen tres propiedades clave:

Imitación en el aprendizaje



Interacción similar a la humana



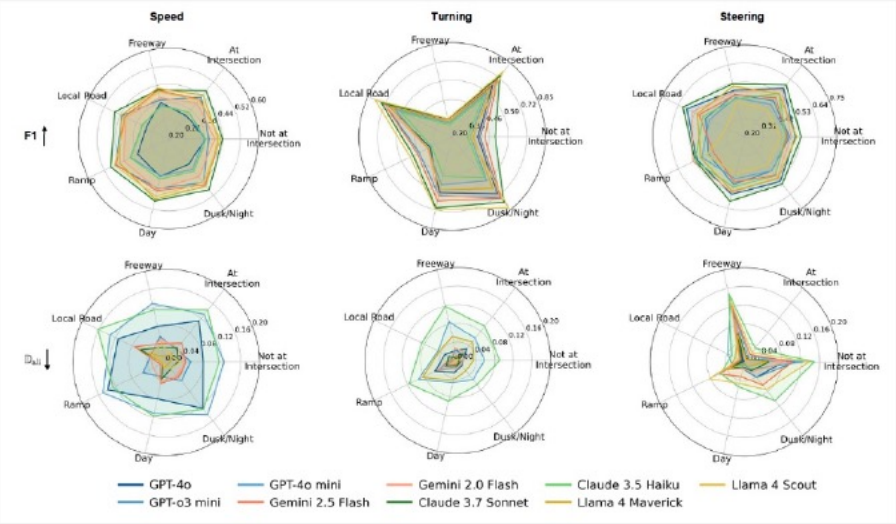
Seguimiento de instrucciones y juego de rol



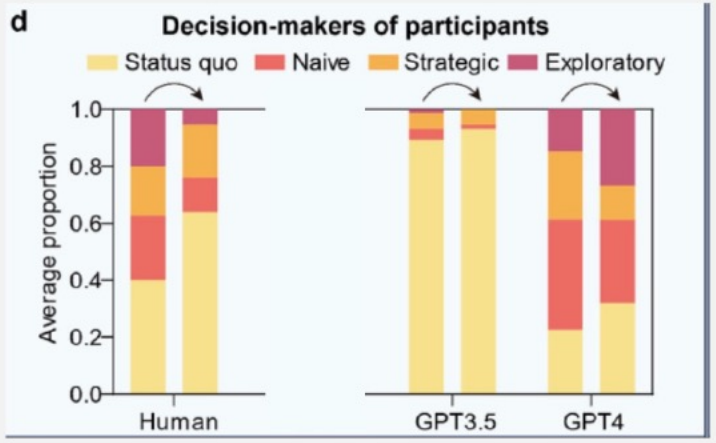
Pregunta crítica: ¿hasta qué punto se alinean con el comportamiento de viaje humano?

* Grossmann, et al., AI and the transformation of social science research, Science, 2023, 380 (6650).
** Hutson, M., Can AI chatbots replace human subjects in behavioral experiments. Science, 2023, 381(6654).

Los LLM parecen humanos, pero no son auténticamente humanos



Conducción autónoma: más alineados con conductores agresivos



Se necesita alineación

Juegos de congestión: aprender la adaptación de la ruta

Purpose	Income Elasticity			
	USDOT	Binsuwadan et al. (2023)*	Shires and de Jong (2009)**	GPT-4o
Commute	1	0.37	0.67	0.24
Business	1	0.53	0.47	0.21
Leisure	1	0.53	0.52	0.22
Personal	1	0.53	0.52	0.22

Valor del tiempo: elasticidades más bajas

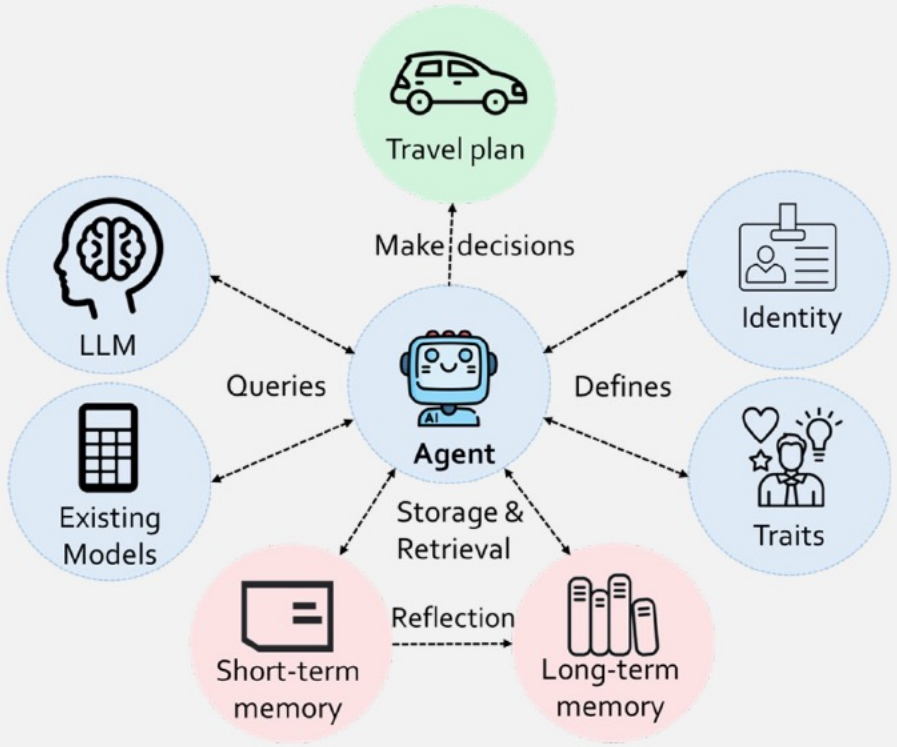




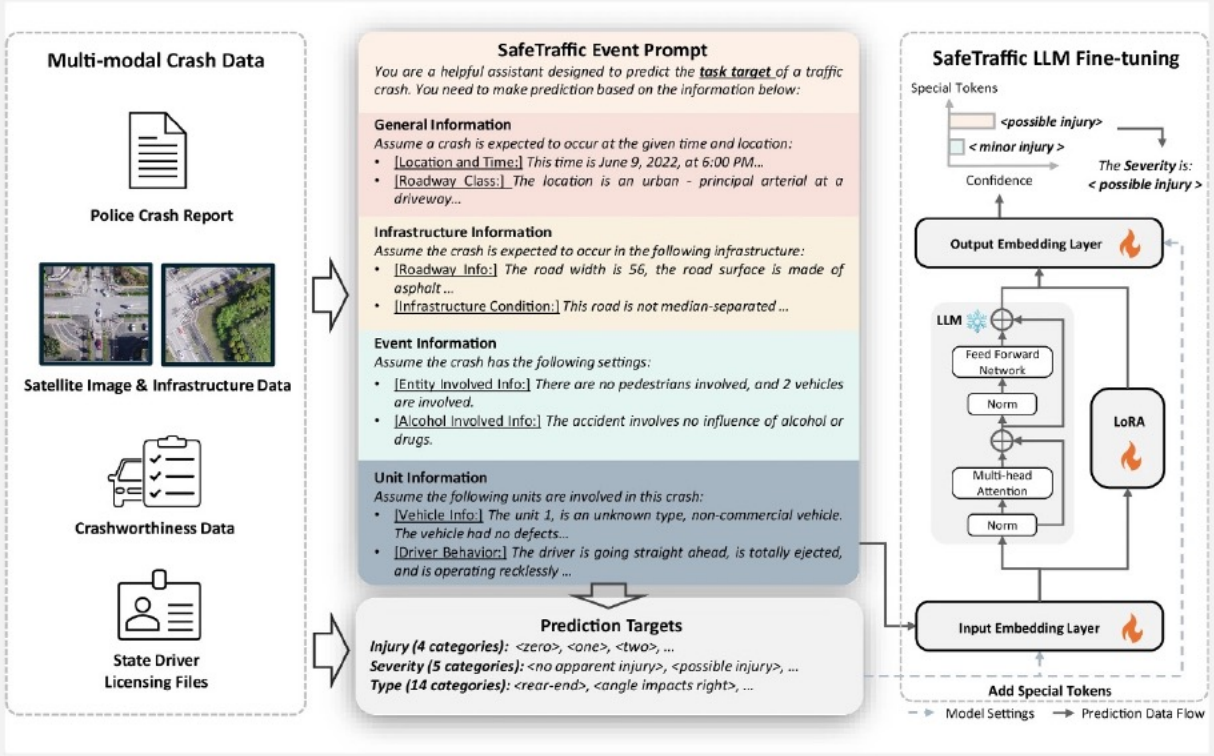
Ética de la conducción: sesgos en los principios

Wang, P., et al. "LLM agents can partially mimic human driving behaviors…." Transportation Research Part C: Emerging Technologies 186 (2026): 105606.
Xu, Z. et al.. (2025). Where is morality on wheels? …. Travel Behaviour and Society, 40, 101039.
Wang, L. et al. (2025). Comparing AI and human decision-making mechanisms in daily collaborative experiments. Iscience, 28(6).
Yan, Y. et al. (2026). Valuing time in silicon: Can large language models replicate human value of travel time. Travel Behaviour and Society, 44, 101245.

Desarrollar LLM y agentes más humanos



Agentes y optimización de prompts para imitar la toma de decisiones humana



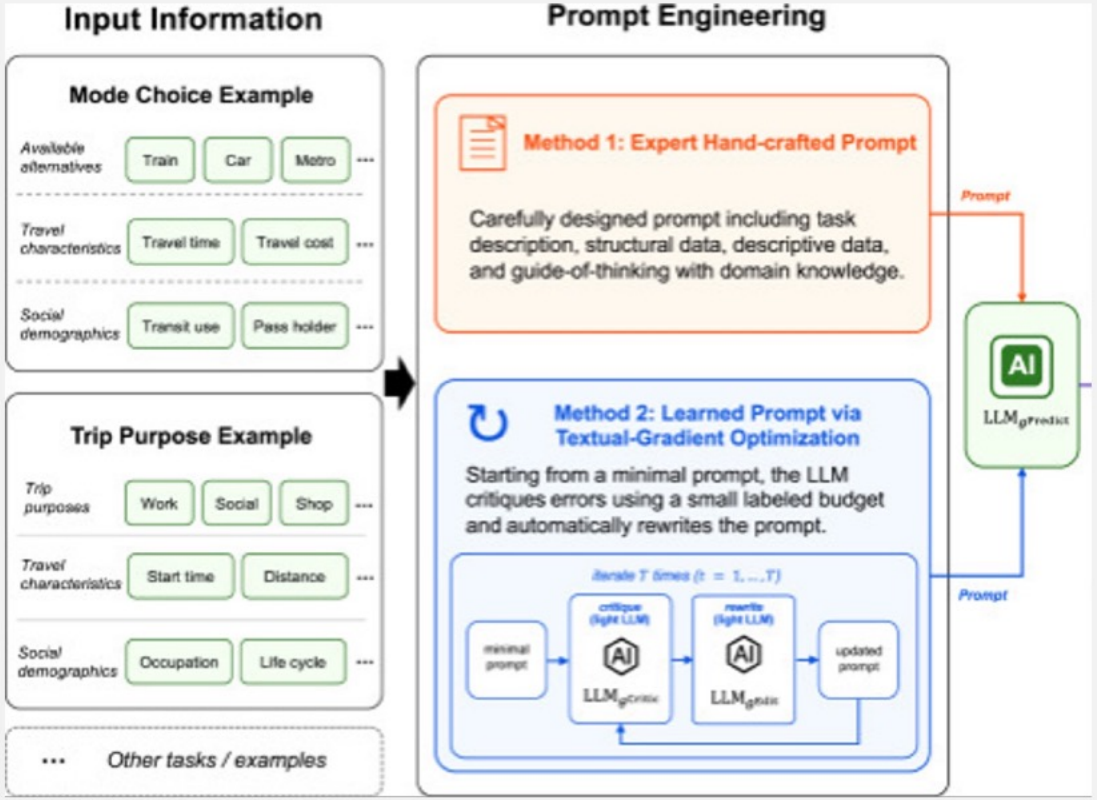
Post-entrenamiento para que los LLM imiten respuestas humanas

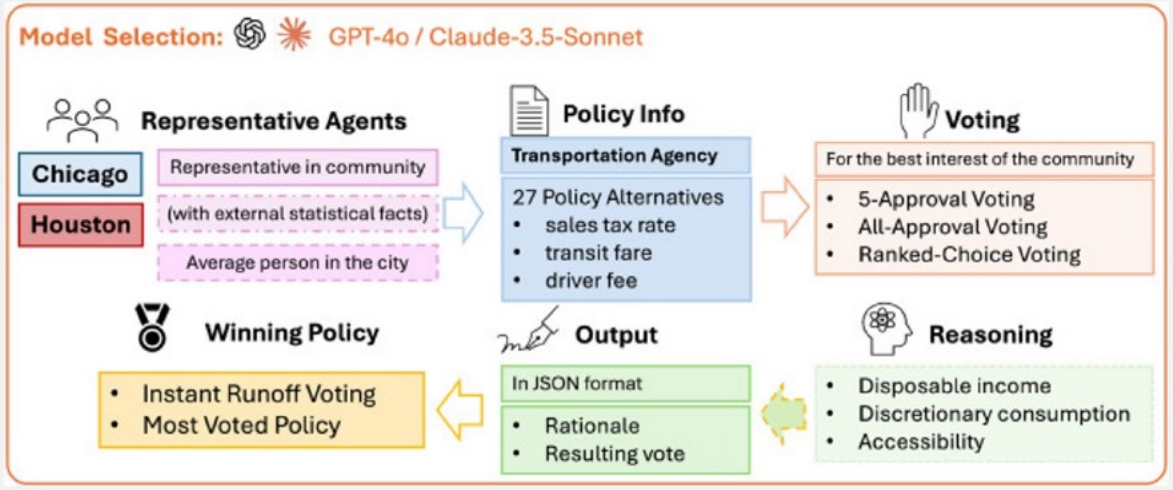
Liu, T. et. al. (2025). Toward LLM-agent-based modeling of transportation systems: A conceptual framework. Artificial Intelligence for Transportation, 1, 100001.

Zhao, Y, et al. (2025). SafeTraffic Copilot: adapting large language models for trustworthy traffic safety assessments and decision interventions. Nature Communications, 16(1), 8846.

Observaciones de la comunidad hasta ahora

El conocimiento interno y el juego de rol de los LLM pueden facilitar la previsión del comportamiento de viaje y la planificación del transporte





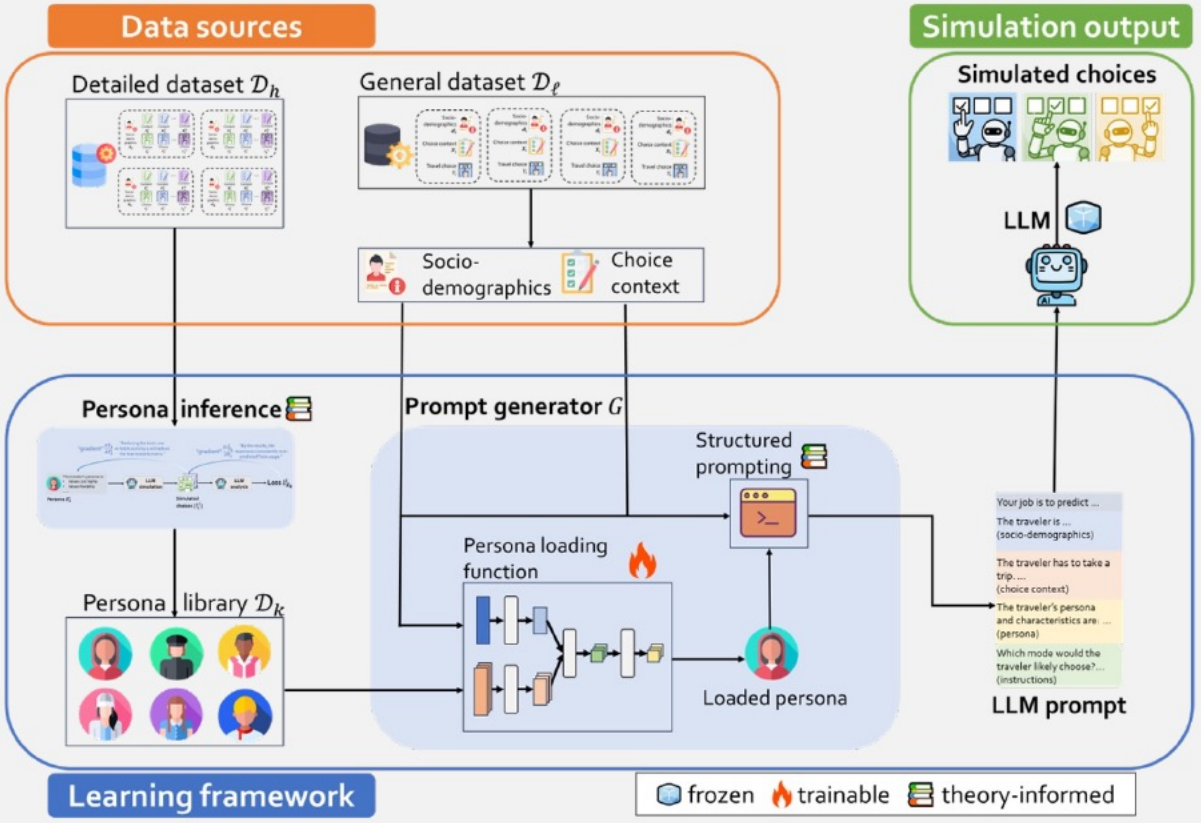
Los agentes LLM pueden actuar como agentes representativos en la planificación del transporte para reducir el sesgo de participación

Los LLM pueden usar su conocimiento interno para simular el comportamiento de viaje

Mo.B. et al. (2026) Large language models for travel behavior prediction. Transportation Research Interdisciplinary Perspectives, 38, 102124.
Yan, X., Dai, T., & Nie, Y. M. (2026). Addressing the alignment problem in transportation policy making: an LLM approach. Transportation Research Part C: Emerging Technologies, 188, 1
Cho, J. H., & Wu, C . (2026). AGORA: Can Deliberation and Governance Gates Absorb Participation Bias in Transit Planning?. IEEE Intelligent Transportation Systems Conference.

Observaciones de la comunidad hasta ahora

Entrenados con pocos datos humanos, los agentes LLM pueden predecir la demanda de viajes mejor que los modelos existentes.



- Los agentes LLM solo necesitan pocos datos humanos para simular bien las elecciones
- Al relajar los supuestos de comportamiento, los agentes LLM se adaptan a viajeros con comportamientos diversos
- Con memoria, arquetipos de comportamiento y post-entrenamiento con datos humanos, los agentes LLM diagnostican patrones e intenciones en las trazas de movilidad y predicen bien las trayectorias

Liu, T. et. al. (2026). Aligning LLM with Humans for Travel Choices: A Persona-Based Embedding Learning Approach. TransportationScience, Articles in Advance.
Liu, T. et al. (2026). Aligning LLM agents with human learning and adjustment behavior: a dual agent approach. TransportationResearch Part C: Emerging Technologies, 191, 105818.
Qin, Z. et.la. (2026). A foundational individual mobility prediction model based on open-source LLMs. Transportation Research Part C: Emerging Technologies, 185, 105562.
Wang, J. et al.. (2024). Large language models as urban residents: An llm agent framework for personal mobility generation. Advances in Neural Information Processing Systems, 37, 124547-124574.

Retos

Fundamentos y casos de uso

- Identificar el mejor caso de uso y los compromisos de los LLM: dónde aportan más y cuándo conviene aplicarlos
- Desarrollar enfoques y procedimientos unificados para aplicar LLM en distintos contextos

Validación

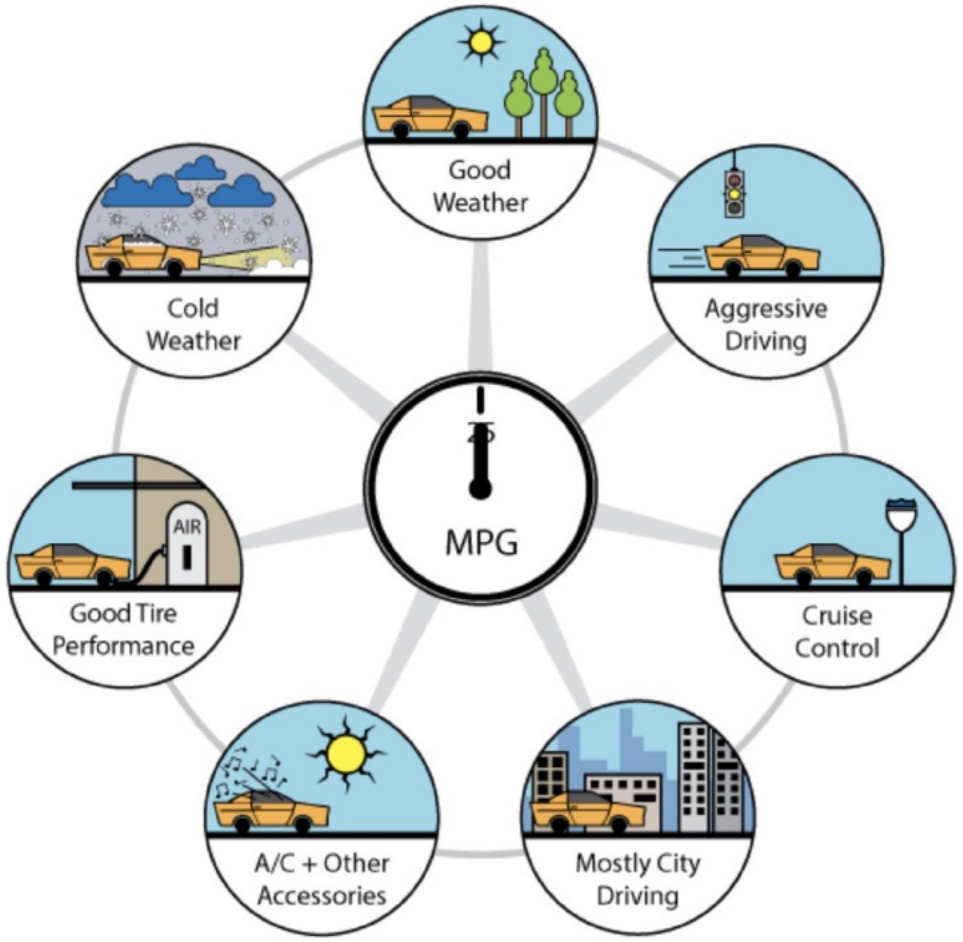
- Evaluación sistemática de las capacidades y el rendimiento de los LLM
- Ir más allá del comportamiento observado hacia la alineación de valores

Escalabilidad

- Reducir el coste de cómputo, el consumo de energía y la latencia en aplicaciones a gran escala

En profundidad: Mejorar IA para la eficiencia del transporte

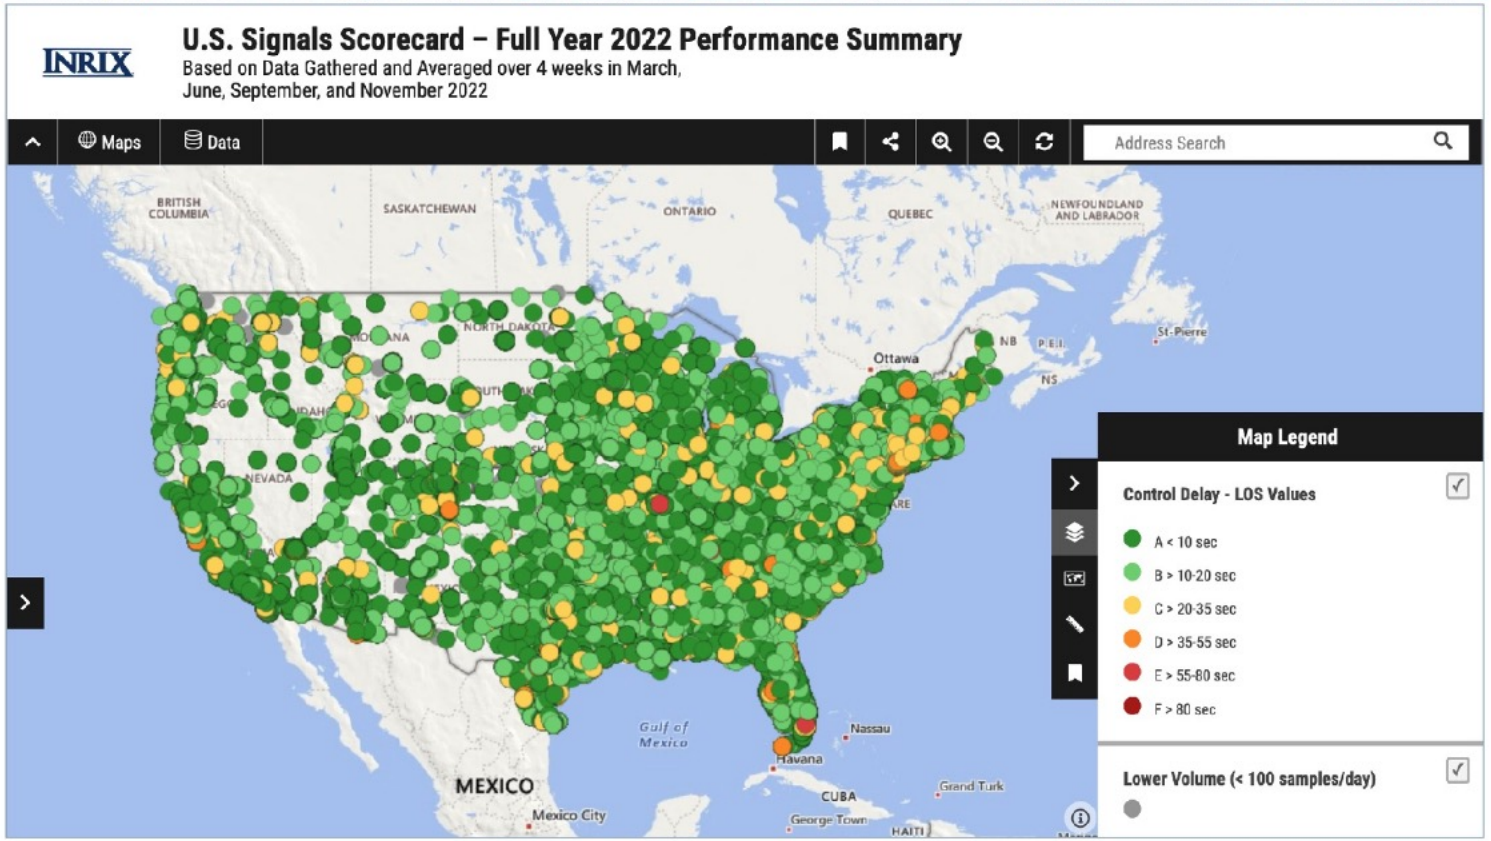
Factores que afectan al consumo



Fuente: US EPA, “Your Mileage May Vary,” 2026.

INRIX U.S. Signals Scorecard

2022 Annual Summary



Inputs

~5 Billion
Total Number of Observed Crossings Used to Generate Results

~10 Million
Number of Connected Vehicles Providing Location and Movement Data



242,757
Signalized Intersections Analyzed

All 50 States
(Plus District of Columbia)

400+ Regions

1,150+ Counties

Results

23,308
Intersection Avg Daily Traffic

18.1
Seconds of Delay Per Vehicle

63.5%
Arrival on Green

117.4
Total Hours of Daily Delay

2.53 Days
Days to Generate 1 Metric Tonne of Carbon Emissions From Delay

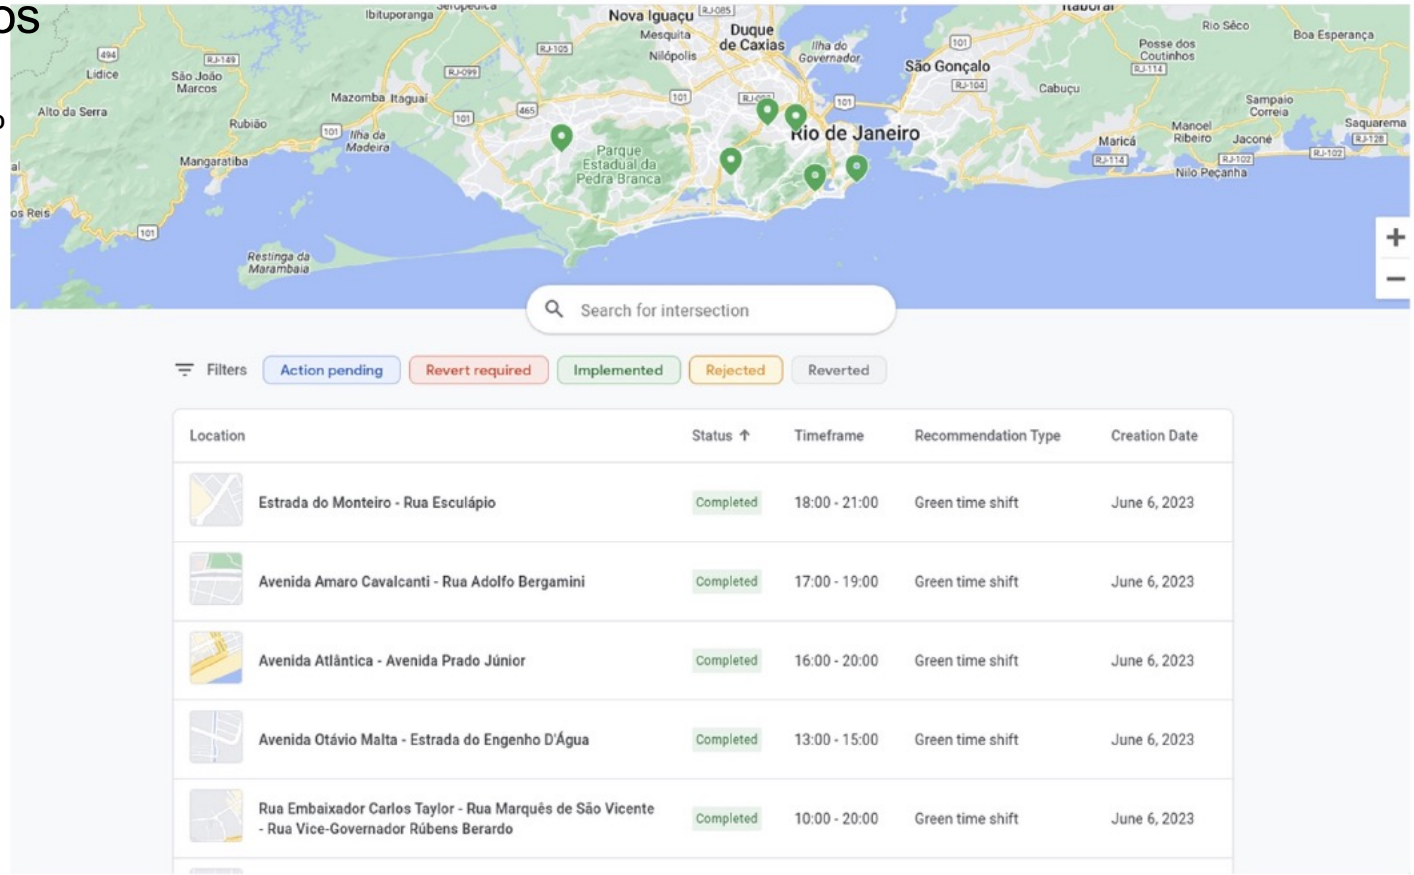
0.97 Days
Days to Consume 1 Barrel of Oil From Delay

Average Traffic Signal

INRIX U.S. Signals Scorecard: 2022 Annual Summary. INRIX. https://inrix.com/signals-scorecard/.

Project Green Light (Google AI)

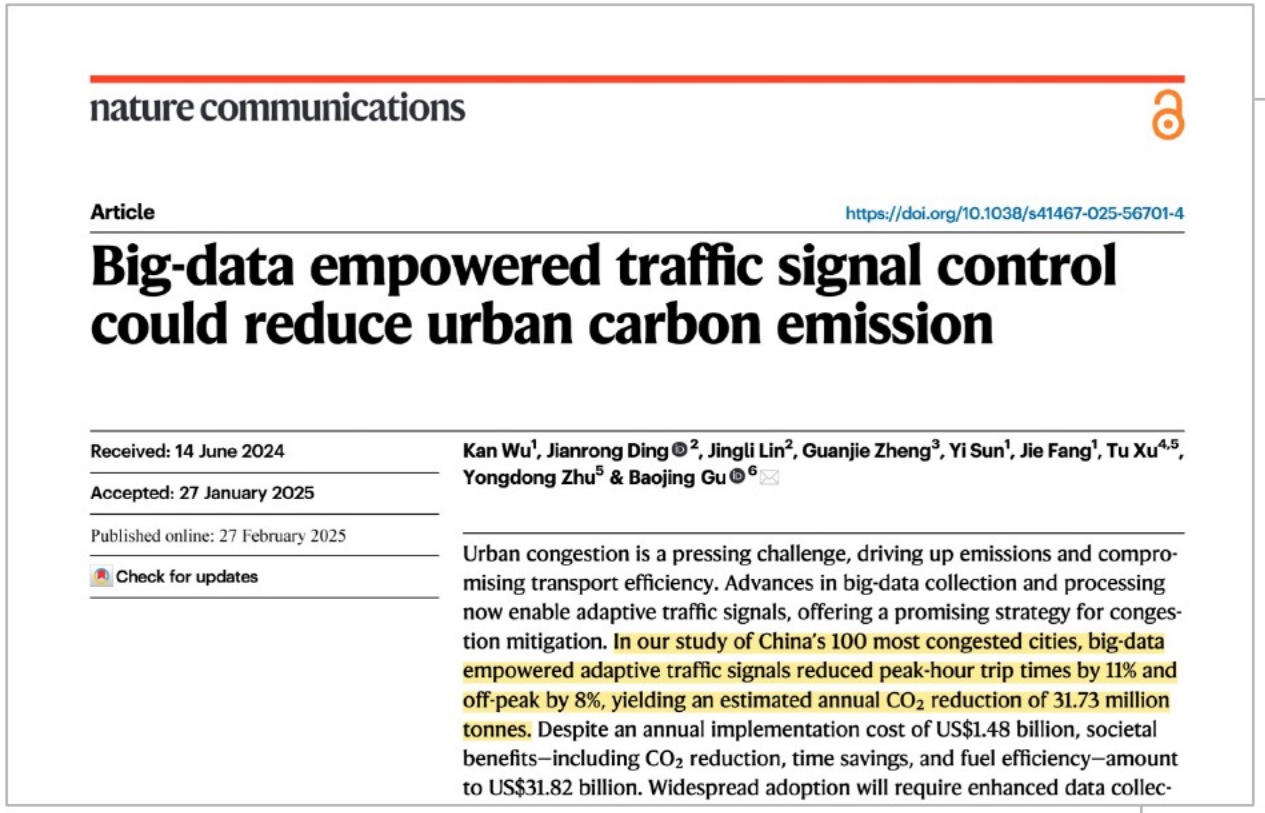
- Big data para la temporización de semáforos
  - Lanzado en 2023; activo en 20 ciudades
  - Hasta un 30 % menos de paradas y un 10 % menos de emisiones de GEI*
- Usa IA para inferir los parámetros actuales de los semáforos de tiempo fijo
  - Duración del ciclo
  - Tiempo de transición
  - Reparto del verde (tiempo y orden de paso)
  - Coordinación
  - Funcionamiento de sensores (actuación)
- Ofrece recomendaciones a los ingenieros de tráfico municipales sobre ajustes de los parámetros de los semáforos



* No hay auditoría independiente disponible

Google AI's Green Light. sites.research.google/gr/greenlight.

IA para la optimización de semáforos



nature communications

Article

https://doi.org/10.1038/s41467-025-56701-4

Big-data empowered traffic signal control could reduce urban carbon emission

Received: 14 June 2024

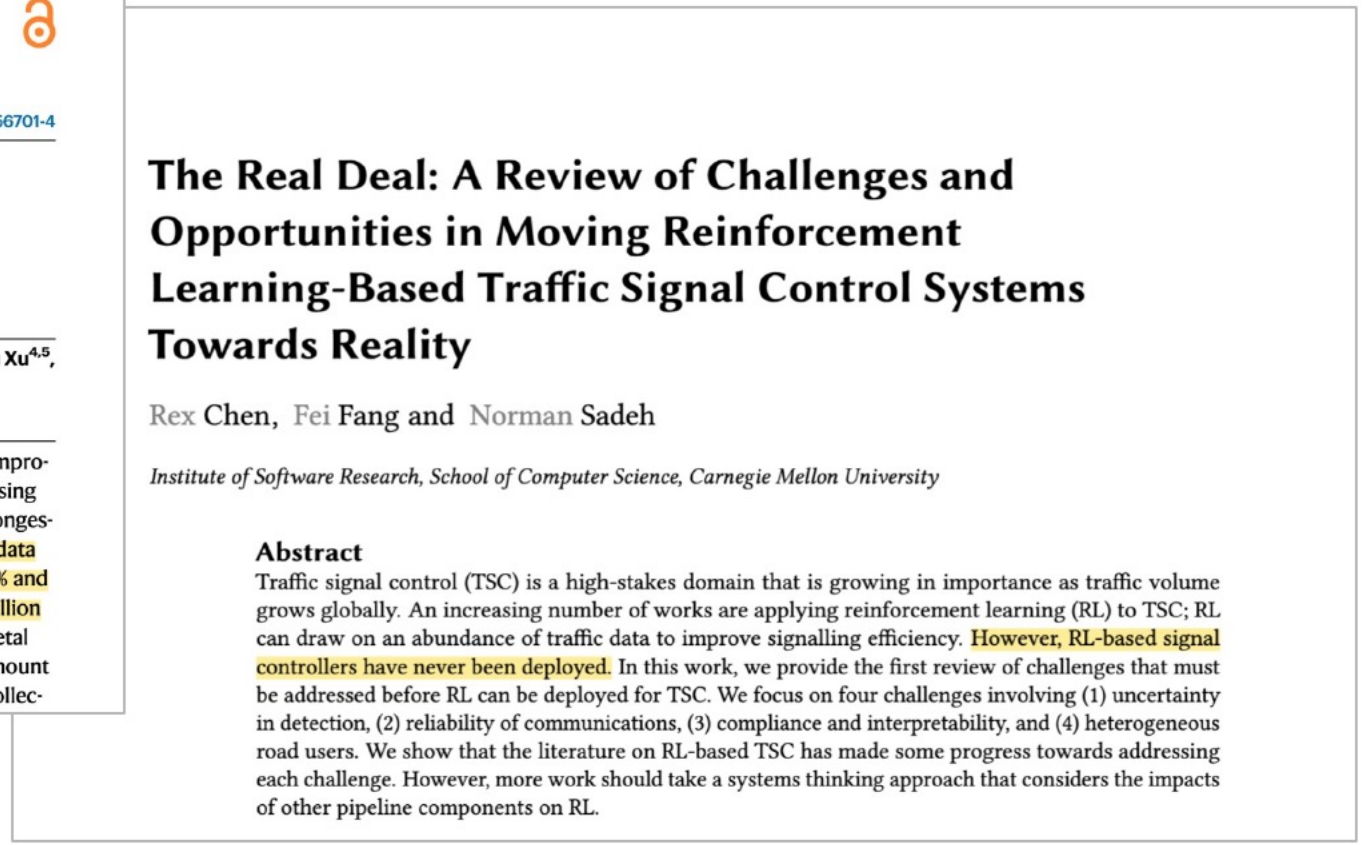
Accepted: 27 January 2025

Published online: 27 February 2025

Check for updates

Kan Wu[1], Jianrong Ding[2], Jingli Lin[2], Guanjie Zheng[3], Yi Sun[1], Jie Fang[1], Tu Xu[4,5], Yongdong Zhu[5] & Baojing Gu[6]

Urban congestion is a pressing challenge, driving up emissions and compromising transport efficiency. Advances in big-data collection and processing now enable adaptive traffic signals, offering a promising strategy for congestion mitigation. In our study of China's 100 most congested cities, big-data empowered adaptive traffic signals reduced peak-hour trip times by 11% and off-peak by 8%, yielding an estimated annual CO_2 reduction of 31.73 million tonnes. Despite an annual implementation cost of US$1.48 billion, societal benefits—including CO_2 reduction, time savings, and fuel efficiency—amount to US$31.82 billion. Widespread adoption will require enhanced data collec-



The Real Deal: A Review of Challenges and Opportunities in Moving Reinforcement Learning-Based Traffic Signal Control Systems Towards Reality

Rex Chen, Fei Fang and Norman Sadeh

Institute of Software Research, School of Computer Science, Carnegie Mellon University

Abstract

Traffic signal control (TSC) is a high-stakes domain that is growing in importance as traffic volume grows globally. An increasing number of works are applying reinforcement learning (RL) to TSC; RL can draw on an abundance of traffic data to improve signalling efficiency. However, RL-based signal controllers have never been deployed. In this work, we provide the first review of challenges that must be addressed before RL can be deployed for TSC. We focus on four challenges involving (1) uncertainty in detection, (2) reliability of communications, (3) compliance and interpretability, and (4) heterogeneous road users. We show that the literature on RL-based TSC has made some progress towards addressing each challenge. However, more work should take a systems thinking approach that considers the impacts of other pipeline components on RL.

[1] K. Wu et al., "Big-data empowered traffic signal control could reduce urban carbon emission," Nat Commun, 2025, doi: 10.1038/s41467-025-56701-4.
[2] R. Chen, F. Fang, and N. Sadeh, "The real deal: A review of challenges and opportunities in moving reinforcement learning-based traffic signal control systems towards reality," arXiv preprint arXiv:2206.11996, 2022.

Energy Policy 38 (2010) 762–769

Contents lists available at ScienceDirect

Energy Policy

journal homepage: www.elsevier.com/locate/enpol

Eco-driving: An overlooked climate change initiative

Jack N. Barkenbus

Climate Change Research Network, Vanderbilt University, 131 21st Avenue South, Nashville, TN 37203, United States

ARTICLE INFO

Article history:
Received 11 June 2009
Accepted 2 October 2009
Available online 28 October 2009

Keywords:
Climate change
Transportation
Mitigation

ABSTRACT

The actions individuals can take to mitigate climate change are, in the aggregate, significant. Mobilizing individuals to respond personally to climate change, therefore, must be a complementary approach to a nation's climate change strategy. One action item overlooked in the United States has been changing driver behavior or style such that eco-driving becomes the norm rather than the exception. Evidence to date indicates that eco-driving can reduce fuel consumption by 10%, on average and over time, thereby reducing CO_2 emissions from driving by an equivalent percentage. A sophisticated, multi-dimensional campaign, going well beyond what has been attempted thus far, will be required to achieve such savings on a large scale, however, involving education (especially involving the use of feedback devices), regulation, fiscal incentives, and social norm reinforcement.

© 2009 Elsevier Ltd. All rights reserved.

[1] J. N. Barkenbus, "Eco-driving: An overlooked climate change initiative," Energy Policy, 2010, doi: 10.1016/j.enpol.2009.10.021.

Conducción eficiente por el planeta (con IA)

Mitigating Metropolitan Carbon Emissions with Dynamic Eco-driving at Scale

Transportation Research Part C: Emerging Technologies 2025







Vindula Jayawardana Baptiste Freydt Ao Qu Cameron Hickert Edgar Sanchez






Catherine Tang Mark Taylor Blaine Leonard Cathy Wu

¿Implicaciones políticas de los vehículos conectados y automatizados?

Posibilidad de los VCA: conducción eficiente en cruces con semáforo

Vídeo: Audi



De «cómo conducir de forma eficiente» (1000+ artículos)
a «si debemos hacerlo» (≈ 0 artículos)?

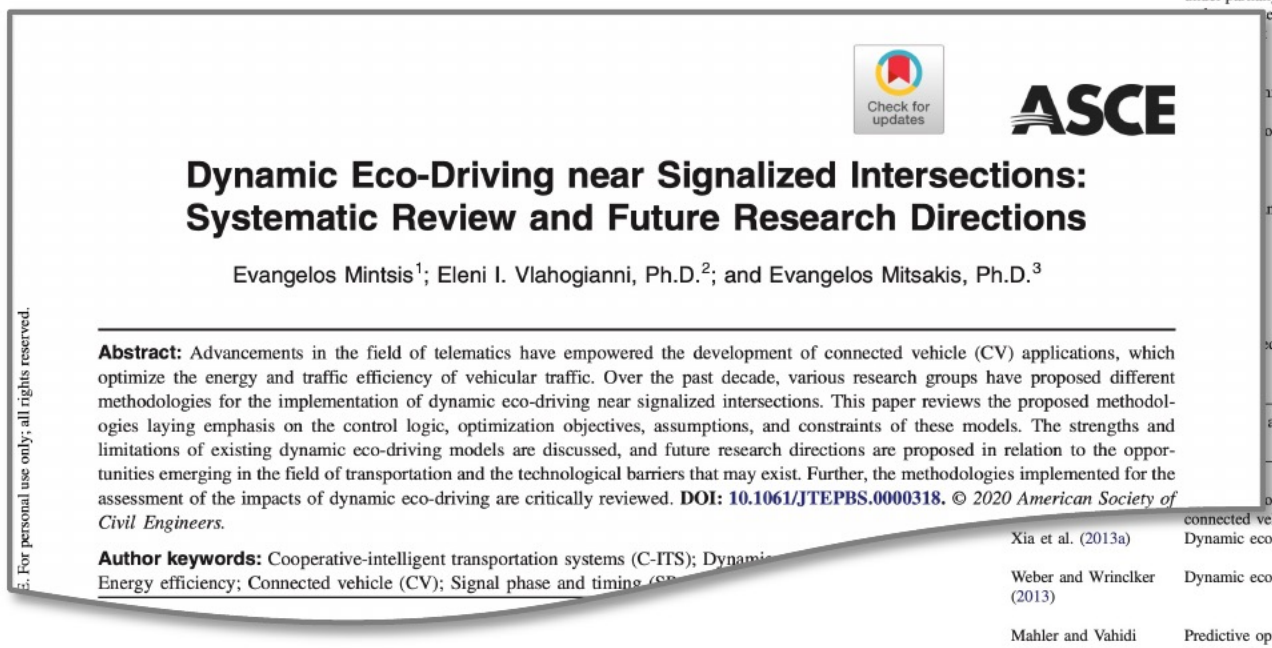
Pregunta de investigación: ¿un control inteligente de los vehículos para reducir el CO en los cruces, a escala de ciudad, haría avanzar los objetivos de mitigación?

* Estimated using Google Scholar

[1] Mintsis et al. Dynamic eco-driving near signalized intersections: Systematic review and future research directions . Journal of Transportation Engineering, Part

Ahorro de energía / emisiones

Ahorro de la conducción eficiente



Check for updates

ASCE

Dynamic Eco-Driving near Signalized Intersections: Systematic Review and Future Research Directions

Evangelos Mintsis[1]; Eleni I. Vlahogianni, Ph.D.[2]; and Evangelos Mitsakis, Ph.D.[3]

Abstract: Advancements in the field of telematics have empowered the development of connected vehicle (CV) applications, which optimize the energy and traffic efficiency of vehicular traffic. Over the past decade, various research groups have proposed different methodologies for the implementation of dynamic eco-driving near signalized intersections. This paper reviews the proposed methodologies laying emphasis on the control logic, optimization objectives, assumptions, and constraints of these models. The strengths and limitations of existing dynamic eco-driving models are discussed, and future research directions are proposed in relation to the opportunities emerging in the field of transportation and the technological barriers that may exist. Further, the methodologies implemented for the assessment of the impacts of dynamic eco-driving are critically reviewed. **DOI: 10.1061/JTEPBS.0000318.** © *2020 American Society of Civil Engineers.*

Author keywords: Cooperative-intelligent transportation systems (C-ITS); Dynami
Energy efficiency; Connected vehicle (CV); Signal phase and timing (SP

. For personal use only; all rights reserved.

Table 3. Evaluation methodologies of existing dynamic eco-driving models and corresponding impacts

Authors	Speed advisory model	Evaluation method	Test network configuration	Vehicle type	Energy savings (%)	Emissions savings (%)	Travel time savings (%)	Real-time ready
Ha et al. (2016)	PAD	Field experiment (real-world traffic)	El Camino Real test site	Single-vehicle (2.5L 4-cylinder)	2 (all trips)	7 (CO) 18 (HC) 13 (NO_x)	—	—
Jiang et al. (2017)	Dynamic eco-driving under partially connected ed vehicles	Simulation (Excel VBA, MATLAB, and VISSIM)	Hypothetical intersection	—	2.02	1.97	10.80	Yes
		Field experiment (real-world traffic)	DRIVE C2X test site (Gothenburg, Sweden)	10 retrofitted prototype vehicles	—	—	—	Yes
	mendation	Field experiment	Virginia Smart Road Test facility	2014 Cadillac SRX	19	—	10	Yes
	o-driving	Field experiment (real-world traffic)	Signalized arterial corridor (Thessaloniki, Greece)	340 taxis	—	9 (compliant versus noncompliant)	—	Yes
		MATLAB	—	30 top sold vehicles in the US	—	—	—	Yes
	nce model	Simulation (EstiNet)	3.7 km urban arterial road in Beijing	—	—	2.13	8.15	—
		Numerical evaluation	Hypothetical intersection	—	3–12	5–20 (CO) 3–14 (HC) 6–21 (NO_x)	—	Yes
		Controlled experiment	Palmyrita Avenue, Riverside, California	2008 Nissan Altima	5–27	—	—	Yes
	d dynamic	Simulation (INTEGRATION)	Cross intersection (Blacksburg, Virginia)	—	13	13 (CO, HC, CO_2, and NO_x)	38	—
		Simulation	—	—	—	—	—	—
	—	MATLAB (GPOPS)	—	—	29	—	–9	Yes
	assistant	Field experiment (real-world traffic)	Urban network	5 different vehicles (series-production)	4.9	—	—	Yes
	—	MATLAB (sensitivity analysis)	—	—	—	50 (NO_x)	14	—
	o-driving for connected vehicles	Simulation (PARAMICS)	Hypothetical intersection	Single and multivehicle	31	—	—	Yes
Xia et al. (2013a)	Dynamic eco-driving	Simulation (PARAMICS)	11-signalized arterial corridor	Single and multivehicle	12.5	13 (CO_2)	0.7	Yes
Weber and Wrinclker (2013)	Dynamic eco-driving	Field experiment	Richmond Field Station test track El Camino Real test site	BMW mid-sized sedan	14	—	—	Yes
Mahler and Vahidi (2012)	Predictive optimal velocity planning algorithm	MATLAB Field experiment	— (Greenville, South Carolina)	— —	— —	— —	— —	Yes
Rakha et al. (2012)	—	MATLAB	—	—	30	—	—	—
Schuricht et al. (2011)	Predictive driver assistance	Simulation (IDM)	—	—	8.7	—	—	—
Kaupitsch et al. (2011)	Predictive driving strategy	MATLAB Field experiment	— BMW test track (Aschheim, Munich, Germany)	—	10	—	—	Yes
Barth et al. (2011)	Dynamic eco-driving	Simulation (PARAMICS)	Hypothetical 10-signalized arterial	Mid-sized Sedan	12	12 (CO_2)	2	Yes
Asadi and Vahidi (2011)	PCC	SIMULINK (MATLAB)	Urban road Suburban road	—	47	56 (CO_2)	—	—
Tielert et al. (2010)	Speed adaptation model	Simulation (VISSIM)	Single-lane road segment Karlsruhe's inner city, Germany	EURO4 Otto and diesel engines	22 8	80 (CO); 35 (NO_x); 18 (PM) —	—	—
Vreeswijk et al. (2010)	—	Simulation (VISSIM)	Four-leg intersection (Rotterdam, Netherlands)	—	—	5 (CO_2 and NO_x)	—	Yes
Saust et al. (2010)	—	Field experiment	Ring road of Braunschweig, Germany (two-lane arterial road)	—	35	—	—	Yes
Mandava et al. (2009)	Arterial velocity planning algorithm	Stochastic simulation	Hypothetical 10-signalized arterial	LDV24 and LDV17	12–14	12–14 (CO_2)	—	—
Li et al. (2009)	ADAS	Parametric analysis Simulation	—	—	14 8	—	—	—

§ Ahorro estimado de energía / emisiones entre el 2 y el 56 % (25 estudios)

Mintsis et al. Dynamic eco-driving near signalized intersections: Systematic review and future research directions . Journal of Transportation Engineering, Part A, 2020

Wu

Cálculo de impacto (estimación aproximada*)

Impacto en la conducción

51.9%
x [6, 28]%
[3.1, 14.5]%

Km recorridos (VMT) cerca de cruces con semáforo [1]

Emisiones evitables con conducción eficiente (± 1 desv. típica según [2])

de las emisiones de CO_2 de la conducción simplemente se «desperdician» en los cruces

Impacto nacional

x 29%
x 81%
[0.7, 3.41]%

GEI del sector del transporte [3]

↳ GEI de los vehículos de carretera [4]

de las emisiones de CO_2 de EE. UU. simplemente se «desperdician» en los cruces

Gold standard:
–1% global GHG
Breakthrough Energy Ventures
Led by Bill Gates

[1] U.S. Federal Highway Administration (FHWA). Highway Statistics 2021. 2023.
[2] Mintsis et al. Dynamic eco-driving near signalized intersections: Systematic review and future research directions . Journal of Transportation Engineering, Part A, 2020.
[3] U.S. Environmental Protection Agency, Inventory of U.S. greenhouse gas emissions and sinks . 2023.
[4] U.S. Environmental Protection Agency, Fast Facts on Transportation Greenhouse Gas Emissions . 2023.

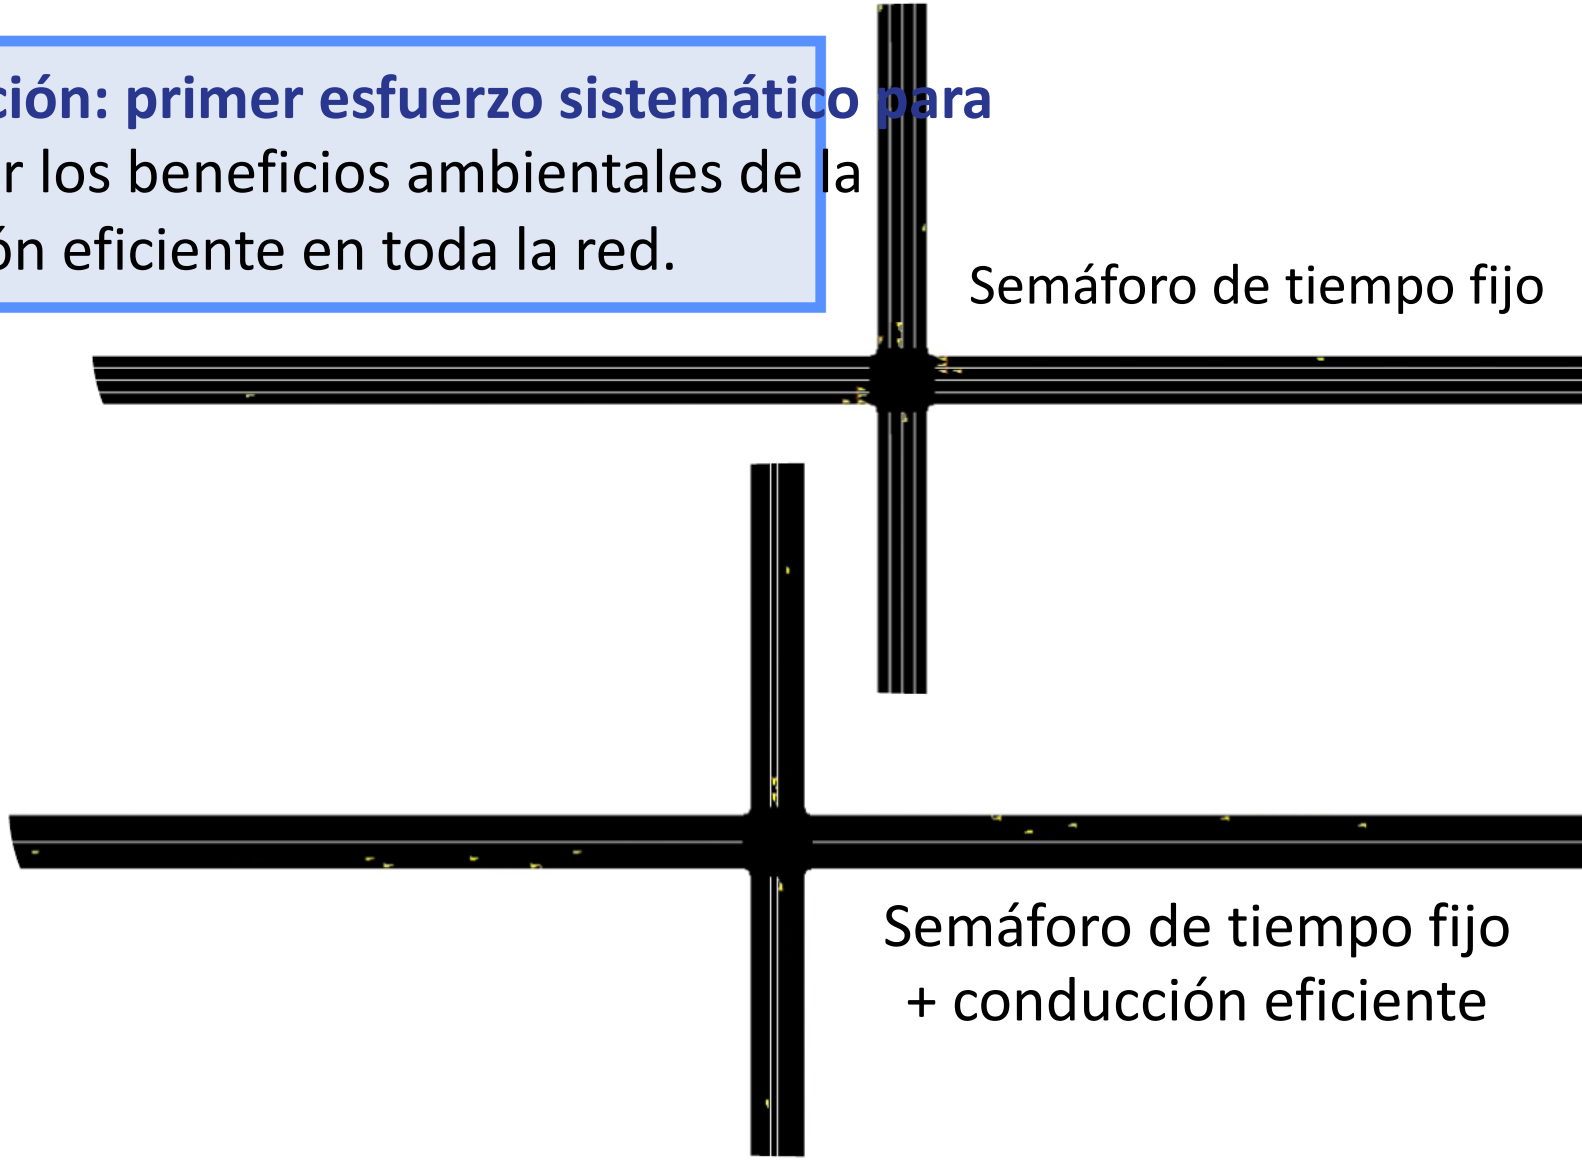
* Cálculos basados en estadísticas de EE. UU.

Conducción eficiente a escala regional



San Francisco

Contribución: primer esfuerzo sistemático para cuantificar los beneficios ambientales de la conducción eficiente en toda la red.



Objetivo: reducción esperada de emisiones de la flota sin impacto notable en el tiempo de viaje ni en la capacidad del cruce

Sujeto a: requisitos de seguridad, límites de los actuadores del vehículo y normas de circulación

Todos los escenarios se modelizan en simuladores de nivel industrial

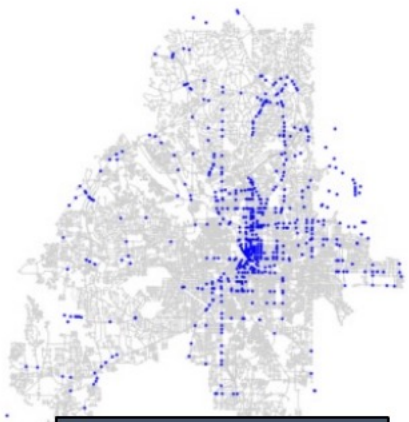
6011 cruces basados en datos reales modelizados en el simulador microscópico SUMO de nivel industrial



San Francisco

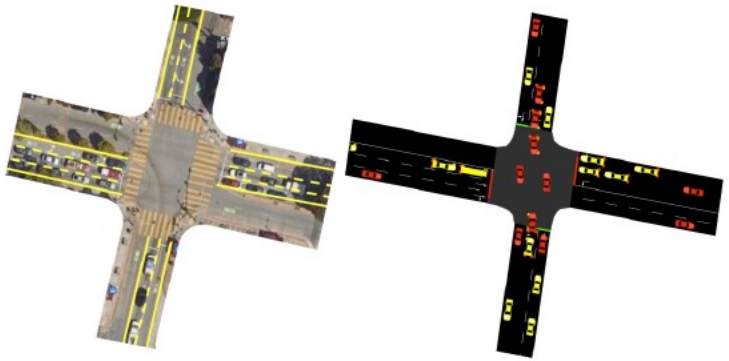


Los Angeles

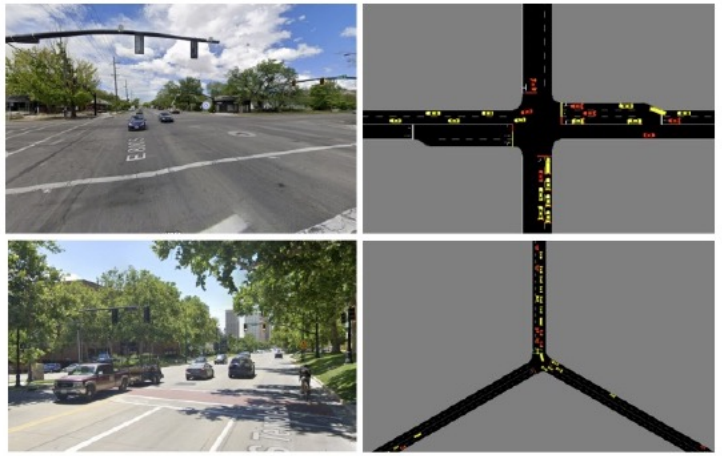


Atlanta

Más de 1 M de escenarios de tráfico





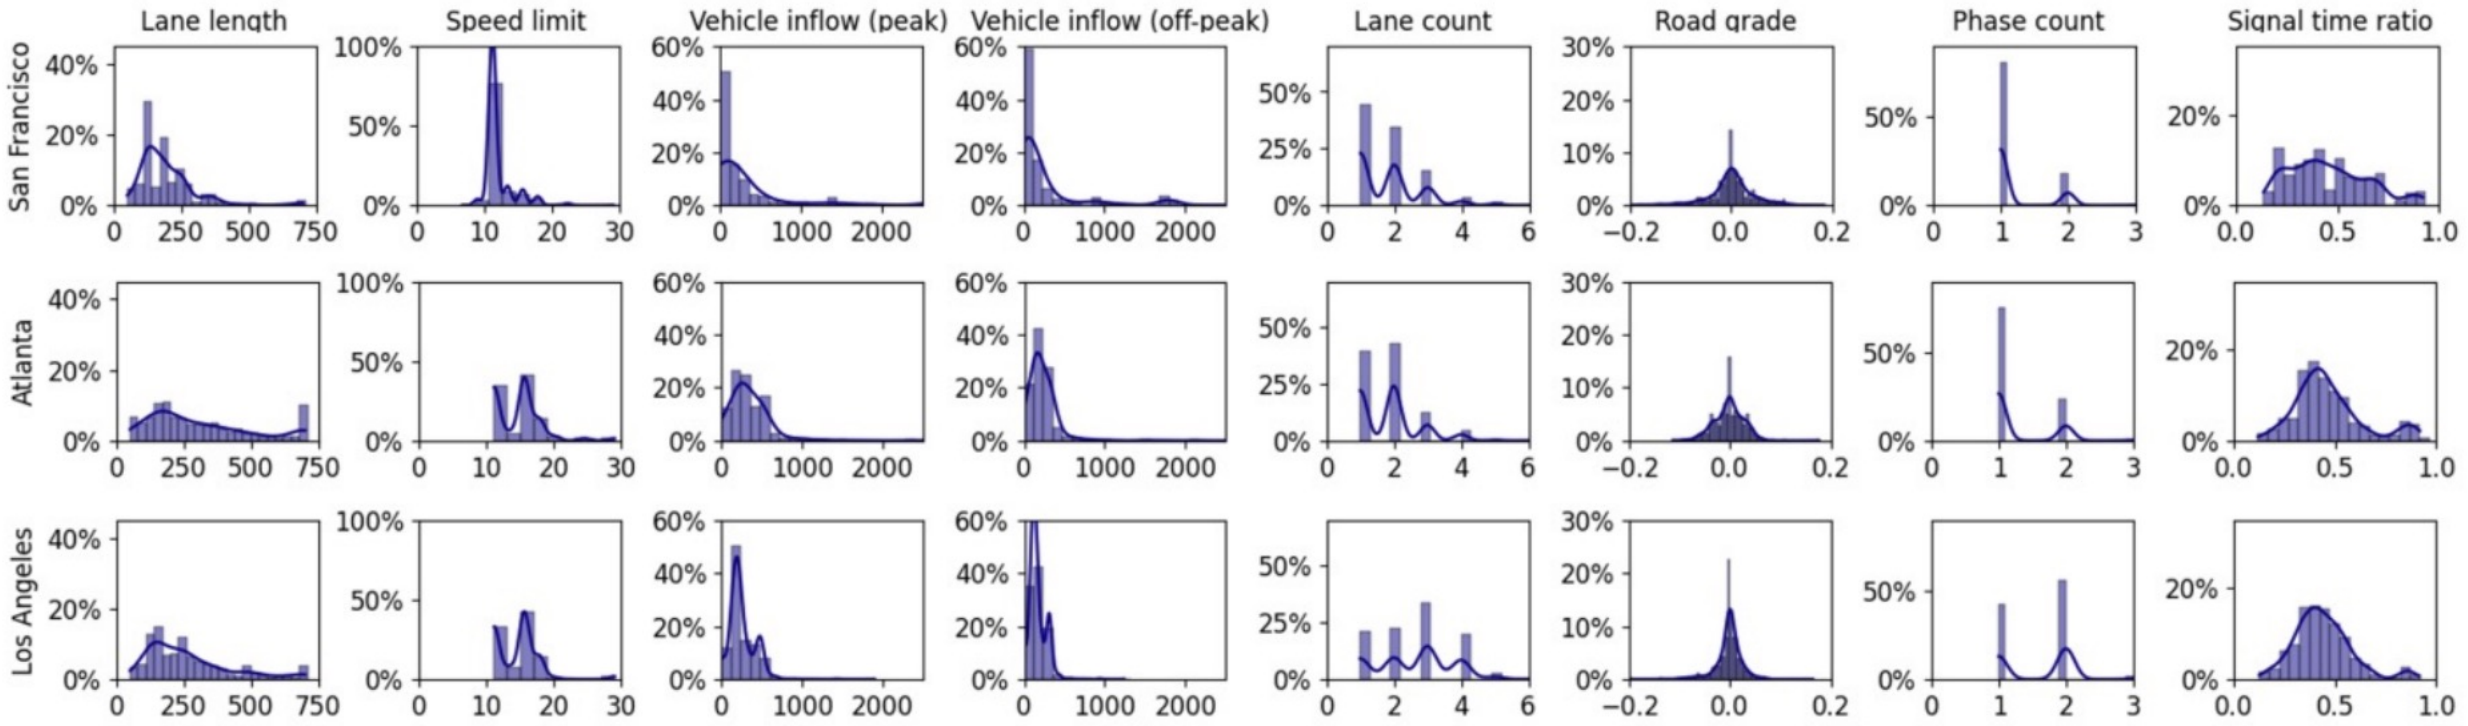


Cruce real vs. simulación

Qu, Valiveru, Tang, Jayawardana, Freydt, Wu, What is a typical signalized intersection in a city? A pipeline for intersection data imputation from OpenStreetMap , Transportation Research Board, 2023.
Jayawardana et al. IntersectionZoo: Eco-driving for benchmarking contextual reinforcement learning . International Conference on Learning Representations (ICLR), 2025.

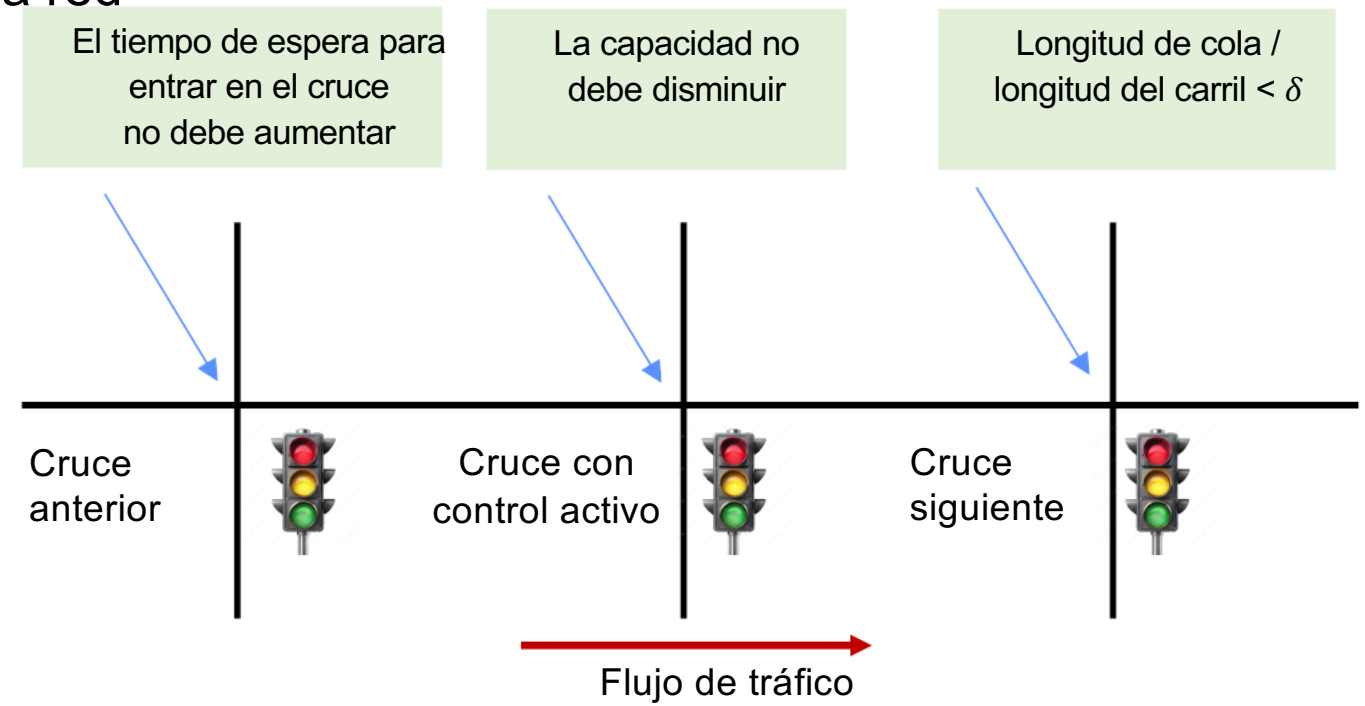
Todos los escenarios se modelizan con datos y herramientas abiertos

Servicio Geológico de EE. UU. (USGS)



Descomposición de la red

Requisitos de la descomposición de la red



Si la conducción eficiente incumple alguno de estos requisitos, los beneficios se fijan en cero

Así, los beneficios son una cota inferior de los beneficios posibles

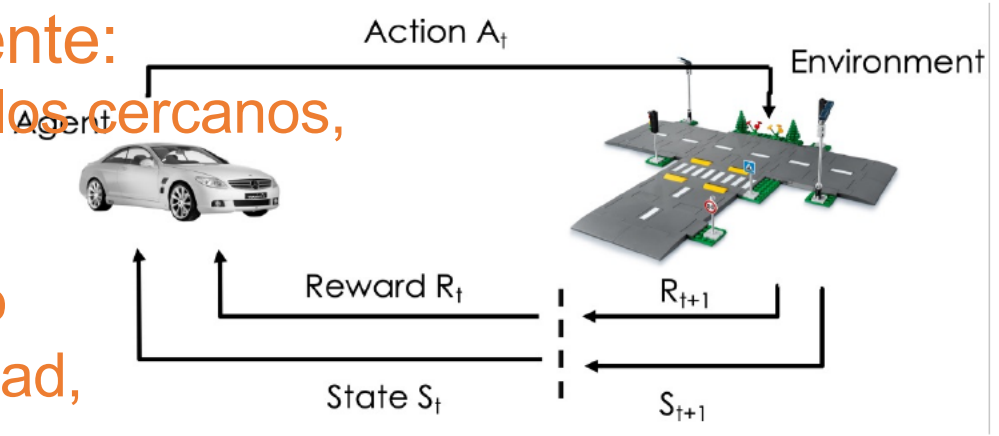
Modelizar la conducción eficiente como un PDM

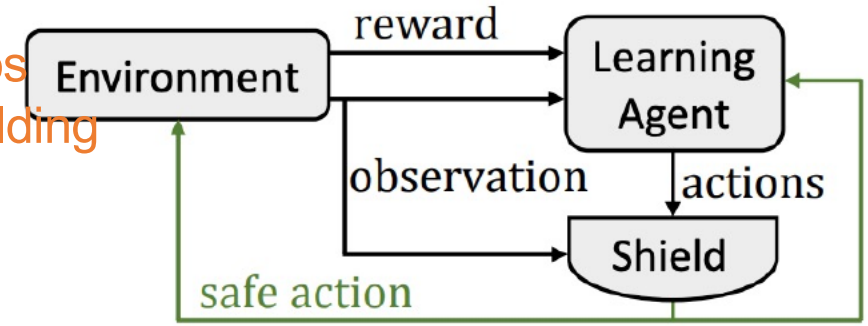
§ Protocolo de entrenamiento: RL multiagente con parámetros compartidos, con entrenamiento centralizado y ejecución descentralizada.

- Proceso de decisión de Markov descentralizado parcialmente observable (Dec-POMDP)

§ Para cada vehículo con conducción eficiente:

- Observación: sensores del vehículo, vehículos cercanos, información de los semáforos y contexto del cruce
- Acción: aceleración longitudinal del vehículo
- Recompensa: combinación lineal de velocidad, emisiones y ralentí
- Función de transición:
  - § Comportamiento de los demás usuarios, semáforos
  - § Restricciones estrictas garantizadas con post-shielding
- Horizonte: 12,5 min (1500 pasos de 0,5 s) con factor de descuento $\gamma = 0.99$
  - § Un ciclo semafórico típico dura 1-3 min





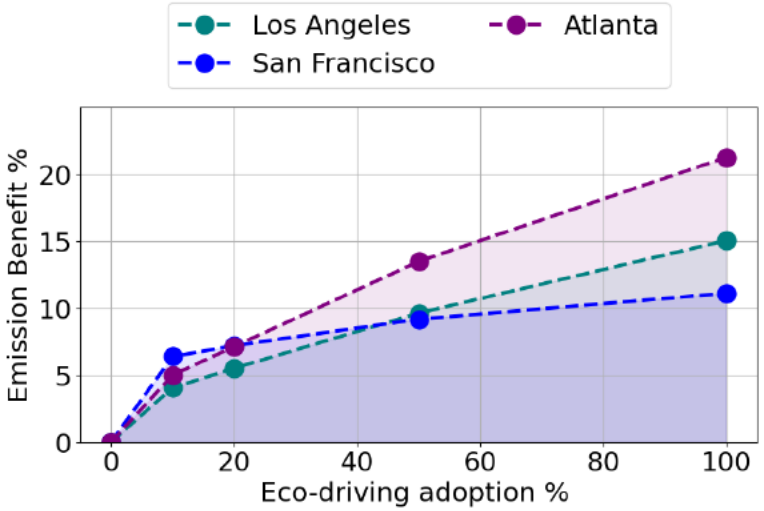
Wu

Resultados: eficacia global

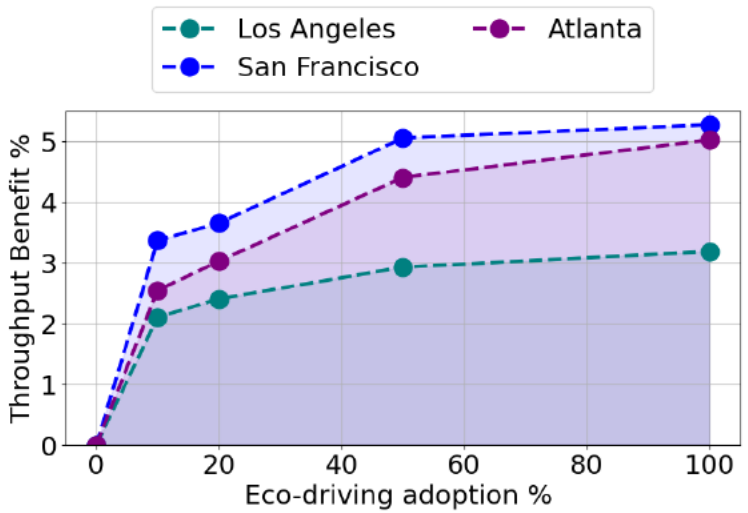
Gold standard:
–1% global GHG
Breakthrough Energy
Led by Bill Gates

La conducción eficiente podría reducir un 11-21 % las emisiones de CO en los cruces de una ciudad.
Esto equivale al 1,34-2,68 % de las emisiones de CO de EE. UU.

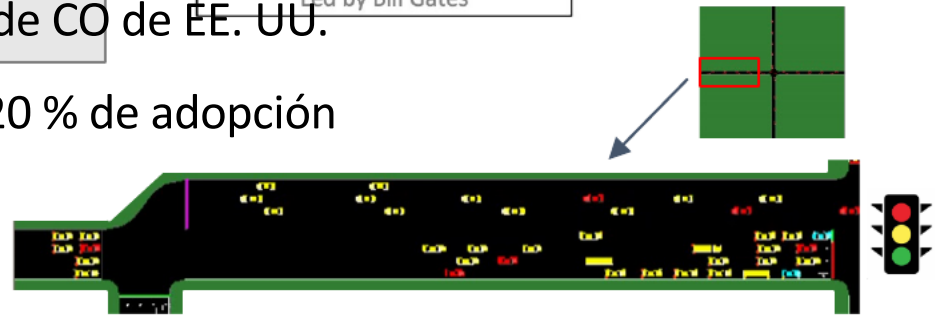
Reducción de emisiones



Aumento de capacidad

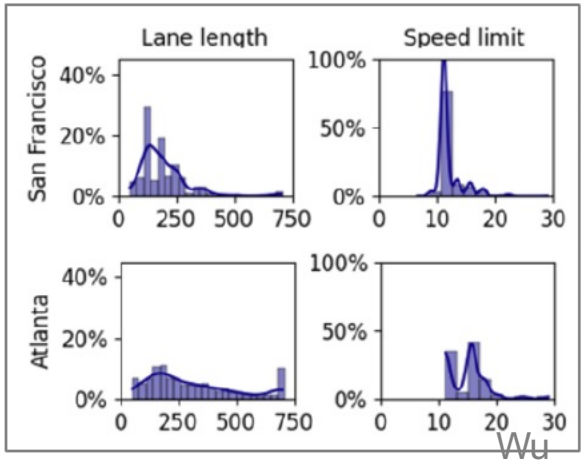


20 % de adopción



100 % de adopción





§ Escala no lineal: 25-50 % de los beneficios
con un 10 % de adopción

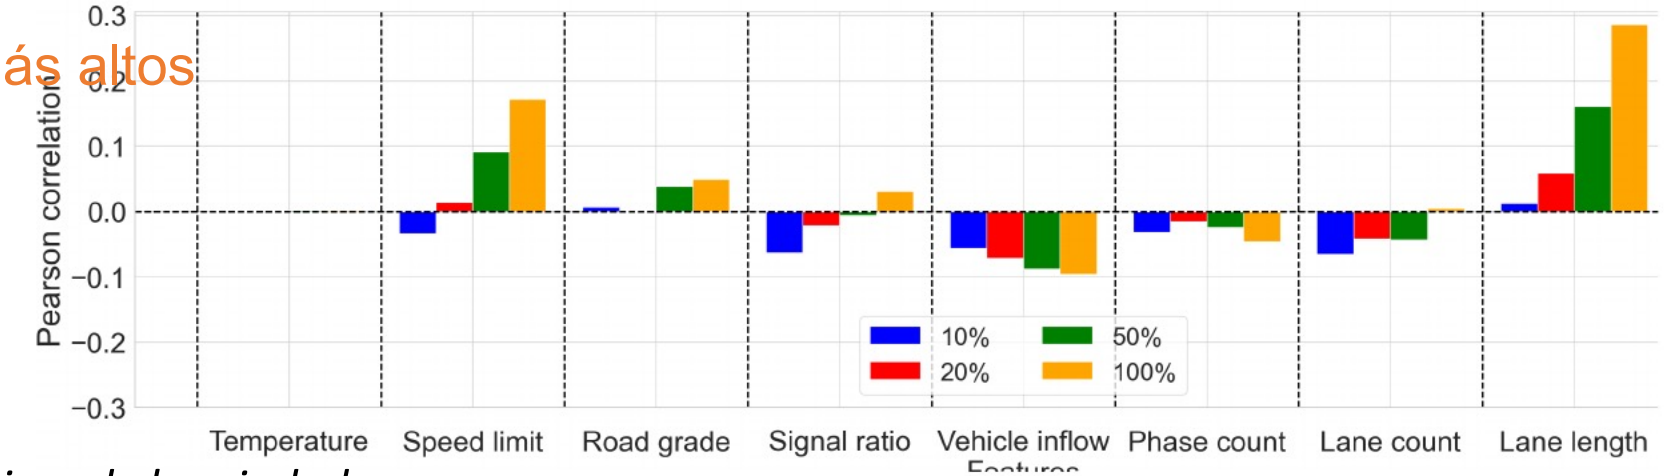
Wu

¿Por qué Atlanta se beneficia más que San Francisco?

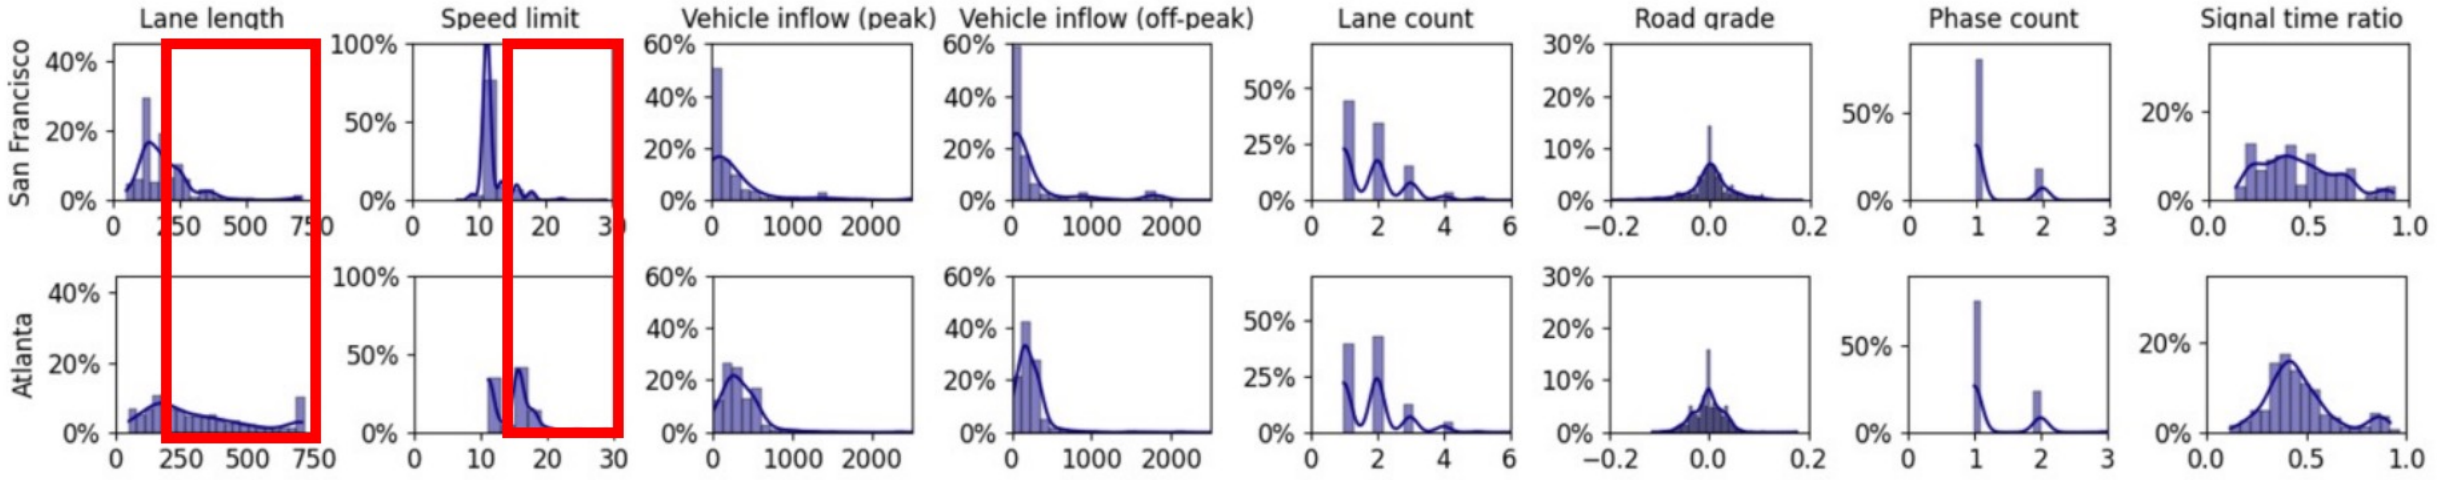
Atlanta vs. San Francisco
§ Carriles más largos
§ Límites de velocidad más altos

Son los dos factores **más correlacionados** con los beneficios de **la conducción eficiente**

Correlación de Pearson entre beneficios de la conducción eficiente y factores



Distribución de las características de las ciudades



V. Jayawardana, et al., C. Wu , "Mitigating Metropolitan Carbon Emissions with Dynamic Eco-driving at Scale," Transportation Research Part C: Emerging Technologies , 2025.

Cálculo global del impacto de la conducción eficiente

Sitio web

Impacto en la conducción

51.9%
x [11, 22]%
[5.7, 11.4]%

Km recorridos (VMT) cerca de cruces con semáforo [1]

Emisiones evitables con conducción eficiente

de las emisiones de CO_2 de la conducción simplemente se «desperdician» en los cruces

Impacto nacional

x 29%
x 81%
[1.3-2.7]%

GEI del sector del transporte [3]

↳ GEI de los vehículos de carretera [4]

de las emisiones de CO_2 de EE. UU. simplemente se «desperdician» en los cruces

Gold standard:
–1% global GHG
Breakthrough Energy Ventures
Led by Bill Gates

[1] U.S. Federal Highway Administration (FHWA). Highway Statistics 2021. 2023.
[2] Mintsis et al. Dynamic eco-driving near signalized intersections: Systematic review and future research directions . Journal of Transportation Engineering, Part A, 2020.
[3] U.S. Environmental Protection Agency, Inventory of U.S. greenhouse gas emissions and sinks . 2023.
[4] U.S. Environmental Protection Agency, Fast Facts on Transportation Greenhouse Gas Emissions . 2023.

* Cálculos basados en estadísticas de EE. UU.

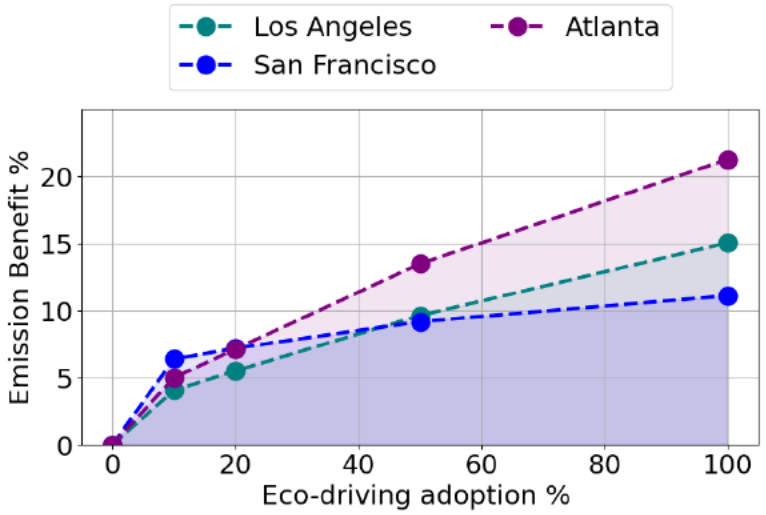
Resultados e implicaciones políticas

Impacto en las emisiones:
11-22 % de las emisiones de CO_2 en los cruces

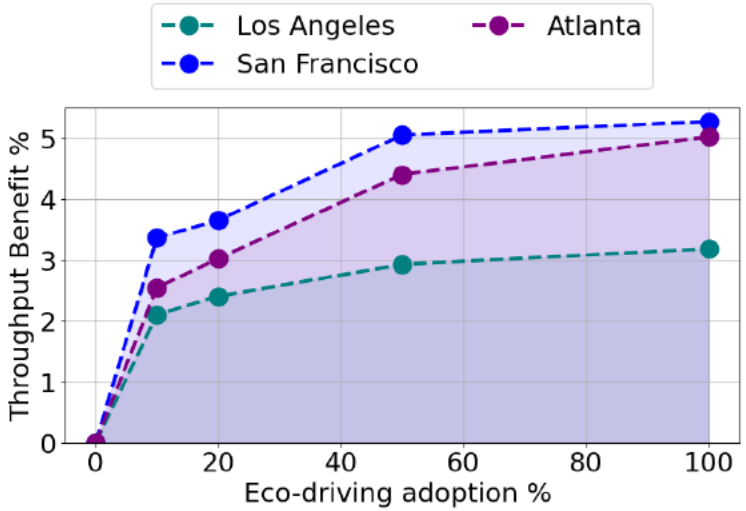
Potencial a corto plazo:
la mayor parte del impacto viene de una minoría de conductores y de cruces

Relevancia a largo plazo:
impacto robusto hasta 2050 por efectos de flota y demanda de viajes

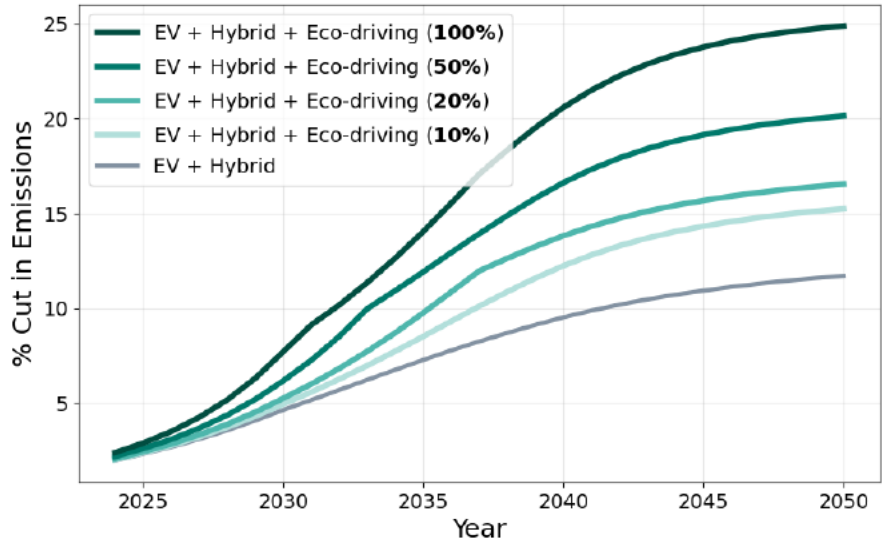
Reducción de emisiones



Aumento de capacidad



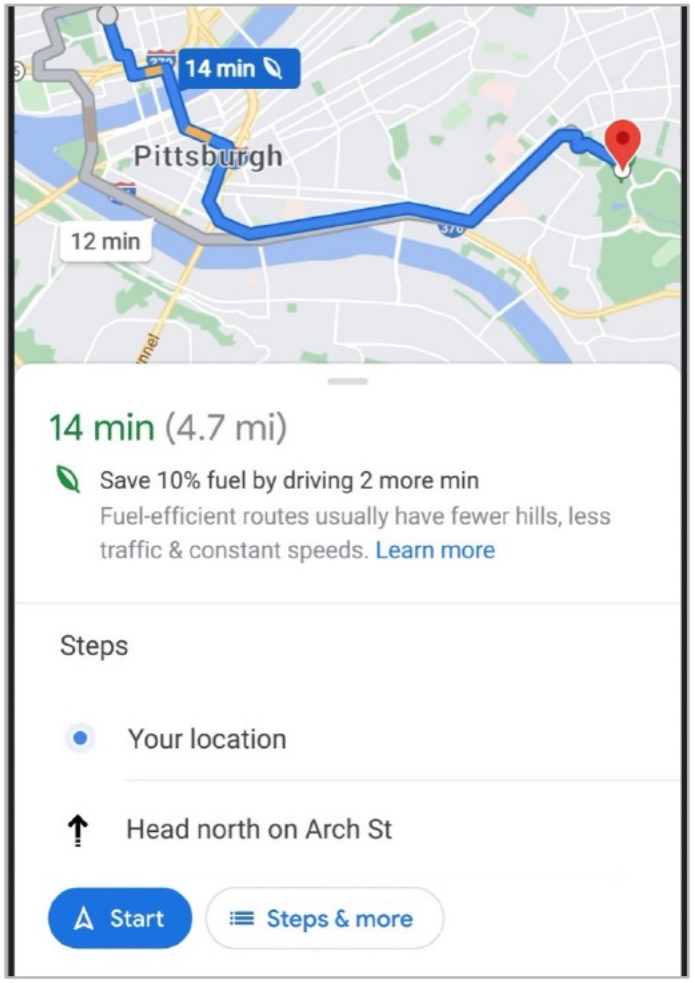
Proyección hasta 2050 (LA)



Gran impacto, coste relativamente bajo, y complementa las medidas climáticas existentes

V. Jayawardana et al. , “Mitigating Metropolitan Carbon Emissions with Dynamic Eco-driving at Scale,” Transportation Research Part C: Emerging Technologies, Apr. 2025.

Rutas ecológicas de Google Maps



Step 1

Simulate vehicle fuel efficiency across vehicle powertrains

NREL's **FASTSim** technology simulates fuel efficiency across various vehicle types and powertrains, incorporating second-by-second real-world driving data to calculate real-world fuel consumption over different road types and conditions with high accuracy.

Step 2

Predict fuel consumption across unique routes

NREL's **RouteE** is then trained by the FASTSim-calculated fuel consumption over different driving conditions to predict expected fuel consumption differences among a set of defined routes.

Step 3

Integrate Google's ML Routing Algorithm

Google integrates the insights and modeling from FASTSim and RouteE across all of Google Maps, incorporating Google's predicted traffic speeds with NREL's fuel consumption modeling to predict fuel consumption for all routes in the U.S., enabling a highly accurate model to maximize fuel efficiency.

Step 4

Set parameters to optimize journey time

Finally, we developed a set of parameters and time caps to determine the optimal time vs. fuel usage trade-off within Google Maps to avoid increasing travel time for negligible fuel savings. In this way, the vast majority of our recommended routes continue to be as fast as before.

[1] Google Research, "Google Maps Eco Friendly Routing," 2021.

ORION de UPS: optimización y navegación integradas en ruta

- Lanzado en 2013
- Elige rutas eficientes para los conductores según información en tiempo real (tráfico, tiempo, horas de recogida)
- Reducción estimada del consumo de combustible de 10 millones de galones al año, y de la producción de CO_2 de 100 000 toneladas (Informs)
- Uso de la IA
  - Predecir el rendimiento de las rutas
  - Recomendar rutas concretas a los conductores
- La IA es prometedora para la eficiencia de las mercancías cuando mejora *decisiones operativas repetidas: rutas, consolidación, asignación de cargas, reducción de km en vacío, programación de flotas y respuesta a interrupciones*

IA para abordar la larga cola de la optimización del transporte

Ejemplo: problemas de rutas de vehículos (VRP)

Uno de los problemas más estudiados en optimización combinatoria:

- ≈10 000 trabajos publicados solo en 2025 (Google Scholar), sobre todo heurísticas
- Aplicación directa en sistemas reales que distribuyen bienes y prestan servicios
- Reparto de última milla, recogida de residuos, servicio técnico, viajes compartidos, transporte a demanda



~10 000

artículos en 2025

11 billones $+

costes logísticos mundiales, 2023

65 M+

paquetes entregados / día en EE. UU.

Dantzig, G. B., & Ramser, J. H. "The Truck Dispatching Problem." Management Science, 1959.
Estadísticas: Statista/Research & Markets (2024); informe de paquetería ShipMatrix de EE. UU. (2024).

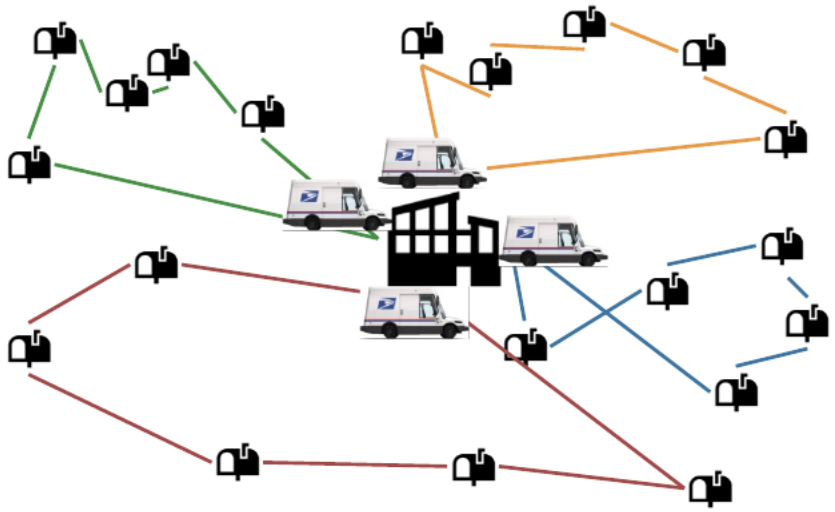
La larga cola de problemas de optimización del transporte

Definición: problemas de rutas de vehículos (VRP)

Dados

- Depósito
- N clientes (ubicación, demanda)
- Flota de vehículos (capacidad)
- … Otras restricciones …

Hallar el conjunto de rutas de menor coste que satisfaga a todos los clientes



Dimensiones clásicas

- Capacidad de los vehículos
- Ventanas horarias
- Flotas heterogéneas
- Múltiples depósitos
- Recogida y entrega, carga de retorno
- Entrega fraccionada
- Rutas por arcos (p. ej. recogida de basura)

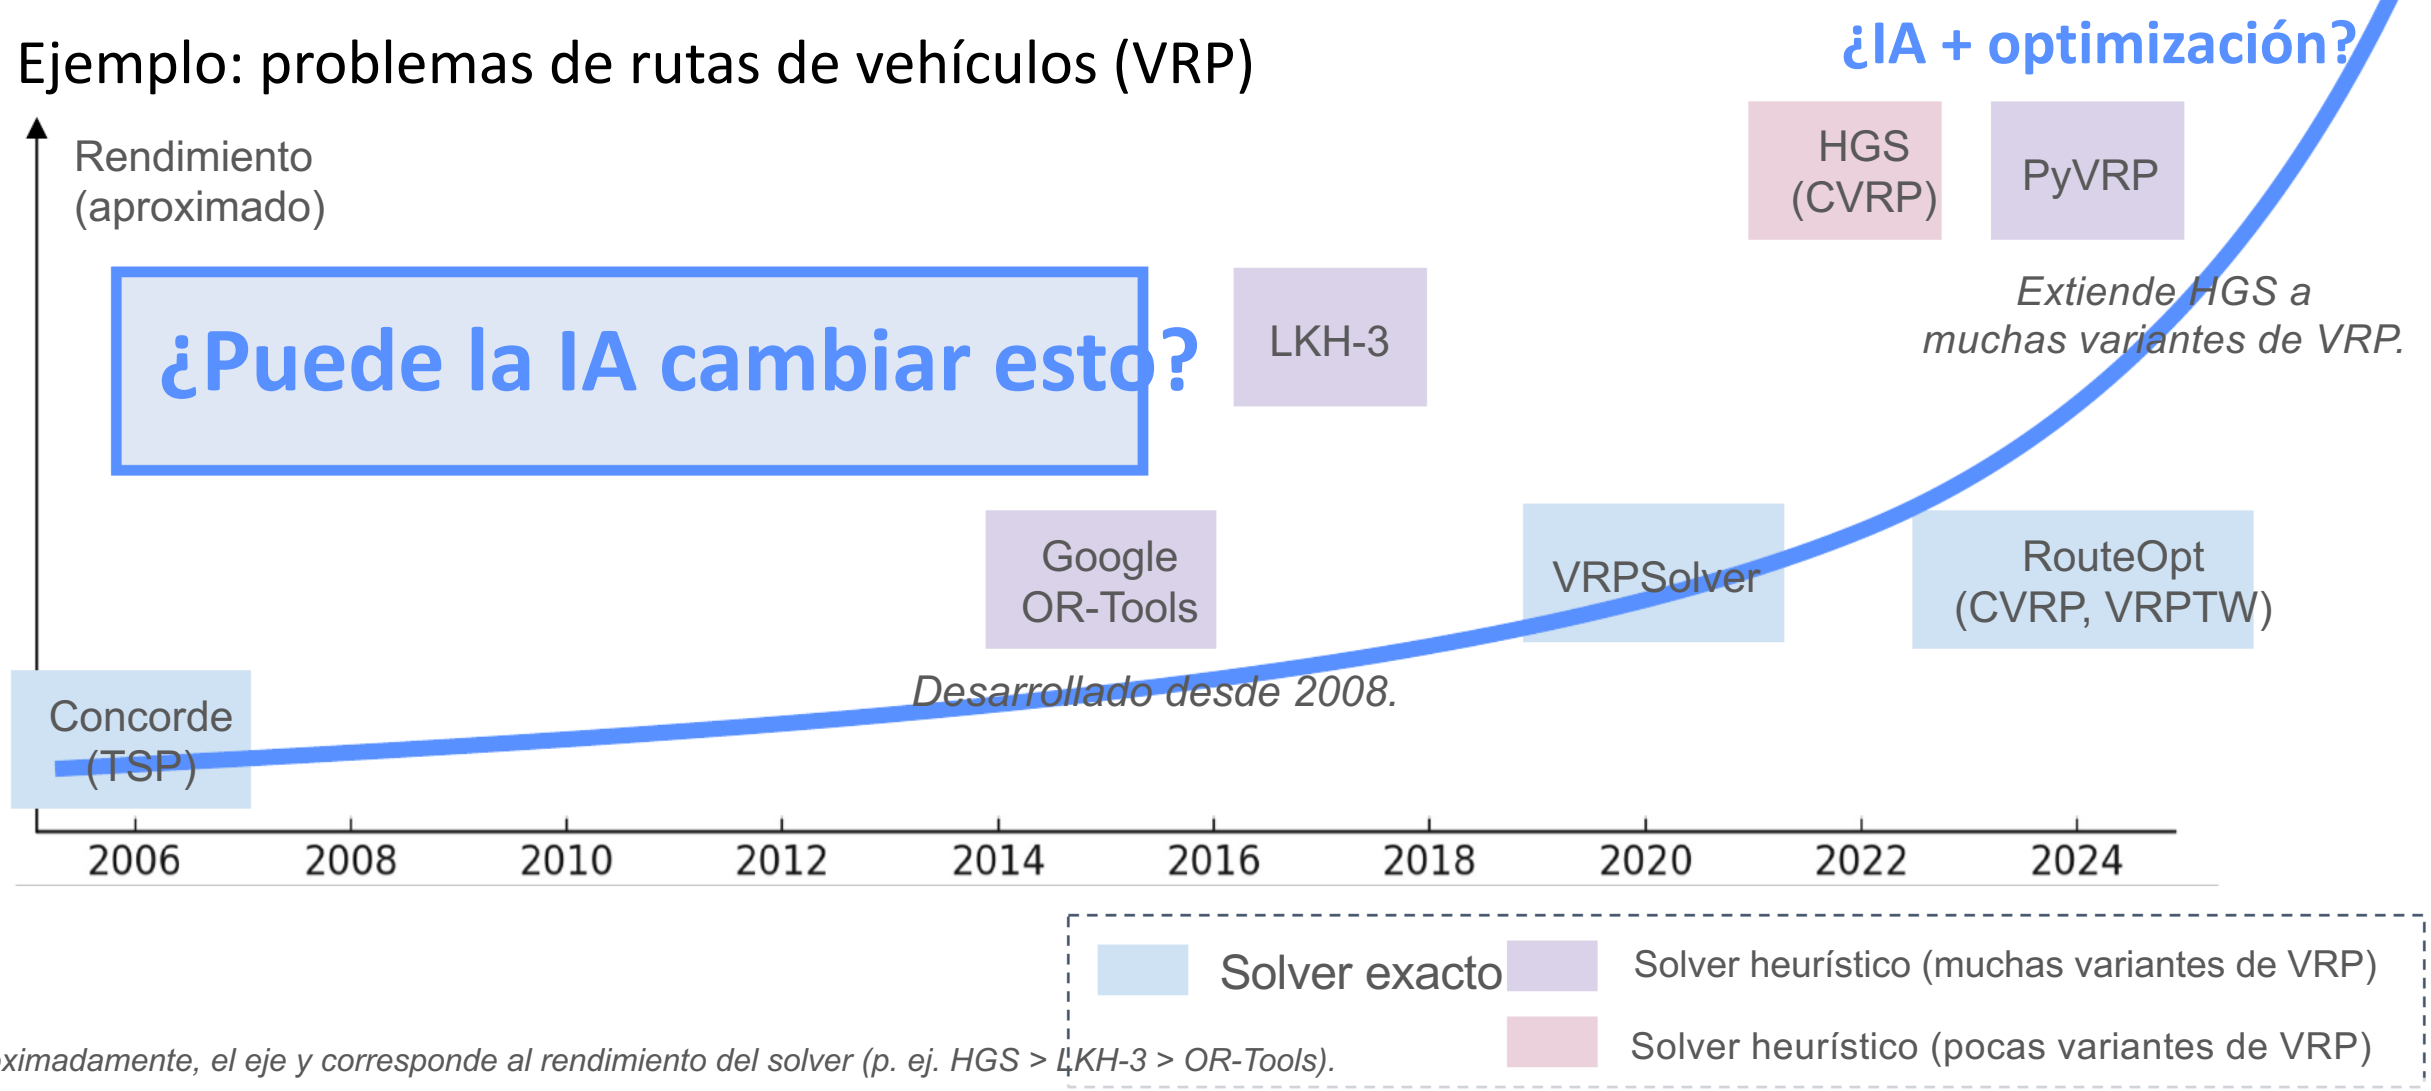
Variantes emergentes

- Rutas de vehículos eléctricos (decisiones de carga)
- Rutas de drones (3D, límites de autonomía)
- Rutas en almacenes (preparadores, clasificación)
- Logística multimodal (camión + dron, tren + camión)

Laporte, G. “Fifty Years of Vehicle Routing.” Transportation Science, 2009.
Dantzig, G. B., & Ramser, J. H. “The Truck Dispatching Problem.” Management Science, 1959.

Resolver la larga cola es lento y laborioso

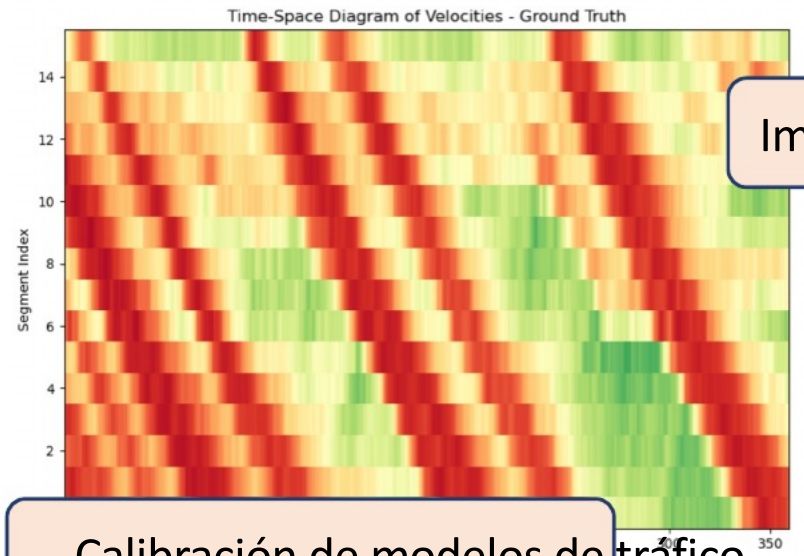
Ejemplo: problemas de rutas de vehículos (VRP)



*Aproximadamente, el eje y corresponde al rendimiento del solver (p. ej. HGS > LKH-3 > OR-Tools).

Laporte, G. “Fifty Years of Vehicle Routing.” Transportation Science, 2009.
Dantzig, G. B., & Ramser, J. H. “The Truck Dispatching Problem.” Management Science, 1959.

La larga cola de la optimización es transversal

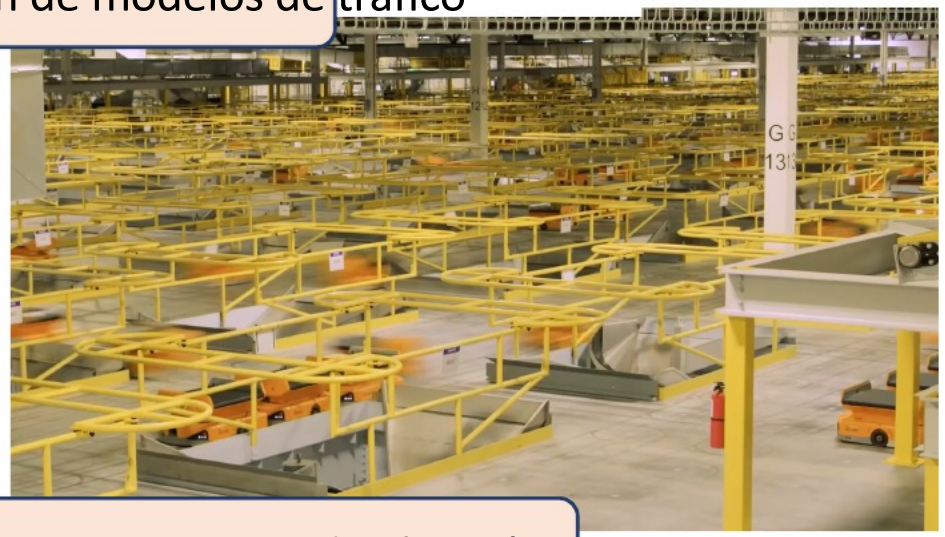


Calibración de modelos de tráfico

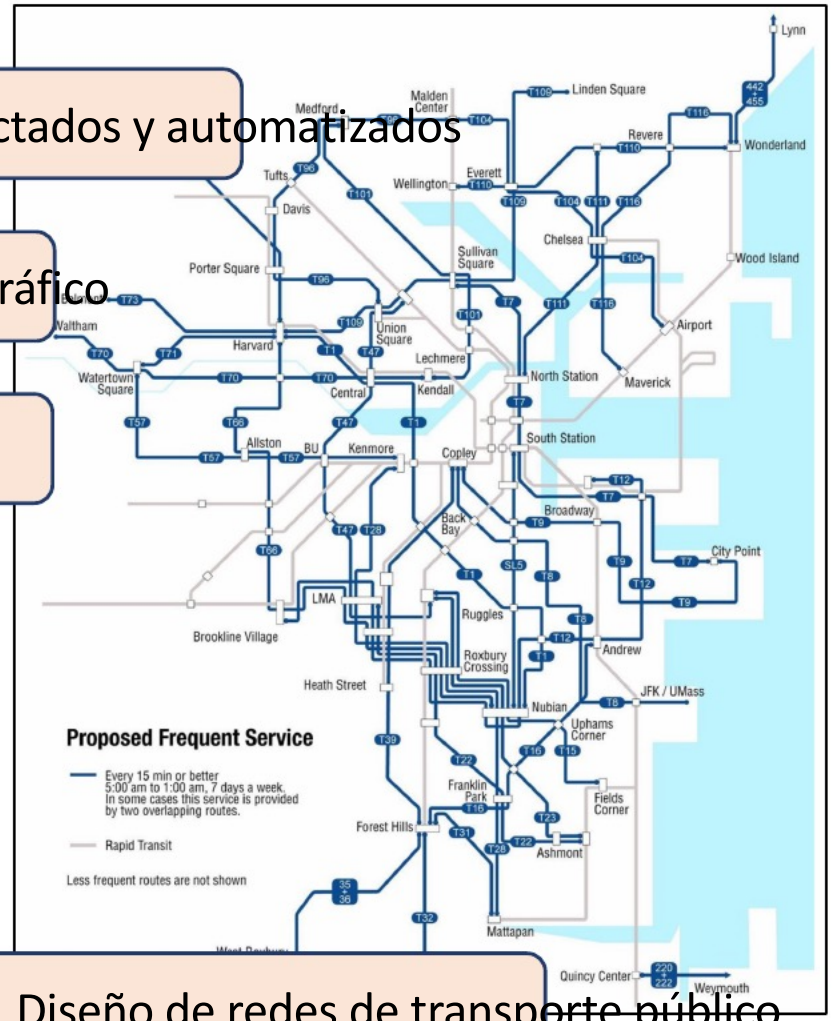
Impactos de los vehículos conectados y automatizados

Asignación dinámica del tráfico

Optimización de redes

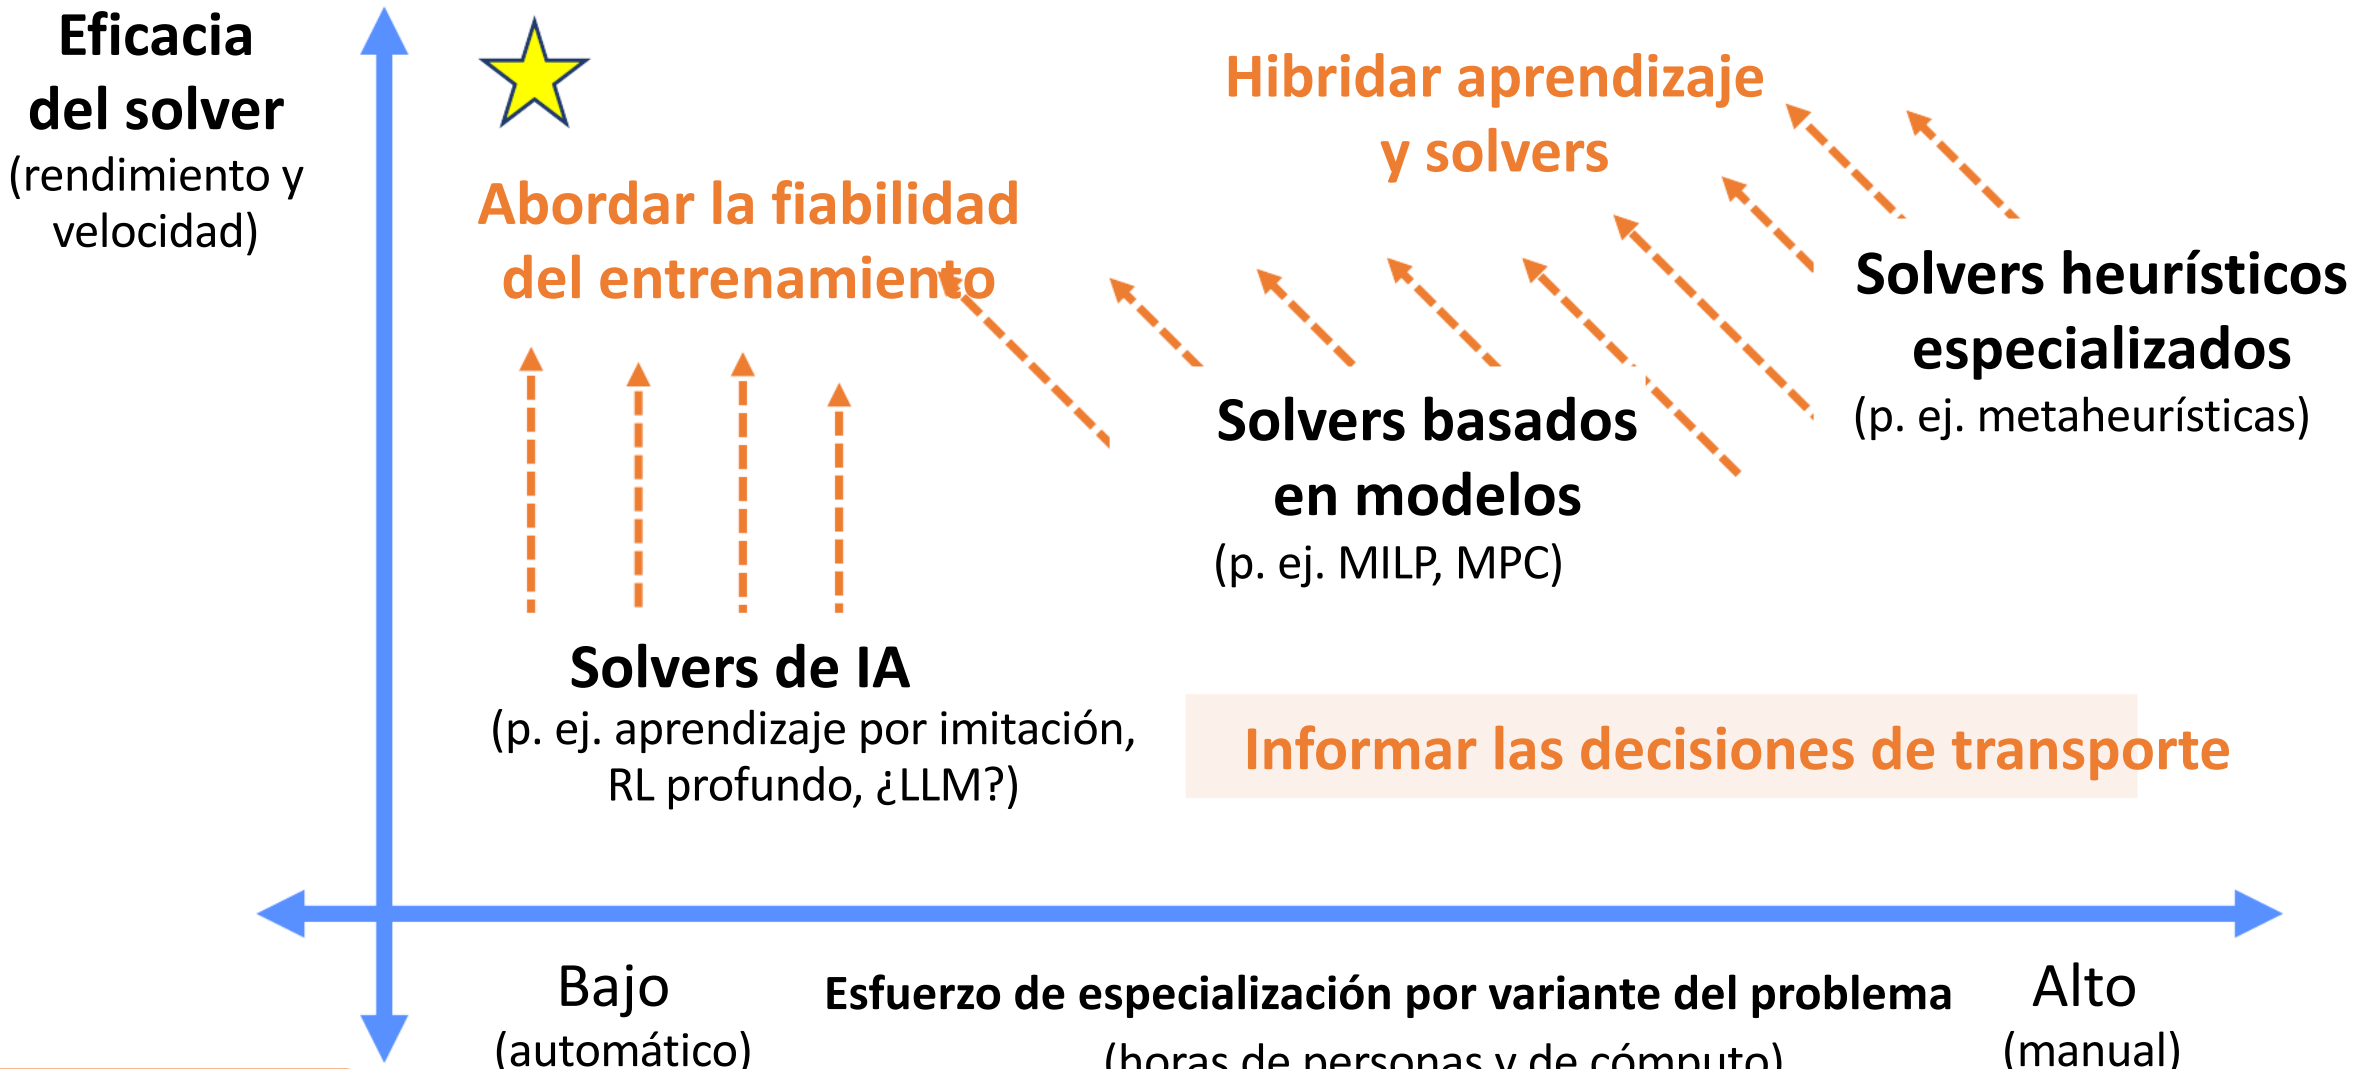


Operaciones de almacén



Diseño de redes de transporte público

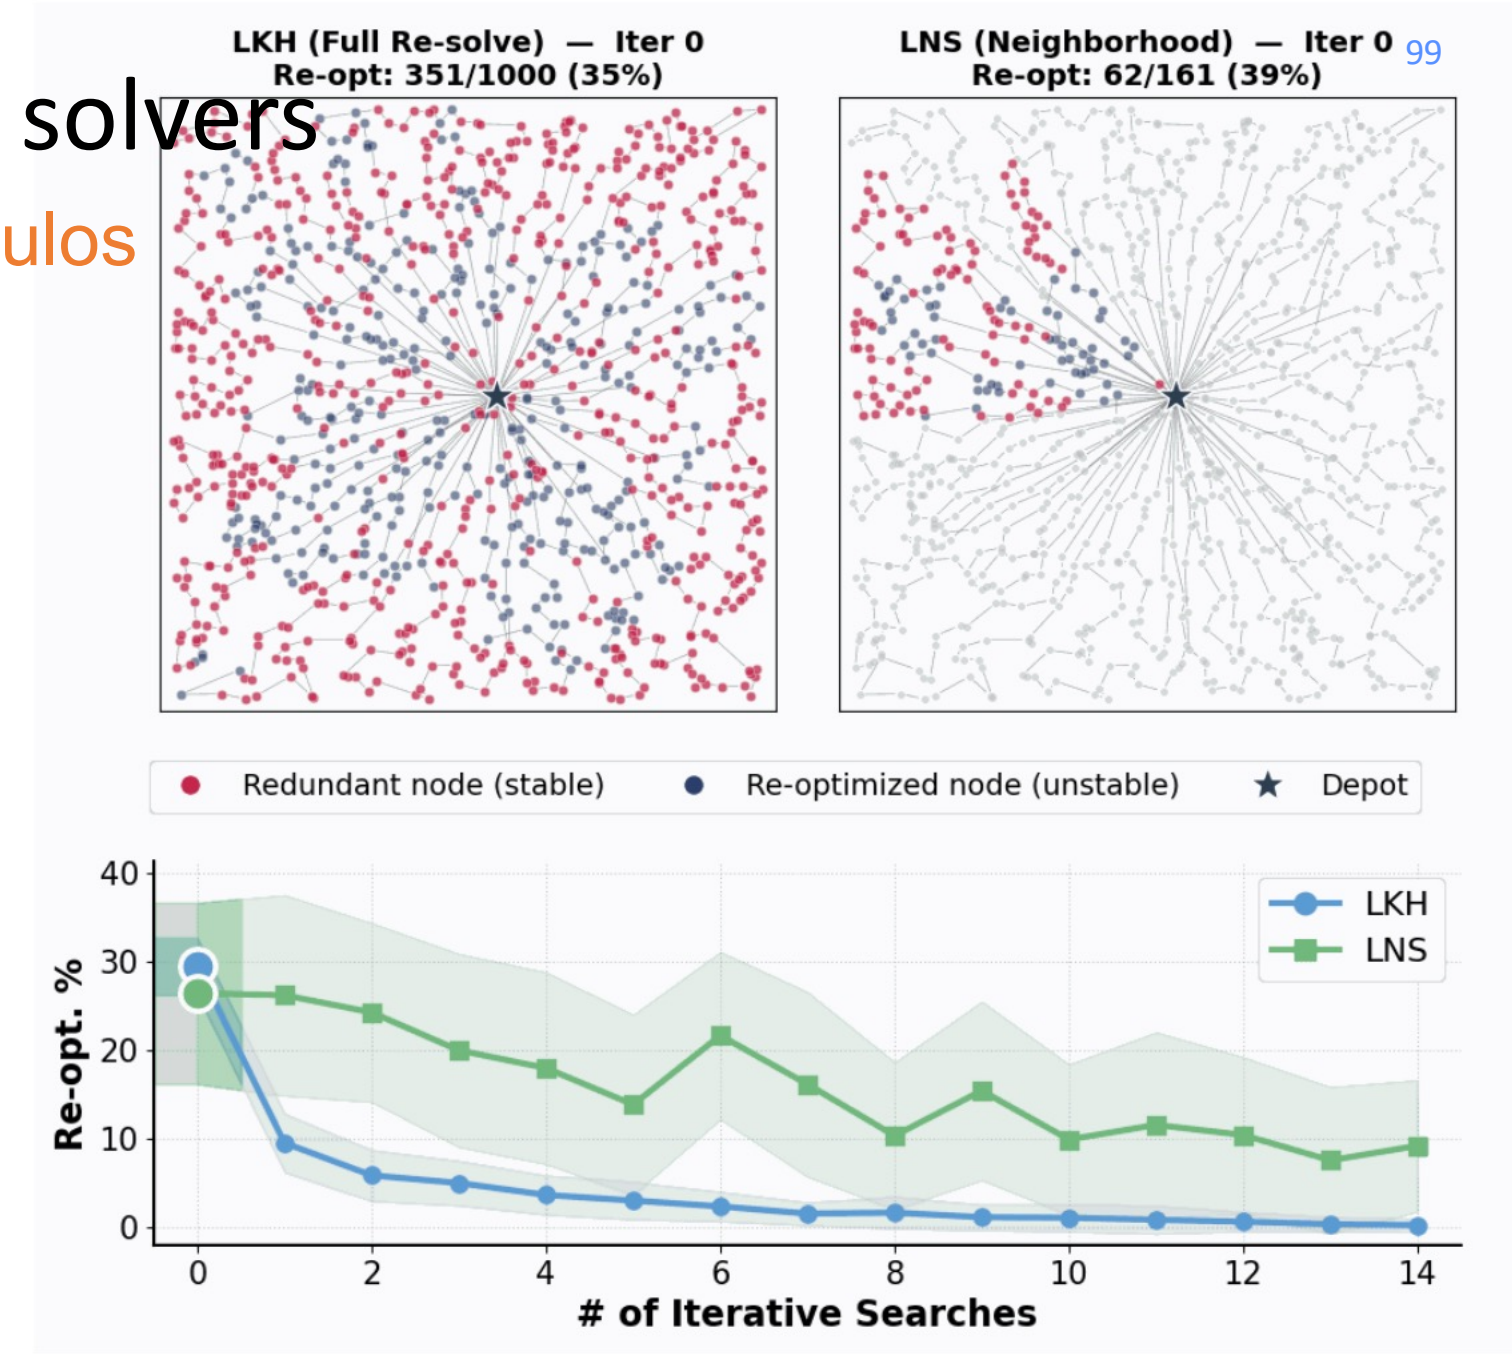
Panorama de los solvers de optimización



Mi laboratorio

Redundancia de los solvers

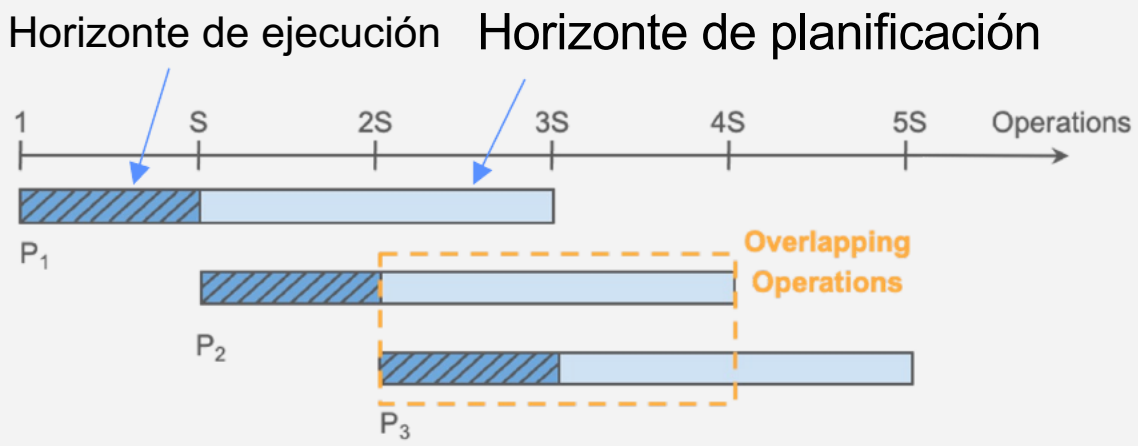
§ Ejemplo: rutas de vehículos
(solvers: LKH, LNS + LKH)



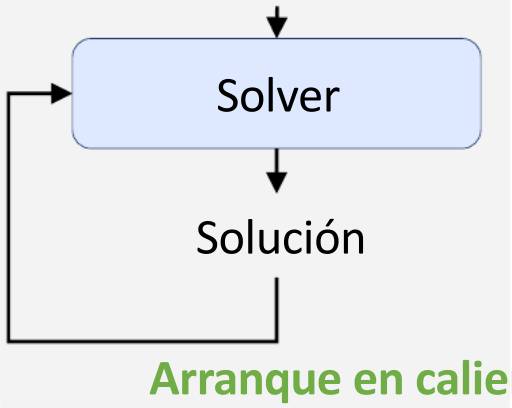
W. Ouyang, S. Li, Y. Ma, and C. Wu, "Learning to Segment for Vehicle Routing Problems," International Conference on Learning Representations (ICLR), 2026. Oral (1%).

Aprender a reutilizar: evitar cálculos redundantes

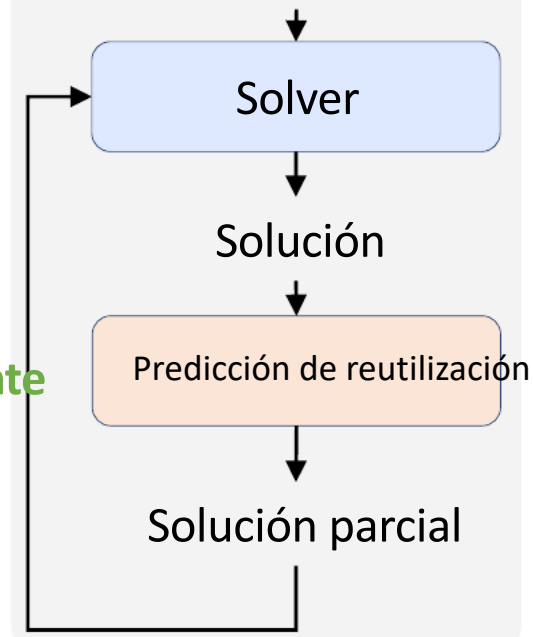
Contexto: optimización con horizonte rodante (RHO)



RHO con arranque en caliente



L-RHO (nuestro)



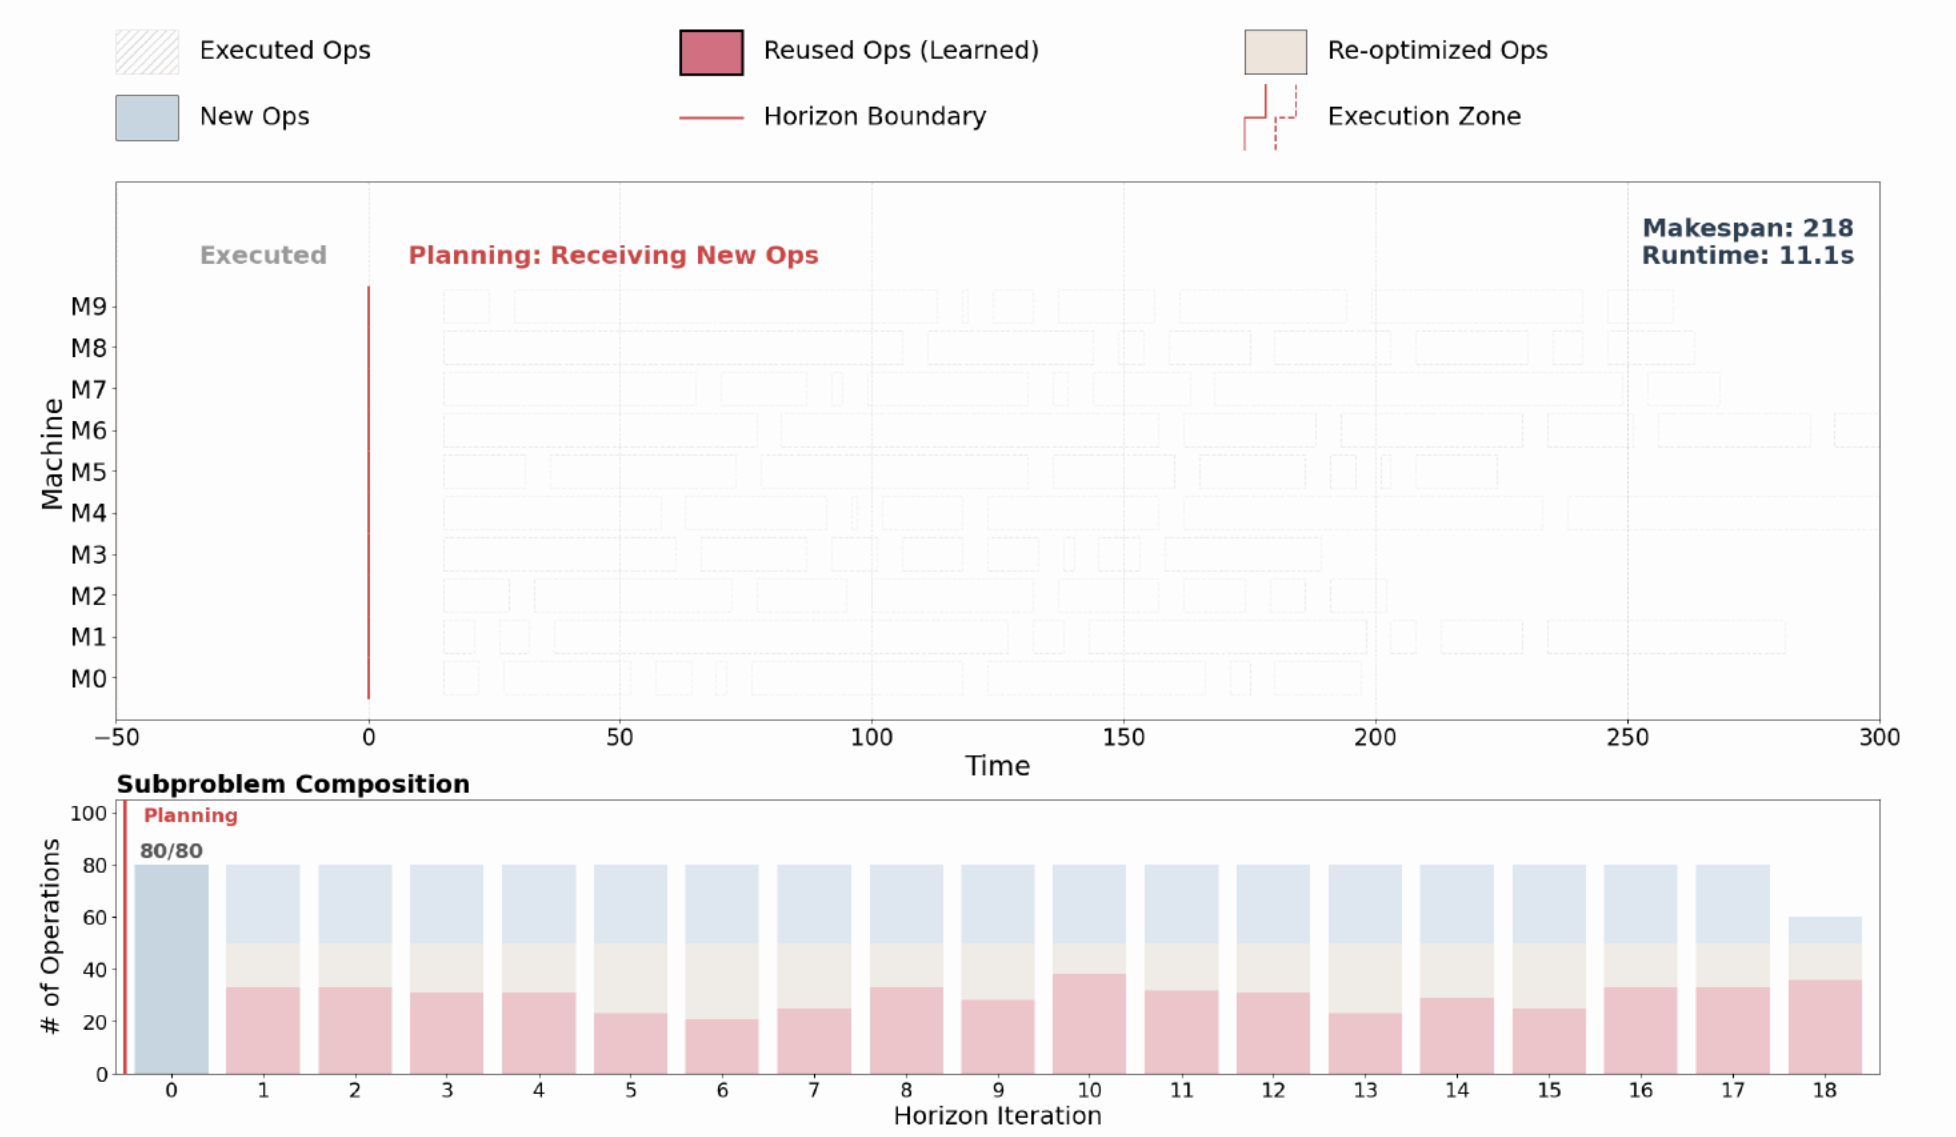
L-RHO: hasta un 50 % más rápido al aprender a reutilizar soluciones en subproblemas RHO consecutivos [1]

§ Método: entrenar una red neuronal profunda para predecir si una variable de la solución cambiará de un subproblema al siguiente

§ Etiquetas de entrenamiento: oráculo con anticipación

S. Li, W. Ouyang, Y. Ma, and C. Wu , "Learning-Guided Rolling Horizon Optimization for Long-Horizon Flexible Job Shop Scheduling," in ICLR, 2025.

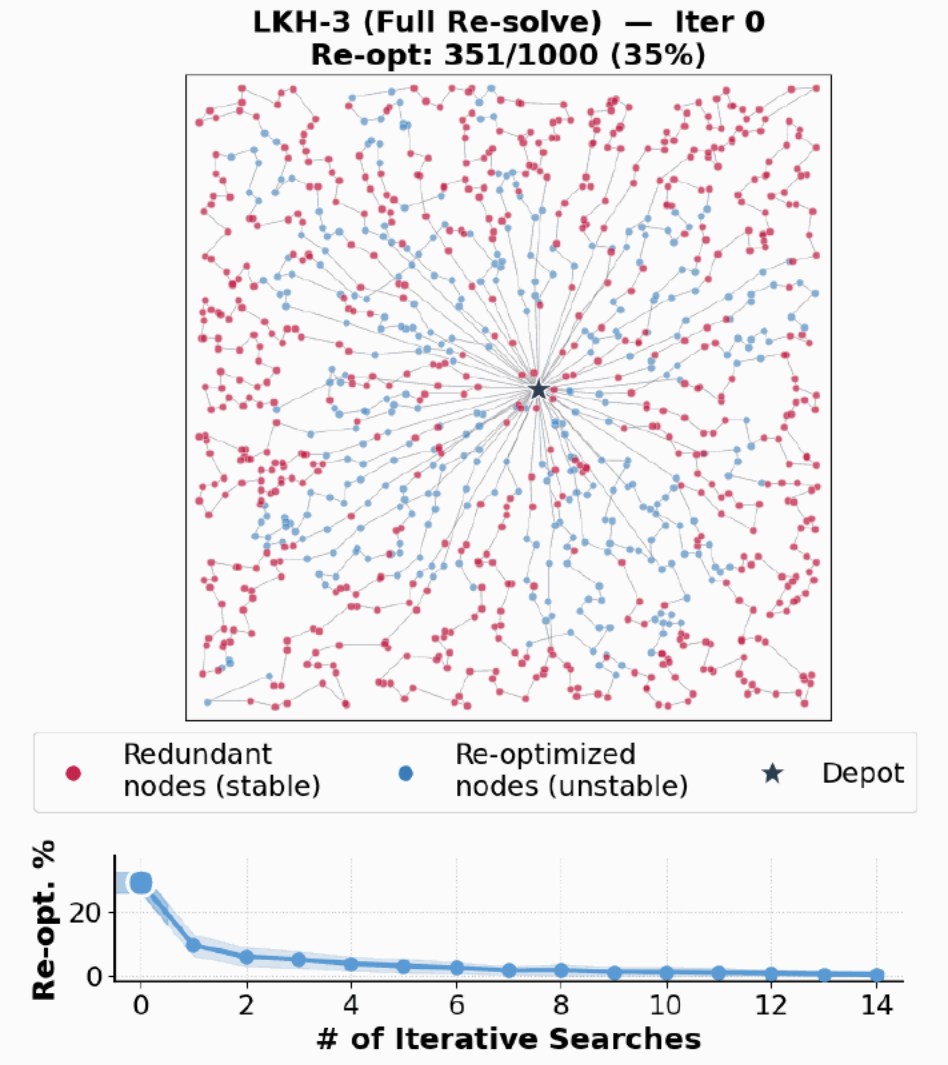
L-RHO para la programación flexible de talleres (job shop)



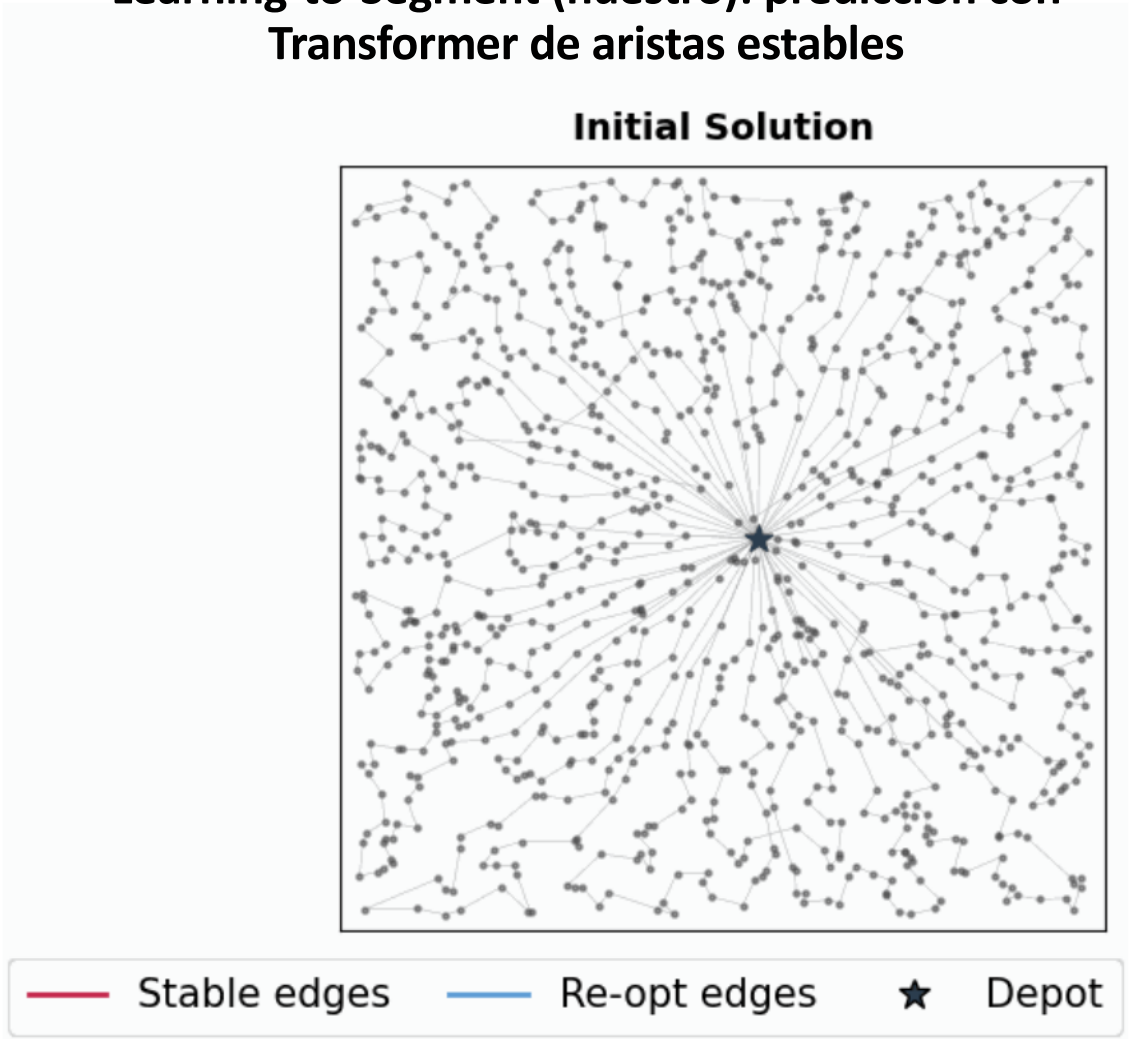
S. Li, W. Ouyang, Y. Ma, and C. Wu , “Learning-Guided Rolling Horizon Optimization for Long-Horizon Flexible Job Shop Scheduling,” in ICLR, 2025.

Aprender a reutilizar en grandes problemas de rutas

Solver de vanguardia LKH (metaheurística)



Learning-to-Segment (nuestro): predicción con Transformer de aristas estables



Resultados: 7 veces más rápido en CVRP con 2000 clientes

W. Ouyang, S. Li, Y. Ma, and C. Wu , "Learning to Segment for Vehicle Routing Problems," International Conference on Learning Representations (ICLR), 2026. Oral (1%) .

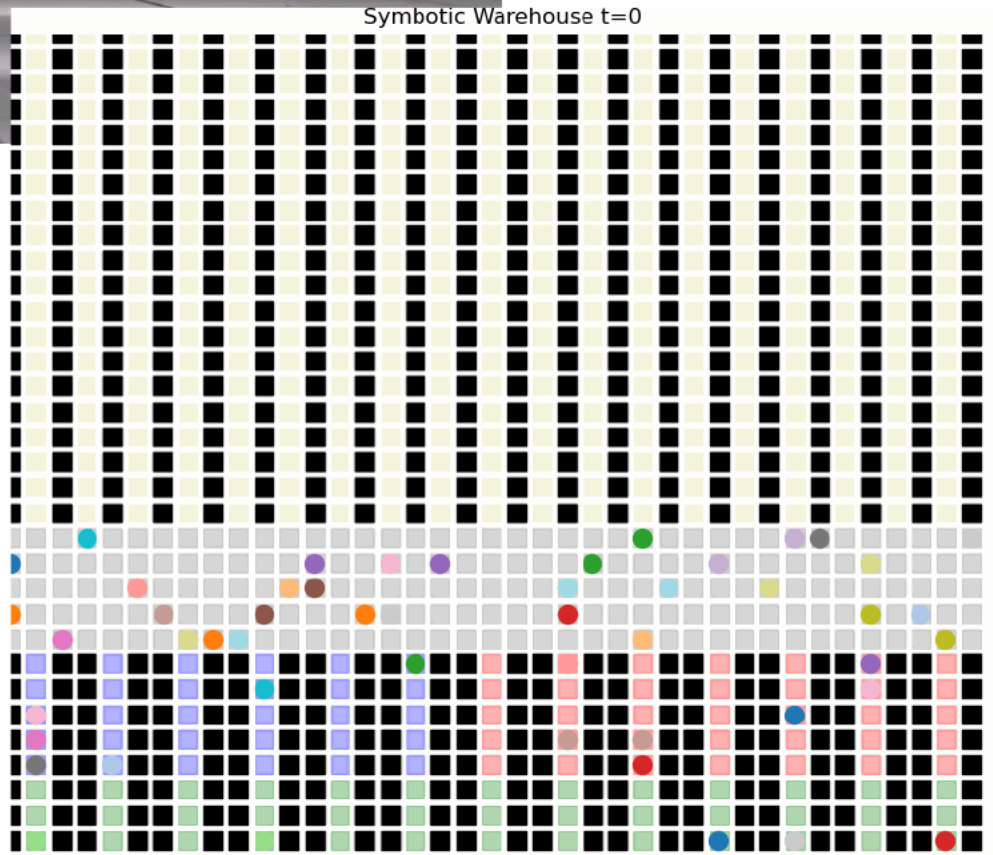
Mitigar la congestión en almacenes automatizados

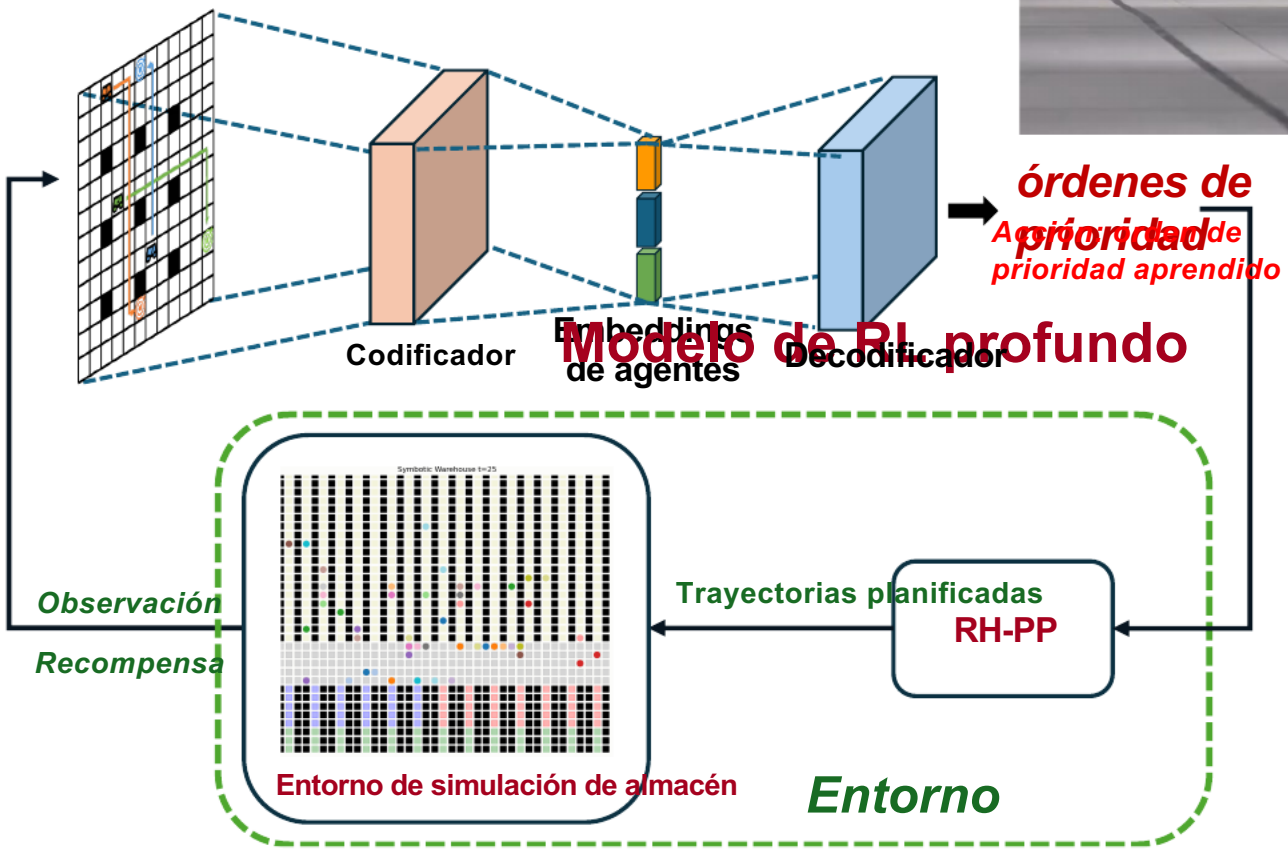
§ Aprender el orden de prioridad de los agentes

§ Método: planificación priorizada guiada por RL profundo

§ Resultados: +20 % de capacidad en **almacenes tipo Symbotic**





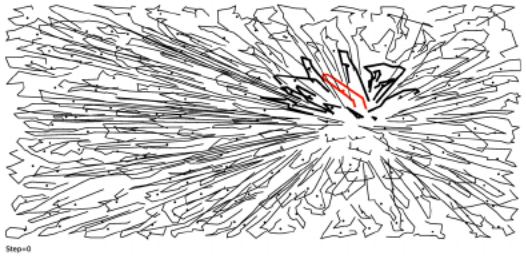


H. Zheng, Y. Ma, B. Araki, J. Chen, and C. Wu , "Learning-guided Prioritized Planning for Lifelong Multi-Agent Path Finding in Warehouse Automation," Journal of Artificial Intelligence Research (JAIR) , 2026.

Optimización combinatoria guiada por aprendizaje

Contribución: el aprendizaje profundo puede acelerar los solvers de optimización combinatoria de 2 a 10 veces.

Aprender a enfocar y priorizar la búsqueda



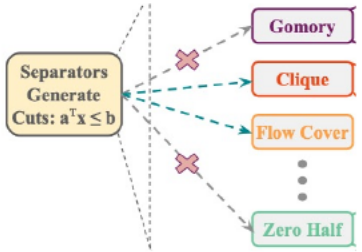
NeurIPS21 Spotlight (<3%)



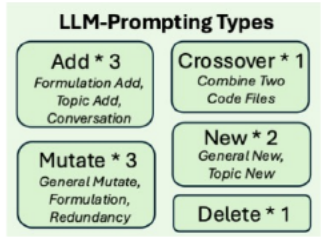
ICLR24

JAIR26

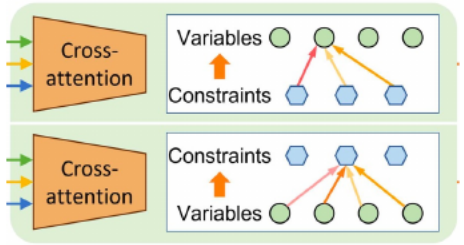
Aprendizaje para programación lineal entera mixta



NeurIPS23



ICLR25

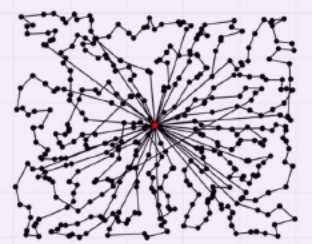


ICML26

Aprender a reutilizar entre iteraciones

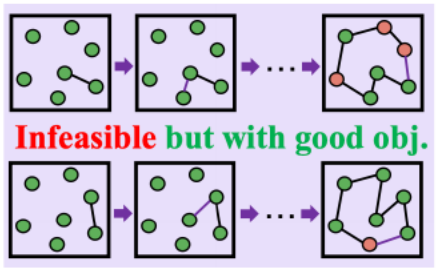


ICLR25



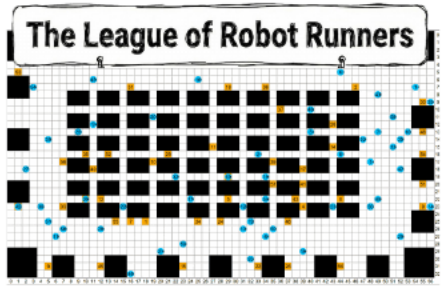
ICLR26 Oral (1%)

Aprender a reparar soluciones

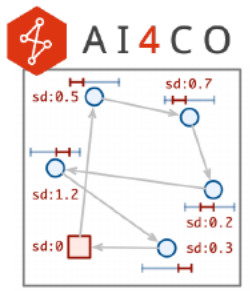


ICLR26

Benchmarks y competiciones



ICAPS24

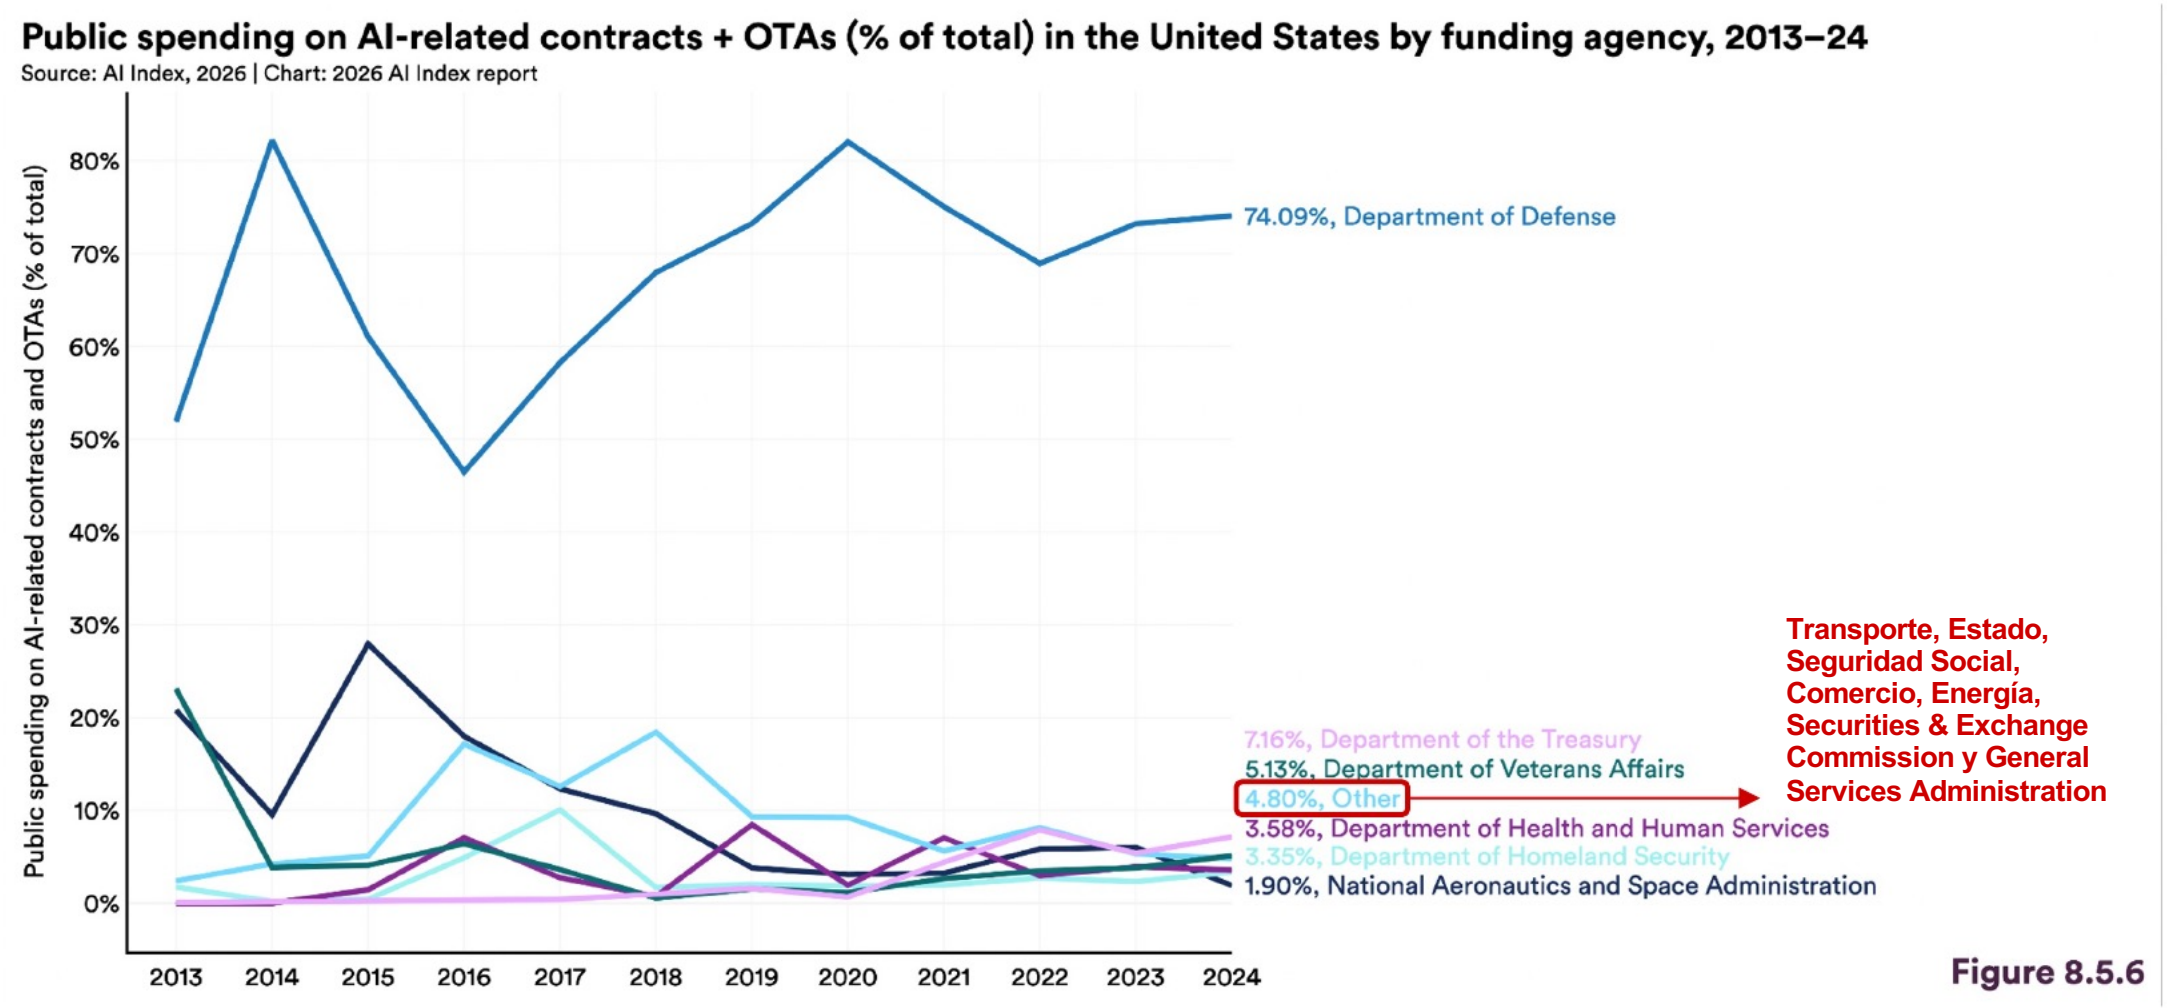


KDD25 Oral (9%)

Datos y cómputo modestos (1000 instancias, 1 día en V100) ; bastante generalizable.

Reflexiones finales

La IA en el transporte está en sus inicios



[1] S. Sha et al., “The AI index 2026 annual report,” in The AI index 2026 annual report, 2026. [Online]. Available: https://hai.stanford.edu/ai-index/2026-ai-index-report

Síntesis de consideraciones clave

- Teoría del cambio para descarbonizar el transporte
  - La descarbonización del transporte carece de un impulsor económico central
  - El éxito requiere una amplia coalición de actores con prioridades alineadas con el clima
    - China → política industrial → seguridad energética → electrificación
    - Clase trabajadora y media → votos → coste y comodidad → cambio modal
    - Empresas → operaciones → coste → mejoras de eficiencia
  - Piense: ¿qué acciones climáticas coinciden con las muchas prioridades del transporte?
    - Ejemplo personal: Utah → regular la conducción → calidad del aire → conducción eficiente
- ¿Cuándo es útil la IA?
  - La IA puede 1) construir modelos de procesos de transporte basados en datos, 2) optimizar modelos para hallar buenas soluciones, 3) automatizar flujos digitales, 4) permitir la automatización robótica
    - Lo más difícil suele ser averiguar cuándo uno de ellos es un cuello de botella clave y cómo se integra con el resto de la solución/sistema

Puntos de entrada y próximos pasos

Participe: transporte sostenible

- Bridging Transportation Researchers (BTR)
  - Congreso de investigación en transporte cero carbono, coste cero (virtual, 12-13 de agosto)
- National Association of City Transportation Officials (NACTO)
  - Asociación de ciudades y organismos de transporte norteamericanos que impulsa la seguridad, la sostenibilidad, el acceso y la equidad en las ciudades
  - Congreso Designing Cities (próxima edición: Nashville, mayo de 2027)
- Transportation Research Part D: Transport and Environment
  - Revista de referencia sobre los impactos ambientales del transporte, las respuestas políticas y sus implicaciones para el diseño, la planificación y la gestión de los sistemas de transporte
- Transportation Research Board (TRB) Annual Meeting
  - El TRB forma parte de las National Academies of Sciences, Engineering, and Medicine
  - Ecosistema profesional central en Norteamérica (Washington DC, cada enero)
  - Standing Committee on Transportation Energy Data and Analysis (AED18) (reunión anterior)
    - Enfoque: investigación e innovación en datos y métodos analíticos para medir el uso de energía, el consumo de combustible y la eficiencia de los sistemas de transporte.



Participe: IA + transporte

- Transportation Research Part C: Emerging Technologies
  - Revista de referencia sobre desarrollo, aplicaciones e implicaciones en sistemas de transporte y tecnologías emergentes
- IEEE Transactions on Intelligent Transportation Systems
  - Revista de referencia sobre investigación básica y aplicada en todos los aspectos científicos y técnicos de los sistemas de transporte modernos
- Transportation Research Board (TRB) Annual Meeting
  - Ecosistema profesional central en Norteamérica (Washington DC, cada enero)
- IEEE International Conference on Intelligent Transportation Systems (ITSC) (próxima edición: Nápoles, Italia, 15-18 de sept.)
  - El principal congreso de IA/SIT del campo





Awesome RERITE: Una lista seleccionada de conjuntos de datos y benchmarks abiertos para la investigación en transporte

https://www.rerite.org/awesome-rerite

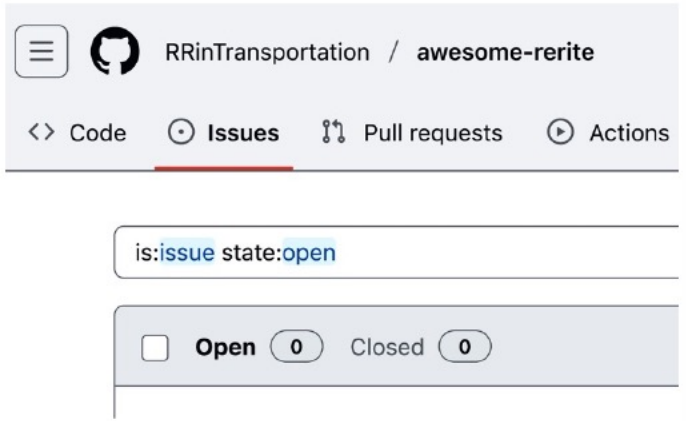
Tooling & Workflows

- **Global Urban Street Networks** — updated and published repository containing street network models for all 10,351 urban areas worldwide (GraphML, GeoPackages, and node/edge lists), plus indicators and metadata. Journal article: https://doi.org/10.1177/23998083261446991. Source code: https://github.com/gboeing/street-network-models.
- **OSMnx** — award-winning toolkit by Geoff Boeing for downloading, modeling, and analyzing street networks.
- **osm2gmns** — converts OpenStreetMap data into GMNS format; developed by Jiawei Lu and Xuesong (Simon) Zhou.
- **DTALite** — ASU Transportation AI Lab's macroscopic/mesoscopic AMS library that natively reads GMNS.
- **DTA** — Dr. Ke Han's open-source dynamic user equilibrium solver (see Networks and Spatial Economics, 2019).
- **OSRM** — C++14 routing engine providing lightning-fast shortest path queries.

¿Tiene más recursos para compartir? ¡Es fácil!

¡Queremos promover y compartir más con la comunidad!

Abra un issue en la página de GitHub o escríbanos



Explorador de ciencia abierta para la investigación en transporte



Convocatoria de interés: número especial sobre evaluaciones y conjuntos de datos de transporte (TR Part C y T-ITS)

Call for Interest: Transportation Evaluations & Datasets

RERITE is excited to announce a new initiative: In preparation for a Special Issue on "**Evaluations & Datasets for Transportation Research**", please let us know your evaluations & datasets **needs and wish list**. The special issue will be published with Transportation Research: Part C (TRC) and/or IEEE Transactions on Intelligent Transportation Systems (T-ITS).

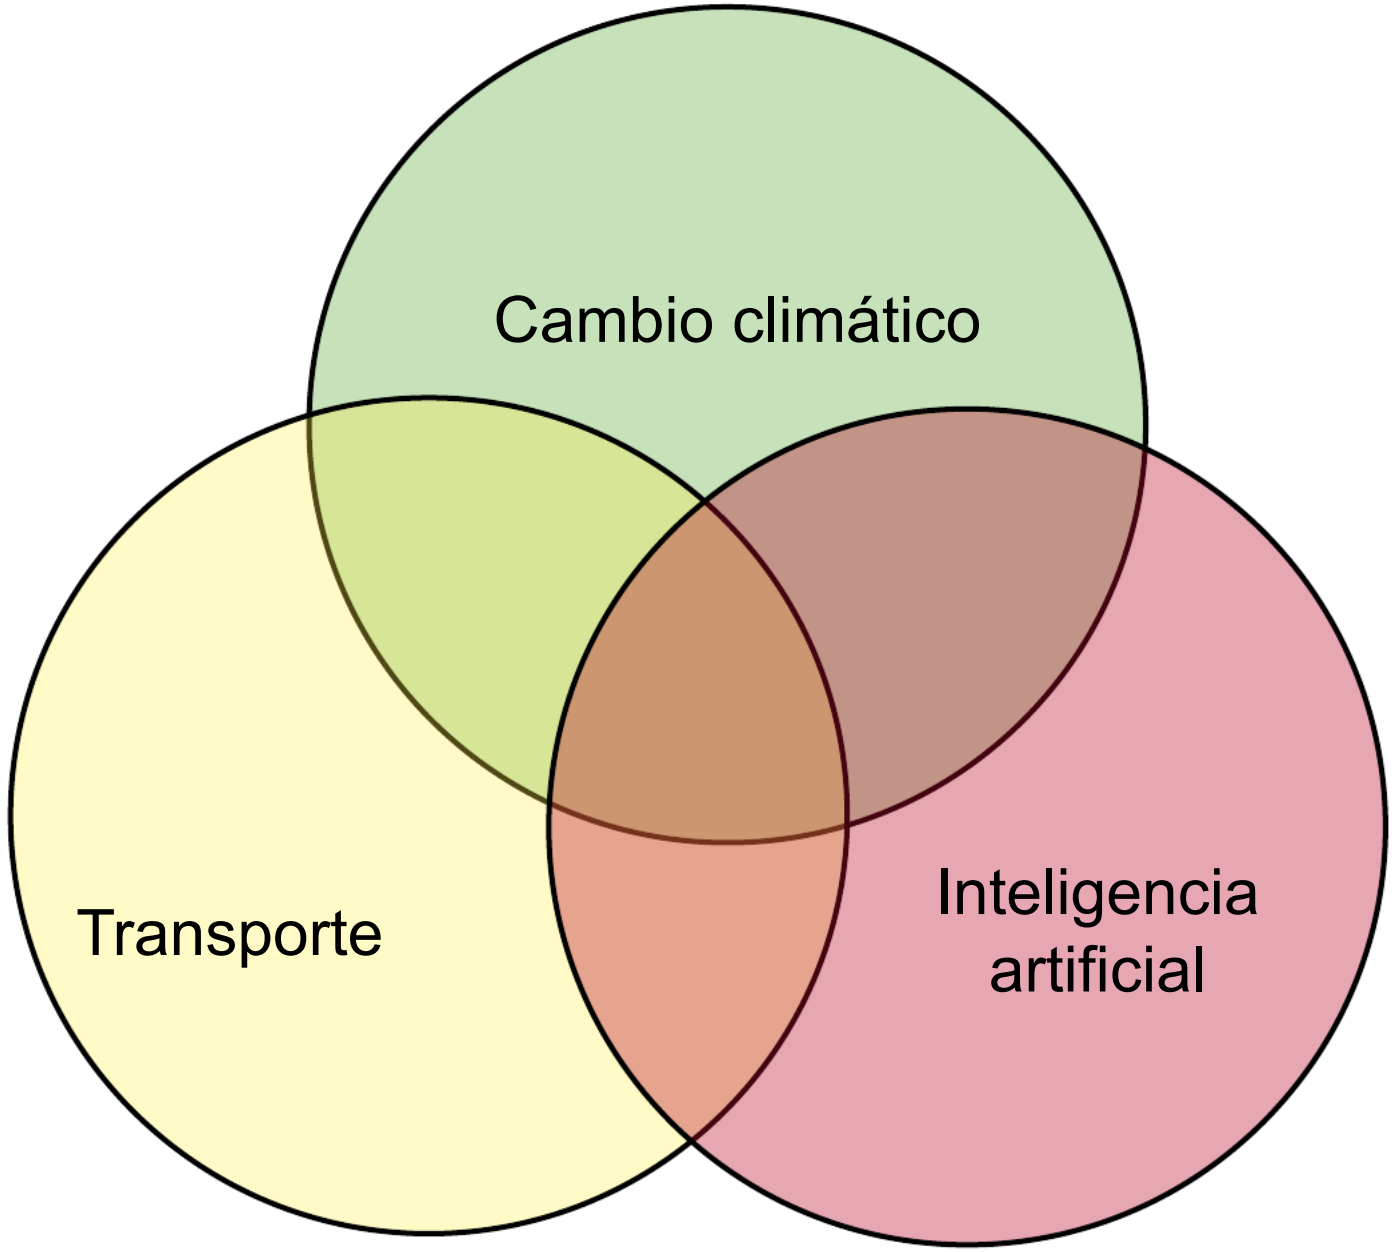
You are welcome to fill out the form as many times as you have wishes. Please include as much context as you can; the more context you provide, the more effectively we will be able to scope and target the special issue.

Do not worry about whether someone else will submit the same topic. The more a topic is expressed as a need, the more we can understand the needs of the community!

This initiative is modeled after the NeurIPS 2026 Evaluations & Datasets Track Call for Papers.

RERITE

rerite.org


Cambio climático
Transporte
Inteligencia artificial

Anexo

Temas adicionales

- IA para la mitigación en la aviación comercial
  - Sandalow, David B. et al., “Artificial Intelligence for Climate Change Mitigation Roadmap (Second Edition),” (Chapter 7: Commercial Aviation), Nov. 2024, doi: 10.7916/2J4P-NW61 .
- IA para la mitigación en el transporte marítimo
  - World Economic Forum, “Intelligent Transport, Greener Future: AI as a Catalyst to Decarbonize Global Logistics.” Jan. 2025. https://seminarleadership.ibo.pe/case-02/ .
- IA para la adaptación y la resiliencia del transporte
  - Costa, Miguel, et al. “Artificial Intelligence for Climate Adaptation: Reinforcement Learning for Climate Change-Resilient Transport.” arXiv, 2026. https://doi.org/10.48550/arXiv.2603.06278 .