GRADO EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE GRADO

Sistema de Gestión de Tráfico Adaptativo con IoT y Edge Computing

Autor: Álvaro Moraga Doménech

Director: Dr. de Curtò i Díaz, Joaquim

Madrid

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título

“Sistema de Gestión de Tráfico Adaptativo con IoT y Edge Computing”

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el

curso académico 2024/25 es de mi autoría, original e inédito y

no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido

tomada de otros documentos está debidamente referenciada.

Fdo.: Álvaro Moraga Fecha: …12…/ …06…/ …2025…

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

deCurto

J. de Curtò i Díaz

Digitally signed by J. de Curtò i Díaz
Date: 2025.06.11 11:39:48 +02'00'

Fdo.: Joaquim de Curtò i Díaz Fecha: …12…/ …06…/ …2025…

GRADO EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE GRADO

Sistema de Gestión de Tráfico Adaptativo con IoT y Edge Computing

Autor: Álvaro Moraga Doménech

Director: Dr. de Curtò i Díaz, Joaquim

Madrid

Agradecimientos

En primer lugar, quisiera expresar mi más sincero agradecimiento al Dr. Joaquim de Curtò i Díaz, director de este trabajo, por su brillante orientación, su implicación constante y sus valiosos consejos a lo largo de todo el proceso. Su guía ha sido fundamental para el desarrollo y la finalización de este proyecto.

Asimismo, agradezco al BARCELONA Supercomputing Center (BSC) por proponer este trabajo y por las facilidades ofrecidas, que han contribuido de manera significativa al desarrollo del mismo. Además, este trabajo fue desarrollado mientras me encontraba de intercambio durante un año académico en la Universidad de San Diego, USA. Lo que me ha brindado una visión diferenciada de temas de investigación actuales y experiencia en un entorno académico internacional.

Por otro lado, deseo agradecer a la Escuela Técnica Superior de Ingeniería (ICAI) por la formación integral que me ha proporcionado a lo largo de estos años. Más allá de los conocimientos técnicos adquiridos, valoro especialmente los principios, el rigor académico y la visión ética y profesional que han impregnado mi paso por esta institución. Esta experiencia ha sido clave en mi desarrollo personal y profesional, y me ha preparado para afrontar con responsabilidad los retos futuros.

Finalmente, quiero agradecer de todo corazón a mis padres, quienes han hecho posible que pudiera estudiar en una institución como ICAI. Su apoyo incondicional, en lo personal, emocional y material, han sido clave para que pudiera afrontar esta etapa con plenitud. Gracias a su dedicación y a la fe que siempre han depositado en mí, he tenido la oportunidad de formarme en un entorno académico de alto nivel.

SISTEMA DE GESTIÓN DE TRÁFICO ADAPTATIVO CON IOT Y EDGE COMPUTING

Autor: Moraga Doménech, Álvaro.
Director: Dr. de Curtò i Díaz, Joaquim
Entidad Colaboradora: BARCELONA Supercomputing Center, ICAI

RESUMEN DEL PROYECTO

Este proyecto explora el uso de inteligencia artificial y Edge Computing para optimizar la gestión del tráfico urbano. A través de simulaciones en SUMO con datos de sensores IoT, se evalúan mejoras en congestión y emisiones de CO_2. Se comparan resultados entre modelos tradicionales y sistemas inteligentes. Los hallazgos demuestran el potencial del enfoque propuesto para ciudades más sostenibles y eficientes.

Palabras clave: Inteligencia Artificial, IoT, Edge Computing, SUMO, TraCI, Bucles de Inducción, Gemini 2.0 Flash

1. Introducción

La congestión del tráfico urbano es uno de los principales retos de las ciudades modernas, con impactos significativos en la calidad de vida, el tiempo de desplazamiento y el medio ambiente, especialmente por el aumento de emisiones de CO_2. Ante esta problemática, la presente tesis propone una solución basada en inteligencia artificial (IA), Internet de las Cosas (IoT) y Edge Computing para optimizar la gestión del tráfico urbano.

A través de simulaciones realistas en tres entornos distintos (Pacific Beach, Coronado y Argüelles), se ha desarrollado un sistema capaz de adaptar dinámicamente la gestión del tráfico en función de las condiciones en tiempo real. La herramienta SUMO ha permitido evaluar el impacto de la propuesta en términos de reducción de congestión y emisiones. Este trabajo demuestra cómo las tecnologías inteligentes pueden aplicarse de forma efectiva para mejorar la movilidad urbana y avanzar hacia ciudades más sostenibles [1].

2. Definición del proyecto

El objetivo principal del proyecto es diseñar, implementar y evaluar un sistema inteligente de gestión del tráfico que utilice tecnologías de vanguardia como inteligencia artificial, IoT y Edge Computing. Este sistema busca optimizar el flujo vehicular y reducir el impacto ambiental, adaptando en tiempo real los parámetros del tráfico en función de datos recogidos por sensores distribuidos por la red vial.

El proyecto se estructura en varias fases: definición y configuración de entornos de simulación, integración de sensores virtuales, implementación de algoritmos adaptativos, y evaluación de resultados mediante métricas clave como la congestión, la velocidad media, las emisiones de CO_2 y el tiempo medio de llegada a destino.

Se han utilizado tres escenarios urbanos reales: Pacific Beach, Coronado (San Diego, EE.UU.) y Argüelles (Madrid, España), cada uno con diferentes niveles de tráfico simulados, para validar la robustez y versatilidad del sistema. Los resultados obtenidos permiten comparar el rendimiento del sistema con IA frente a un escenario tradicional, poniendo en evidencia las ventajas del enfoque propuesto.

3. Descripción del modelo/sistema/herramienta

El sistema propuesto para la gestión inteligente del tráfico combina diferentes componentes tecnológicos en una arquitectura integrada, diseñada para simular entornos urbanos complejos y aplicar estrategias de optimización basadas en inteligencia artificial. La base de este sistema es SUMO (Simulation of Urban MObility), un simulador de tráfico de código abierto ampliamente utilizado en la investigación académica y en proyectos de planificación urbana. SUMO permite modelar redes de tráfico reales, definir rutas, controlar señales y simular el comportamiento de los vehículos a gran escala, lo que lo convierte en una herramienta idónea para el análisis de políticas de movilidad [1].

La interacción dinámica con SUMO se realiza a través de TraCI (Traffic Control Interface), una API que permite controlar la simulación en tiempo real desde scripts externos. Gracias a esta interfaz, es posible implementar un sistema adaptativo que modifica ciertos parámetros del tráfico, como los límites de velocidad o las prioridades de paso, en función de las condiciones del entorno simuladas en cada momento [1,2].

Para la recolección de datos en la simulación, se han incorporado sensores virtuales de tipo bucle inductivo, que replican el funcionamiento de sensores físicos utilizados en muchas ciudades. Estos sensores están ubicados estratégicamente en diversas zonas de las redes viales de los tres escenarios utilizados (Pacific Beach, Coronado y Argüelles), y proporcionan métricas como la ocupación de carriles, la velocidad media de los vehículos y el número de vehículos presentes por tramo y por instante de tiempo.

La capa de inteligencia del sistema se basa en un conjunto de algoritmos adaptativos que procesan estos datos en tiempo real para generar decisiones orientadas a reducir la congestión y las emisiones. Estas decisiones incluyen, por ejemplo, el ajuste dinámico de los límites de velocidad o la redistribución del flujo vehicular. Para lograr una respuesta más ágil, estas decisiones se ejecutan en el entorno de Edge Computing, es decir, en nodos locales próximos a la fuente de los datos, lo que reduce la latencia y la necesidad de enviar información a servidores remotos. Este enfoque es especialmente relevante en el contexto de ciudades inteligentes, donde la inmediatez en la toma de decisiones puede marcar la diferencia en la fluidez del tráfico [2,3].

Además, se ha incorporado un módulo experimental basado en modelos de lenguaje de gran escala (LLM), concretamente Gemini 2.0 Flash, con el objetivo de explorar su capacidad para analizar patrones históricos y generar recomendaciones inteligentes. Este componente no interviene directamente en el control del tráfico, pero abre la puerta a futuras integraciones en las que los LLM puedan colaborar en la planificación estratégica del sistema o en la predicción de comportamientos a gran escala [2-5].

En conjunto, el modelo combina simulación, sensorización, Edge Computing, inteligencia artificial y tecnologías emergentes para ofrecer una plataforma flexible y escalable de gestión del tráfico urbano. Es por ello que esta arquitectura permite tanto el análisis de escenarios como la experimentación con nuevas políticas de movilidad, en un entorno controlado pero representativo de la realidad [6].

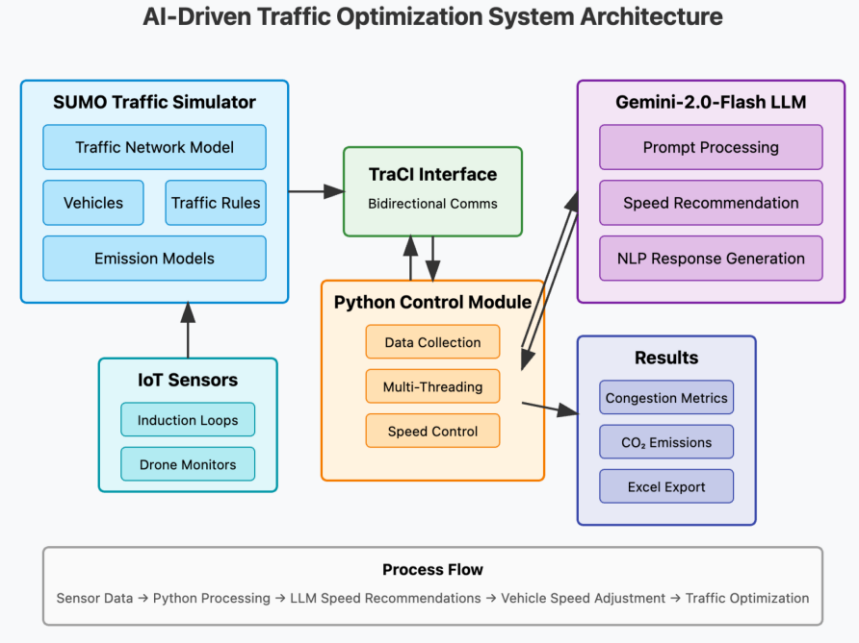

Ilustración 1 – Arquitectura del Sistema [5]

4. Resultados

Los resultados obtenidos a lo largo del desarrollo del proyecto han sido muy positivos y reflejan una mejora significativa en la eficiencia del tráfico cuando se aplican técnicas de inteligencia artificial en entornos urbanos simulados. Aunque los datos cuantitativos serán analizados en detalle en los capítulos correspondientes, es importante destacar que la implementación del sistema adaptativo ha demostrado ser eficaz en distintos contextos urbanos, como por ejemplo en el escenario de Pacific Beach, donde se observó una notable reducción de la congestión y de las emisiones de CO_2 respecto al modelo tradicional sin IA.

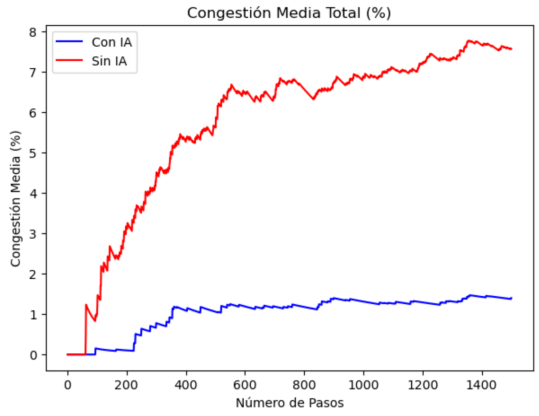

Ilustración 2 - Congestión Media con IA vs sin IA Pacific Beach

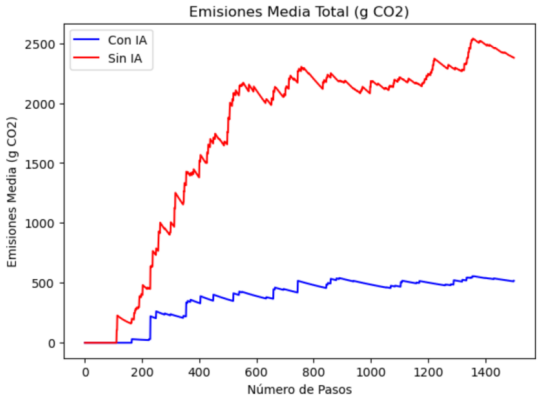

Ilustración 3 - Emisiones Media con IA vs sin IA Pacific Beach

Además, la flexibilidad del sistema ha permitido su aplicación en zonas con distintas intensidades de tráfico, evidenciando su adaptabilidad. La interacción fluida entre los sensores de IoT, el Edge Computing y la Inteligencia Artificial ha sido clave para estos buenos resultados. Por lo tanto, se puede afirmar que los objetivos del proyecto se han cumplido de manera satisfactoria y se abre la puerta a aplicaciones reales de este tipo de soluciones en ciudades inteligentes.

5. Conclusiones

Este proyecto ha permitido demostrar el potencial de aplicar técnicas de inteligencia artificial y tecnologías emergentes como IoT y Edge Computing en la gestión inteligente del tráfico urbano. A través de la simulación en diferentes entornos y la integración de

componentes adaptativos, se ha comprobado que es posible mejorar diversos indicadores clave del tráfico, como la congestión y las emisiones contaminantes.

Aunque las conclusiones detalladas se presentarán posteriormente, a nivel general puede afirmarse que la propuesta desarrollada no solo ha funcionado correctamente en entornos simulados, sino que también sienta una base sólida para futuras aplicaciones en entornos reales. La experiencia obtenida a lo largo del desarrollo también ha permitido identificar áreas de mejora y nuevas líneas de investigación para seguir avanzando hacia un transporte más eficiente y sostenible.

6. Referencias

[1] Ulvi, H., Yerlikaya, M. A., & Yildiz, K. (2024). Urban Traffic Mobility Optimization Model: A Novel Mathematical Approach for Predictive Urban Traffic Analysis. Applied Sciences, 14(13), 5873. https://doi.org/10.3390/app14135873

[2] de Zarzà, I.; de Curtò, J.; Roig, G.; Calafate, C.T. LLM Multimodal Traffic Accident Forecasting. Sensors 2023, 23, 9225. https://doi.org/10.3390/s23229225

[3] Movahedi, Mohammad, and Juyeong Choi. "The Crossroads of LLM and Traffic Control: A Study on Large Language Models in Adaptive Traffic Signal Control." IEEE Transactions on Intelligent Transportation Systems (2024)

[4] Akhtar, Mahmuda, and Sara Moridpour. "A review of traffic congestion prediction using artificial intelligence." Journal of Advanced Transportation 2021.1 (2021): 8878011.

[5] Moraga , Á., de Curtò, J., de Zarzà, I., & Calafate, C. T. (2025). AI-Driven UAV and IoT Traffic Optimization: Large Language Models for Congestion and Emission Reduction in Smart Cities. Drones, 9(4), 248. https://doi.org/10.3390/drones9040248

ADAPTIVE TRAFFIC MANAGEMENT SYSTEM WITH IOT AND EDGE COMPUTING

Author: Moraga Doménech, Álvaro
Supervisor: Dr. de Curtò i Díaz, Joaquim
Collaborating Entity: BARCELONA Supercomputing Center, ICAI

ABSTRACT

This project explores the use of artificial intelligence and Edge Computing to optimize urban traffic management. Through simulations in SUMO using IoT sensor data, improvements in congestion and CO_2 emissions are evaluated. Results are compared between traditional models and intelligent systems. The findings demonstrate the potential of the proposed approach for more sustainable and efficient cities.

Keywords: Artificial Intelligence, IoT, Edge Computing, SUMO, TraCI, Induction Loops, Gemini 2.0 Flash.

1. Introduction

Urban traffic congestion is one of the main challenges faced by modern cities, with significant impacts on quality of life, travel time, and the environment, especially due to the increase in CO_2 emissions. In response to this issue, this thesis proposes a solution based on Artificial Intelligence (AI), the Internet of Things (IoT), and Edge Computing to optimize urban traffic management.

Through realistic simulations in three different environments (Pacific Beach, Coronado, and Argüelles), a system has been developed that can dynamically adapt traffic management based on real-time conditions. The SUMO tool has been used to assess the impact of the proposal in terms of congestion and emissions reduction. This work demonstrates how intelligent technologies can be effectively applied to improve urban mobility and move towards more sustainable cities [1].

2. Project Definition

The main objective of this project is to design, implement, and evaluate an intelligent traffic management system that leverages cutting-edge technologies such as Artificial Intelligence, IoT, and Edge Computing. This system aims to optimize vehicle flow and reduce environmental impact by dynamically adjusting traffic parameters in real time based on data collected from sensors distributed across the road network.

The project is structured into several phases: defining and configuring simulation environments, integrating virtual sensors, implementing adaptive algorithms, and evaluating results using key metrics such as congestion, average speed, CO_2 emissions, and average travel time to destination.

Three real urban scenarios were used: Pacific Beach and Coronado (San Diego, USA), and Argüelles (Madrid, Spain); each with different levels of simulated traffic, to validate the robustness and versatility of the system. The results obtained allow for a comparison between the AI-powered system and a traditional scenario, clearly highlighting the advantages of the proposed approach.

3. Description of the model/system/tool

The proposed intelligent traffic management system combines various technological components within an integrated architecture, designed to simulate complex urban environments and apply optimization strategies based on artificial intelligence. The core of this system is SUMO (Simulation of Urban MObility), an open-source traffic simulator widely used in academic research and urban planning projects. SUMO enables the modeling of real traffic networks, route definition, signal control, and large-scale vehicle behavior simulation, making it an ideal tool for mobility policy analysis [1].

Dynamic interaction with SUMO is carried out through TraCI (Traffic Control Interface), an API that allows real-time simulation control from external scripts. Thanks to this interface, it is possible to implement an adaptive system that modifies certain traffic parameters such as speed limits or right-of-way priorities based on conditions simulated at any given moment [1,2].

For data collection during simulation, virtual inductive loop sensors have been integrated, replicating the functionality of physical sensors commonly used in many cities. These sensors are strategically placed across various areas of the road networks in the three scenarios used (Pacific Beach, Coronado, and Argüelles), and provide metrics such as lane occupancy, average vehicle speed, and the number of vehicles per road segment and time step.

The system's intelligence layer is based on a set of adaptive algorithms that process this data in real time to generate decisions aimed at reducing congestion and emissions. These decisions include, for example, dynamic adjustment of speed limits or redistribution of vehicle flow. To ensure faster response times, these decisions are executed within an Edge Computing environment, meaning on local nodes close to the data source, which reduces latency and the need to send information to remote servers. This approach is especially relevant in the context of smart cities, where real-time decision-making can make a significant difference in traffic flow [2,3].

Additionally, an experimental module based on large language models (LLMs) specifically Gemini 2.0 Flash, has been incorporated to explore its capacity to analyze historical patterns and generate intelligent recommendations. This component does not directly intervene in traffic control, but it opens the door to future integrations in which LLMs could contribute to the system’s strategic planning or large-scale behavior prediction [2-4].

Overall, the model combines simulation, sensor integration, Edge Computing, artificial intelligence, and emerging technologies to offer a flexible and scalable platform for urban traffic management. As such, this architecture supports both scenario analysis and the experimentation with new mobility policies in a controlled yet realistic environment [5].

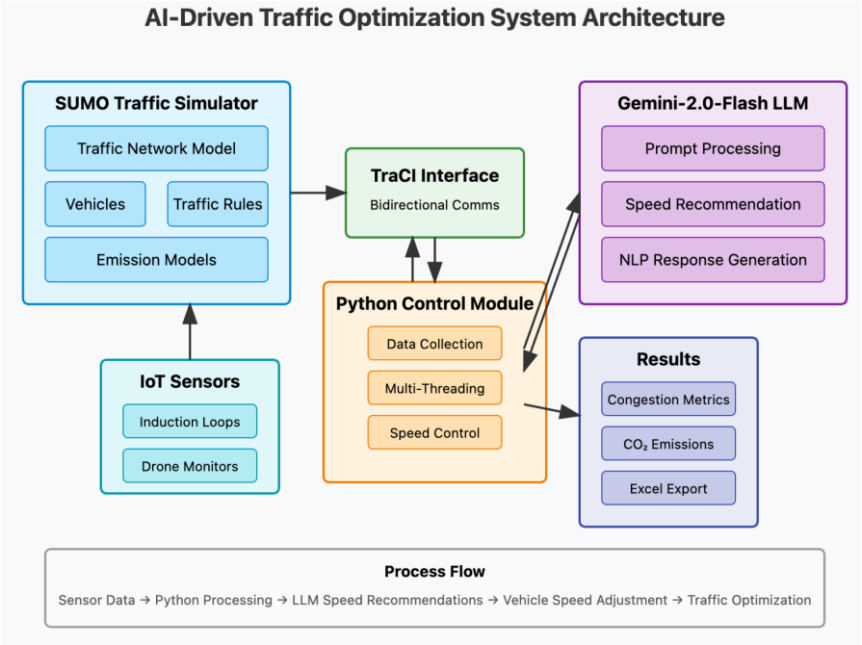

Figure 1 – System Architecture [5]

4. Results

The results obtained throughout the development of the project have been very positive and show a significant improvement in traffic efficiency when artificial intelligence techniques are applied in simulated urban environments. Although the quantitative data will be analyzed in detail in the corresponding chapters, it is important to highlight that the implementation of the adaptive system has proven to be effective across different urban contexts. For example, in the Pacific Beach scenario, a notable reduction in congestion and CO_2 emissions was observed compared to the traditional non-AI model.

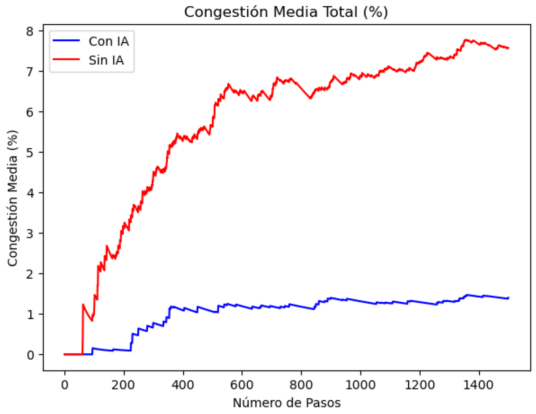

Figure 2 – Average Congestion with AI vs without AI in Pacific Beach

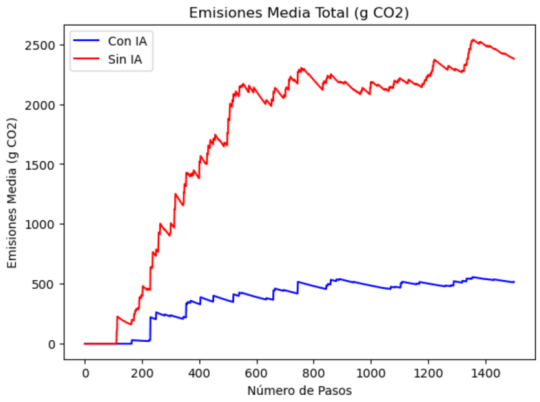

Figure 3 – Average Emissions with AI vs without AI in Pacific Beach

Moreover, the flexibility of the system has enabled its application in areas with varying traffic intensities, demonstrating its adaptability. The smooth interaction between IoT sensors, Edge Computing, and Artificial Intelligence has been key to achieving these positive results. Therefore, it can be stated that the project's objectives have been successfully met, paving the way for real-world applications of this type of solution in smart cities.

5. Conclusions

This project has demonstrated the potential of applying artificial intelligence techniques and emerging technologies such as IoT and Edge Computing to intelligent urban traffic management. Through simulation in different environments and the integration of adaptive components, it has been shown that it is possible to improve various key traffic indicators, such as congestion and pollutant emissions.

Although detailed conclusions will be presented later, it can be generally stated that the proposed solution has not only performed successfully in simulated environments, but also lays a solid foundation for future applications in real-world settings. The experience gained throughout the development has also helped identify areas for improvement and new lines of research to continue advancing toward more efficient and sustainable transportation.

6. References

[1] Ulvi, H., Yerlikaya, M. A., & Yildiz, K. (2024). Urban Traffic Mobility Optimization Model: A Novel Mathematical Approach for Predictive Urban Traffic Analysis. Applied Sciences, 14(13), 5873. https://doi.org/10.3390/app14135873

[2] de Zarzà, I.; de Curtò, J.; Roig, G.; Calafate, C.T. LLM Multimodal Traffic Accident Forecasting. Sensors 2023, 23, 9225. https://doi.org/10.3390/s23229225

[3] Movahedi, Mohammad, and Juyeong Choi. "The Crossroads of LLM and Traffic Control: A Study on Large Language Models in Adaptive Traffic Signal Control." IEEE Transactions on Intelligent Transportation Systems (2024)

[4] Akhtar, Mahmuda, and Sara Moridpour. "A review of traffic congestion prediction using artificial intelligence." Journal of Advanced Transportation 2021.1 (2021): 8878011.

[5] Moraga , Á., de Curtò, J., de Zarzà, I., & Calafate, C. T. (2025). AI-Driven UAV and IoT Traffic Optimization: Large Language Models for Congestion and Emission Reduction in Smart Cities. Drones, 9(4), 248. https://doi.org/10.3390/drones9040248

Índice de la memoria

Capítulo 1. Introducción 6

1.1 Antecedentes y motivación del proyecto 6

1.2 Planteamiento del problema 6

1.3 Objetivos de la investigación 7

1.4 Contribuciones de la tesis 8

1.5 Organización de la tesis 8

Capítulo 2. Revisión de la literatura 10

2.1 Congestión del tráfico e impacto ambiental 10

2.2 Sistemas inteligentes de gestión de tráfico 11

2.3 Internet de las cosas (IoT) en el transporte 15

2.4 Aplicaciones de Edge Computing en ciudades inteligentes 18

2.5 Herramientas de simulación para el análisis del tráfico (SUMO) 23

2.6 Revisión de trabajos relacionados y limitaciones 27

Capítulo 3. Metodología 29

3.1 Descripción general de la arquitectura del sistema 29

3.2 Configuración de la simulación SUMO 30

3.2.1 Diseño de la red y modelado del entorno: 30

3.2.2 Dinámica del vehículo y modelos de emisiones: 31

3.3 Integración de sensores IoT 33

3.3.1 Técnicas de recopilación de datos: 33

3.4 Edge Computing con Large Language Models 34

3.4.1 Procesamiento de datos y análisis en tiempo real: 34

3.5 Algoritmos de tráfico adaptativo 36

3.5.1 Ajuste dinámico de la velocidad: 36

3.5.2 Estrategias de reducción de emisiones: 37

3.6 Integración de componentes a través da la API TraCI 38

Capítulo 4. Configuración e implementación experimental 39

4.1 Descripción de entornos y escenarios de prueba 39

4.2 Configuración de parámetros y Configuraciones de Simulación 41

4.3 Métricas de Evaluación 43
4.3.1 Métricas de congestión de tráfico: 43
4.3.2 Mediciones de emisiones de CO_2: 43
4.4 Detalles de Implementación y Métricas Utilizadas 44

Capítulo 5. Resultados y análisis 46
5.1 Análisis de la mejora de la congestión del tráfico 48
5.2 Reducción de emisiones medias totales 50
5.3 Análisis comparativo en diferentes escenarios 52
5.4 Discusión de los hallazgos clave 54

Capítulo 6. Discusión 58
6.1 Implicaciones para la gestión inteligente del tráfico 58
6.2 Fortalezas y limitaciones del enfoque 60
6.3 Consideraciones prácticas para la implementación en el mundo real 61
6.4 Trabajo futuro y direcciones de investigación 63
6.5 Contribución y publicación 65

Capítulo 7. Conclusión 68
7.1 Resumen de los hallazgos 68
7.2 Contribuciones al campo 69
7.3 Observaciones finales 71

Capítulo 8. Bibliografía 73

ANEXO I: ALINEACIÓN DEL PROYECTO CON LOS ODS 77

ANEXO II 79

Índice de figuras

Ilustración 1. Id de los bucles de inducción integrados 30
Ilustración 2. Función process_ai_model 32
Ilustración 3. Obtención de emisiones 33
Ilustración 4. Extracción de datos 35
Ilustración 5. Integración de Threads 35
Ilustración 6. Ajuste dinámico de la velocidad..... 37
Ilustración 7. Conexión a SUMO..... 38
Ilustración 8. Entorno de simulación Pacific Beach 39
Ilustración 9. Entorno de simulación Coronado 40
Ilustración 10. Entorno de simulación Argüelles 41
Ilustración 11. Scale Traffic 1.5 42
Ilustración 12. Scale Traffic 2 42
Ilustración 13. Scale traffic 2.5 42
Ilustración 14. Pacific Beach IA 46
Ilustración 15. Pacific Beach sin IA 46
Ilustración 16. Coronado IA 47
Ilustración 17. Coronado sin IA 47
Ilustración 18. Argüelles IA 47
Ilustración 19. Argüelles sin IA 48
Ilustración 20. Gráfica de Congestión Media co IA vs sin IA Pacific Beach 49
Ilustración 21. Gráfica de Congestión Media con IA vs sin IA Coronado 49
Ilustración 22. Gráfica de Congestión Media con IA vs sin IA Argüelles 50
Ilustración 23. Gráfica de Emisiones de CO_2 medias con IA vs sin IA Pacific Beach 51
Ilustración 24. Gráfica de Emisiones de CO_2 medias con IA vs sin IA Coronado 51
Ilustración 25. Gráfica de Emisiones de CO_2 medias con IA vs sin IA Argüelles..... 52
Ilustración 29. Certificado de aceptación 66
Ilustración 30. Portada del artículo 67
Ilustración 31. Creación del entorno de Coronado con OpenStreetMap..... 79

Ilustración 32. Implantación de bucles de inducción en el entorno de edición NETEDIT... 80

Índice de tablas

Ilustración 26. Tabla comparativa de Congestión total y media 51

Ilustración 27. Tabla comparativa de Emisiones Medias 52

Ilustración 28. Tabla Comparativa de Velocidades medias y Tiempos medios..... 52

Capítulo 1. INTRODUCCIÓN

1.1 ANTECEDENTES Y MOTIVACIÓN DEL PROYECTO

En las últimas décadas, el crecimiento exponencial del tráfico urbano ha generado desafíos significativos en la movilidad de las ciudades. El aumento del número de vehículos ha llevado a niveles críticos de congestión, con repercusiones negativas en la calidad del aire, la eficiencia del transporte y la calidad de vida de los ciudadanos. Además, el transporte es uno de los principales contribuyentes a las emisiones de CO_2, lo que agrava la crisis climática global.

En este contexto, la Inteligencia Artificial (IA) ha emergido como una herramienta poderosa para la optimización del tráfico, ofreciendo soluciones innovadoras basadas en el análisis de datos y la toma de decisiones en tiempo real. Gracias a la integración de modelos de IA con sistemas de simulación de tráfico, como SUMO (Simulation of Urban Mobility), es posible desarrollar estrategias dinámicas para reducir la congestión y minimizar las emisiones contaminantes.

El presente trabajo explora el uso de IA para optimizar la movilidad urbana, utilizando un modelo que ajusta dinámicamente la velocidad de los vehículos en función de los niveles de congestión detectados en tiempo real.

1.2 PLANTEAMIENTO DEL PROBLEMA

Las infraestructuras de tráfico actuales operan, en su mayoría, bajo sistemas de control predefinidos que no se adaptan de manera eficiente a las variaciones del flujo vehicular. Esto provoca situaciones en las que se generan atascos innecesarios y un consumo excesivo de combustible, lo que impacta directamente en el medio ambiente.

El problema central que aborda esta investigación es la optimización de la movilidad urbana mediante la implementación de un sistema basado en IA que pueda reducir la congestión y las emisiones de CO_2. Se busca responder a la siguiente pregunta:

"¿Puede un modelo de IA mejorar la eficiencia del tráfico urbano en comparación con los métodos tradicionales, reduciendo tanto la congestión como las emisiones contaminantes?"

Para responder a esta pregunta, se han desarrollado dos tipos simulaciones:

-Una utilizando técnicas de IA para la optimización de la velocidad vehicular.

-Otra sin IA, funcionando como control para la comparación de resultados.

1.3 OBJETIVOS DE LA INVESTIGACIÓN

El principal objetivo de esta investigación es desarrollar y evaluar un sistema basado en IA para la optimización del tráfico urbano, con el fin de reducir la congestión y las emisiones contaminantes. Para ello, se establecen los siguientes objetivos específicos:

1. Diseñar un modelo de IA capaz de analizar datos de tráfico en tiempo real y proponer ajustes dinámicos en la velocidad de los vehículos.

2. Implementar este modelo en un entorno de simulación utilizando SUMO y TraCI.

3. Comparar los resultados obtenidos con una simulación sin IA, evaluando métricas como la congestión media y las emisiones de CO_2.

4. Determinar el impacto del modelo en la movilidad y sostenibilidad urbana, validando su viabilidad como herramienta de optimización del tráfico.

1.4 CONTRIBUCIONES DE LA TESIS

Este trabajo aporta al campo de la movilidad urbana y la inteligencia artificial a través de las siguientes contribuciones:

-Desarrollo de un modelo de IA que ajusta la velocidad vehicular en función del nivel de congestión, contribuyendo a la optimización dinámica del tráfico.

-Implementación de una simulación en SUMO que permite evaluar el impacto del modelo en la reducción de la congestión y las emisiones de CO_2.

-Comparación con un sistema sin IA, proporcionando evidencia cuantitativa sobre los beneficios de la integración de IA en la gestión del tráfico urbano.

-Potencial aplicación en entornos reales, con la posibilidad de integrar este tipo de sistemas en infraestructuras inteligentes para mejorar la movilidad y reducir el impacto ambiental del transporte.

1.5 ORGANIZACIÓN DE LA TESIS

La presente tesis se estructura de la siguiente manera:

Capítulo 1: Introducción. Se presenta el contexto de la investigación, el problema a resolver, los objetivos, las contribuciones y la estructura del documento.

Capítulo 2: Revisión de la literatura. Se analizan investigaciones previas relacionadas con la optimización del tráfico mediante IA, así como tecnologías y metodologías utilizadas en este ámbito.

Capítulo 3: Metodología. Se describe el enfoque utilizado, detallando el modelo de IA implementado, las herramientas utilizadas y el diseño de la simulación en SUMO.

Capítulo 4: Configuración e implementación experimental. Se describe la configuración del entorno de simulación, los parámetros utilizados en SUMO, la integración del modelo de IA y la metodología para la recopilación y análisis de datos.

Capítulo 5: Resultados y análisis. Se presentan los resultados obtenidos, comparando el desempeño del modelo con y sin IA, y evaluando el impacto en la congestión y las emisiones.

Capítulo 6: Discusión. Se interpretan los resultados, se analizan las limitaciones, mejoras y el impacto del modelo en la movilidad urbana y la sostenibilidad del transporte.

Capítulo 7: Conclusión. Se resumen los hallazgos de la investigación, destacando las principales conclusiones y sugiriendo líneas de trabajo futuras para mejorar y expandir el modelo propuesto.

Capítulo 2. REVISIÓN DE LA LITERATURA

2.1 CONGESTIÓN DEL TRÁFICO E IMPACTO AMBIENTAL

La congestión del tráfico es un problema global que afecta tanto a la movilidad urbana como al medio ambiente. A medida que las ciudades crecen y el número de vehículos en circulación aumenta, la eficiencia del sistema de transporte se ve comprometida, generando retrasos, pérdidas económicas y un impacto negativo en la calidad del aire.

1. Efectos de la congestión del tráfico

La congestión del tráfico se produce cuando la demanda de infraestructura vial excede su capacidad, lo que provoca velocidades reducidas, tiempos de viaje más largos y un incremento en el consumo de combustible. Este fenómeno no solo afecta la productividad y la calidad de vida de los ciudadanos, sino que también tiene consecuencias ambientales y económicas significativas [4, 22, 26].

Entre los principales efectos de la congestión se encuentran:

Aumento del tiempo de viaje: Retrasos considerables que impactan la eficiencia del transporte público y privado [1, 5, 30].

Mayor consumo de combustible: La conducción en condiciones de tráfico denso incrementa el consumo de combustible debido a la constante aceleración y frenado [5, 37, 10].

Incremento de emisiones contaminantes: La congestión contribuye a la emisión de gases de efecto invernadero, como el dióxido de carbono (CO_2), así como contaminantes locales como óxidos de nitrógeno (NO_x) y material particulado (PM) [5, 24, 10].

Impacto económico: La congestión genera pérdidas económicas asociadas con la reducción de la productividad y el aumento de costos operativos en el transporte de mercancías [1, 26, 37].

Efectos en la salud pública: La exposición prolongada a la contaminación del aire causada por el tráfico está relacionada con enfermedades respiratorias y cardiovasculares [10, 11, 37].

2. Relación entre la congestión del tráfico y el impacto ambiental

El transporte es una de las principales fuentes de contaminación ambiental en entornos urbanos. Según diversos estudios, los vehículos de combustión interna generan una cantidad significativa de emisiones de CO_2, las cuales contribuyen al cambio climático. Además, en situaciones de tráfico denso, los motores operan de manera ineficiente, lo que agrava aún más el problema [10, 26, 37].

Las estrategias para mitigar la congestión y su impacto ambiental incluyen la optimización del tráfico mediante tecnologías avanzadas, el fomento del transporte público y la adopción de vehículos eléctricos o híbridos. La implementación de sistemas de gestión inteligente del tráfico, como los basados en inteligencia artificial (IA), permite mejorar la fluidez del tránsito y reducir el consumo de combustible y las emisiones [1, 5, 11, 24, 35].

2.2 SISTEMAS INTELIGENTES DE GESTIÓN DE TRÁFICO

Los sistemas inteligentes de gestión del tráfico son tecnologías que utilizan sensores, comunicaciones y procesamiento de datos para optimizar el flujo vehicular y mejorar la seguridad en las carreteras. Su objetivo principal es hacer un uso más eficiente de la infraestructura existente, reduciendo la congestión, mejorando la seguridad vial y minimizando el impacto ambiental del transporte [4, 12, 26].

1. Componentes clave de los sistemas inteligentes de gestión del tráfico

Los ITS combinan diversas tecnologías que trabajan en conjunto para gestionar el tráfico de manera más eficiente. Los principales componentes de estos sistemas incluyen:

Sensores de tráfico: Dispositivos que recogen datos en tiempo real sobre el flujo vehicular, la ocupación de los carriles y la velocidad de los vehículos. Los sensores más comunes incluyen los bucles de inducción, cámaras de video, sensores ultrasónicos y radares. Estos dispositivos permiten medir la densidad del tráfico, detectar congestión y prever situaciones de tráfico anormal [14, 18, 27].

Sistemas de información en tiempo real: Los sistemas de información proporcionan a los conductores datos sobre las condiciones del tráfico, como la velocidad de los vehículos, el tiempo estimado de llegada y las rutas más rápidas. Esto se puede hacer a través de señales de tráfico dinámicas, aplicaciones móviles o plataformas en línea que informan sobre incidentes, accidentes o cierres de carreteras [6, 11, 16].

Sistemas de gestión del tráfico basado en IA y big data: Los avances en inteligencia artificial (IA) y el análisis de grandes volúmenes de datos han permitido que los sistemas de tráfico sean más predictivos y proactivos. Utilizando algoritmos de aprendizaje automático, los sistemas pueden anticipar patrones de tráfico, detectar anomalías y ajustar automáticamente los parámetros del tráfico en función de la demanda [2, 5, 28, 29, 31].

2. Tecnologías clave en los sistemas inteligentes de tráfico

Inteligencia Artificial (IA): Los algoritmos de IA, especialmente el aprendizaje automático y el aprendizaje profundo, son utilizados para analizar grandes volúmenes de datos de tráfico en tiempo real y prever comportamientos futuros. Estos algoritmos pueden predecir congestiones, identificar patrones de tráfico, optimizar la sincronización de los semáforos y adaptar las señales de tráfico según las condiciones cambiantes. En algunos casos, la IA

también se usa para procesar datos de los vehículos autónomos, lo que permite una mayor integración en los sistemas de gestión del tráfico [2, 3, 4, 5, 28, 31].

Internet de las Cosas (IoT): Los dispositivos conectados en red son cruciales para la recopilación de datos en tiempo real. Los sensores y dispositivos IoT, como cámaras de vigilancia, detectores de vehículos y señales de tráfico inteligentes, generan una gran cantidad de información que puede ser procesada y utilizada para mejorar la gestión del tráfico. La conectividad de estos dispositivos también permite la comunicación bidireccional entre los vehículos y las infraestructuras viales, lo que permite el desarrollo de vehículos autónomos y de sistemas de transporte inteligentes [14, 16, 26, 27, 35].

Big Data y análisis de datos: Los sistemas de gestión de tráfico modernos dependen del análisis de grandes volúmenes de datos provenientes de diversas fuentes, como sensores de tráfico, cámaras, aplicaciones móviles y plataformas de redes sociales. Estos datos pueden incluir información sobre la velocidad de los vehículos, el número de vehículos en circulación, la congestión en tiempo real y otros factores relevantes. El análisis de estos datos permite identificar patrones de tráfico, predecir problemas antes de que ocurran y hacer ajustes dinámicos en la infraestructura de tráfico [6, 26, 28, 29].

3. Ventajas de los sistemas inteligentes de gestión del tráfico

Reducción de la congestión: Al analizar los datos de tráfico en tiempo real y ajustar dinámicamente los semáforos y las rutas, los ITS pueden reducir significativamente los embotellamientos y optimizar el flujo de tráfico. Esto no solo mejora la eficiencia del transporte, sino que también reduce los tiempos de espera y mejora la experiencia del conductor [3, 4, 5, 28].

Mejoras en la seguridad vial: La integración de tecnologías como los semáforos inteligentes, las alertas en tiempo real y la comunicación V2X ayuda a reducir los accidentes de tráfico, especialmente en intersecciones y áreas de alto riesgo [2, 5, 25, 35].

Reducción de las emisiones contaminantes: Al optimizar el flujo de tráfico y reducir los atascos, los ITS contribuyen a reducir las emisiones de gases contaminantes, como el CO_2. Esto es especialmente relevante en áreas urbanas densamente pobladas, donde los altos niveles de contaminación son una preocupación creciente [5, 10, 37].

Ahorro económico: Al mejorar la eficiencia del tráfico, los ITS reducen los costos operativos para las empresas de transporte y los conductores individuales. Además, la mejora de la movilidad urbana puede tener un impacto positivo en la productividad económica de una ciudad o región [9, 26, 39].

4. Desafíos de la implementación de sistemas inteligentes de gestión del tráfico

A pesar de sus ventajas, la implementación de ITS enfrenta varios desafíos:

Costos iniciales: La instalación de infraestructura de sensores, sistemas de comunicación y plataformas de análisis de datos puede ser costosa, lo que puede representar un obstáculo en algunas regiones [9, 24, 38].

Interoperabilidad: La integración de diferentes tecnologías y sistemas puede ser compleja, especialmente si se utilizan diferentes plataformas o dispositivos de diferentes proveedores [5, 29, 30].

Protección de datos y privacidad: El uso de datos en tiempo real sobre el comportamiento de los vehículos y los conductores plantea preocupaciones sobre la privacidad. Es esencial que los sistemas de ITS cumplan con las normativas de protección de datos y que se establezcan mecanismos de seguridad robustos [6, 33, 34, 35].

2.3 INTERNET DE LAS COSAS (IOT) EN EL TRANSPORTE

El Internet de las Cosas (IoT) en el contexto del transporte se refiere a la interconexión de objetos físicos, como vehículos, infraestructuras viales, sensores, y dispositivos móviles, a través de internet, lo que permite la recopilación, el intercambio y el análisis de datos en tiempo real. El IoT desempeña un papel crucial en la creación de sistemas de transporte inteligentes, proporcionando información valiosa sobre el comportamiento del tráfico, la seguridad vial, el rendimiento de los vehículos y el estado de las infraestructuras, lo que permite una gestión más eficiente y una toma de decisiones informada [2, 5, 16, 35].

1. Componentes del IoT en el transporte

El IoT en el transporte está compuesto por una variedad de dispositivos y tecnologías que recogen y transmiten datos, lo que permite la monitorización en tiempo real y la gestión eficiente del sistema de transporte. Los principales componentes incluyen:

Sensores de tráfico: Los sensores de tráfico, como los bucles inductivos, cámaras de video, radares y sensores ultrasónicos, son dispositivos cruciales en un sistema IoT de transporte. Estos sensores permiten medir la densidad del tráfico, la velocidad de los vehículos y la ocupación de los carriles, recopilando datos que se envían a centros de control para su análisis. Además, los sensores pueden detectar condiciones anormales del tráfico, como accidentes o bloqueos, y comunicar esta información a otros dispositivos del sistema [2].

Dispositivos en vehículos: Los vehículos equipados con dispositivos IoT, como sistemas de navegación, sensores de velocidad, GPS y telemetría, pueden transmitir datos sobre su ubicación, velocidad, condiciones del motor y otros parámetros importantes. Estos datos no solo permiten a los conductores obtener información útil en tiempo real, sino que también contribuyen a una visión global del flujo vehicular en una ciudad o región [16].

Infraestructura vial conectada: Las infraestructuras viales, como los semáforos, señales de tráfico y puntos de control, también pueden ser equipadas con dispositivos IoT. Estos dispositivos permiten que las infraestructuras se comuniquen entre sí y con los vehículos, proporcionando información sobre el estado de las vías y ajustando dinámicamente las señales de tráfico en función de la congestión o las condiciones del tráfico [14].

Plataformas de gestión y análisis de datos: Los datos recopilados por los dispositivos IoT son enviados a plataformas centralizadas, donde se procesan y analizan para generar información útil en tiempo real. Estas plataformas permiten a los operadores del sistema de transporte gestionar el tráfico, predecir problemas y optimizar los flujos vehiculares, así como proporcionar a los conductores recomendaciones de rutas o alertas de tráfico [35].

2. Aplicaciones del IoT en el transporte

Las tecnologías IoT están transformando la forma en que gestionamos el transporte, haciendo que los sistemas de tráfico sean más inteligentes, eficientes y sostenibles. Algunas de las aplicaciones más destacadas del IoT en el transporte incluyen:

Gestión dinámica del tráfico: Los sistemas IoT permiten una gestión del tráfico en tiempo real. A través de sensores distribuidos por las carreteras, los centros de control pueden obtener datos sobre la congestión, la velocidad del tráfico y los incidentes. Con esta información, los semáforos y señales de tráfico pueden ajustarse automáticamente para optimizar el flujo vehicular y reducir los atascos. Además, la información sobre el tráfico puede ser transmitida a los conductores a través de aplicaciones móviles o sistemas de navegación, ayudándoles a tomar decisiones más informadas sobre rutas y tiempos de viaje [2, 14, 16, 20].

Vehículos autónomos: Los vehículos autónomos (o coches sin conductor) dependen en gran medida del IoT para operar de manera segura y eficiente. Equipados con sensores, cámaras, radares y sistemas de comunicación, los vehículos autónomos pueden interactuar con otras partes de la infraestructura vial conectada para tomar decisiones sobre la conducción, como

frenar, acelerar o cambiar de carril. La interconexión con otros vehículos y las infraestructuras viales permite que los vehículos autónomos se adapten dinámicamente a las condiciones del tráfico, mejorando la seguridad y la eficiencia del sistema de transporte en su conjunto [6, 22, 35].

Sistemas de pago electrónico y peajes inteligentes: Los dispositivos IoT permiten la automatización de los sistemas de pago en carreteras, puentes y estacionamientos. A través de tecnologías como RFID (identificación por radiofrecuencia) y sistemas de pago sin contacto, los conductores pueden pagar peajes de manera automática y sin detenerse. Esto mejora la fluidez del tráfico y reduce los tiempos de espera en los puntos de peaje, contribuyendo a una mayor eficiencia en el sistema de transporte [14, 20, 26].

Monitoreo de la salud del vehículo: Los sensores IoT instalados en los vehículos también pueden recopilar datos sobre el estado del motor, la presión de los neumáticos, el nivel de combustible y otros parámetros importantes. Estos datos se pueden enviar a los centros de control o a los conductores para informarles de posibles problemas de mantenimiento, lo que puede mejorar la seguridad y el rendimiento del vehículo [16, 18, 22].

Gestión de la movilidad urbana: El IoT no solo mejora el transporte vehicular, sino que también contribuye a la gestión de otros modos de transporte, como bicicletas, scooters eléctricos y transporte público. A través de sensores y aplicaciones móviles, los usuarios pueden acceder a información sobre la disponibilidad y el estado de los vehículos de transporte público o sistemas de movilidad compartida, optimizando su experiencia y contribuyendo a una mayor eficiencia del sistema de transporte urbano [2, 14, 23].

3. Beneficios del IoT en el transporte

El IoT ofrece una serie de beneficios clave que mejoran la eficiencia, la seguridad y la sostenibilidad del transporte:

Reducción de la congestión: Al recopilar datos en tiempo real sobre el flujo vehicular, el IoT permite una mejor gestión de los semáforos y las rutas, reduciendo los atascos y optimizando el flujo de tráfico. Esto no solo mejora la experiencia de los conductores, sino que también reduce las emisiones de gases contaminantes debido a la menor cantidad de tiempo que los vehículos pasan detenidos en los atascos [2, 14, 20, 36].

Mejor seguridad vial: Los sistemas IoT pueden detectar y alertar sobre condiciones peligrosas, como accidentes, obstáculos en la vía o condiciones climáticas adversas. Además, los vehículos autónomos pueden evitar accidentes mediante la comunicación en tiempo real con otros vehículos e infraestructuras viales, mejorando la seguridad en general [6, 16, 22, 35].

Reducción de emisiones: La optimización del flujo de tráfico y la mejora en la eficiencia del transporte público y privado contribuyen a reducir el consumo de combustible y las emisiones de gases contaminantes, como el CO_2. La gestión inteligente del tráfico basada en IoT puede minimizar el tiempo de inactividad de los vehículos, lo que reduce las emisiones y mejora la sostenibilidad del sistema de transporte [14, 20, 27, 36].

Mejora de la experiencia del usuario: Los sistemas IoT proporcionan a los conductores y pasajeros información en tiempo real sobre el tráfico, los tiempos estimados de llegada y las condiciones de la carretera. Esto permite tomar decisiones más informadas, reducir la frustración del conductor y optimizar las rutas de viaje [2, 14, 18, 23].

2.4 APLICACIONES DE EDGE COMPUTING EN CIUDADES INTELIGENTES

El Edge Computing es una arquitectura de procesamiento de datos que acerca el procesamiento de la información a la fuente de los datos, en lugar de depender exclusivamente de la nube o de servidores centrales ubicados en centros de datos. En el contexto de las ciudades inteligentes, esta tecnología juega un papel crucial al mejorar la

eficiencia, reducir la latencia y aumentar la capacidad de respuesta de los sistemas urbanos que dependen de grandes cantidades de datos generados por sensores, dispositivos IoT y otras fuentes [10, 15, 19, 37].

La implementación de Edge Computing en las ciudades inteligentes es esencial para gestionar de manera más eficiente los recursos urbanos, como el tráfico, la energía, el agua y la seguridad, permitiendo una toma de decisiones en tiempo real. A continuación, se exploran algunas de las principales aplicaciones del Edge Computing en las ciudades inteligentes [11, 19, 38, 24].

1. Gestión del tráfico y optimización del transporte

En el ámbito de la gestión del tráfico, el Edge Computing permite procesar datos de sensores y cámaras en tiempo real, como los ubicados en semáforos, intersecciones y vehículos conectados, sin tener que enviarlos a servidores remotos. Esto reduce significativamente la latencia y mejora la capacidad de respuesta del sistema de tráfico [10, 11, 19, 37]. Algunas de las aplicaciones más destacadas incluyen:

Monitorización en tiempo real: El Edge Computing permite la identificación rápida de incidentes de tráfico, como accidentes o congestiones inesperadas, y la posterior actualización de rutas alternativas para los conductores a través de aplicaciones de navegación [12, 15].

Vehículos autónomos: Los vehículos autónomos pueden beneficiarse del Edge Computing al procesar los datos de los sensores y cámaras localmente para tomar decisiones en fracciones de segundo. Esto les permite interactuar de manera más eficiente con su entorno, como ajustando la velocidad y cambiando de carril, sin depender de la nube para cada pequeña decisión [38, 40, 41].

2. Gestión energética inteligente

Las ciudades inteligentes pueden optimizar la gestión energética a través de redes de distribución de energía (smart grids), sensores IoT, y dispositivos conectados que permiten monitorear el consumo de energía en tiempo real. El Edge Computing facilita el procesamiento de estos datos cerca de su fuente, permitiendo respuestas inmediatas ante fluctuaciones de demanda o fallos en la red [3, 14, 24]. Las aplicaciones clave incluyen:

Distribución eficiente de energía: A través de dispositivos conectados y sensores distribuidos en la red eléctrica, los datos pueden ser procesados para gestionar el flujo de electricidad de manera más eficiente, optimizando la distribución de energía según la demanda de las diferentes zonas de la ciudad [7, 17, 26].

Reducción de costos y huella de carbono: El análisis en tiempo real puede ayudar a identificar oportunidades para reducir el consumo energético o gestionar de manera eficiente el uso de energía renovable en la red. Esto también contribuye a la sostenibilidad, ya que se reduce la dependencia de fuentes de energía no renovables [6, 5, 23].

Control inteligente de edificios: Los sistemas de calefacción, ventilación y aire acondicionado (HVAC) en edificios inteligentes pueden ser optimizados mediante Edge Computing, ajustando automáticamente las temperaturas y otros parámetros en función de los datos recolectados localmente, lo que mejora la eficiencia energética y reduce el consumo [12, 21, 19].

3. Gestión del agua y recursos naturales

La gestión de recursos como el agua y la basura es otro campo en el que el Edge Computing puede ser muy valioso. Los sensores instalados en redes de distribución de agua o en sistemas

de control de residuos pueden generar grandes volúmenes de datos que necesitan ser procesados rápidamente para garantizar un suministro y gestión óptimos [6, 7, 14, 16].

Monitoreo de redes de agua: El Edge Computing permite el monitoreo de las redes de distribución de agua para detectar fugas, cambios en la presión o calidad del agua, y optimizar la distribución según las necesidades locales. Esto puede reducir los desperdicios y mejorar la eficiencia del sistema [6, 14, 16].

Gestión de residuos: El procesamiento local de los datos obtenidos de los sensores en los contenedores de basura puede mejorar la eficiencia de la recolección de residuos. El análisis de estos datos en tiempo real permite la optimización de las rutas de los camiones de basura, minimizando los tiempos de recolección y reduciendo el impacto ambiental [6, 14, 16].

4. Seguridad y vigilancia urbana

La seguridad es una de las áreas más críticas en las ciudades inteligentes, y el Edge Computing proporciona un enfoque más eficiente para procesar datos de cámaras de vigilancia, sensores de movimiento y sistemas de alerta de seguridad. Al procesar los datos en el borde, los sistemas de seguridad pueden responder con mayor rapidez ante incidentes sin tener que depender de la nube o de servidores centrales, lo que reduce la latencia y mejora la eficiencia de las respuestas [6, 14, 16].

Reconocimiento facial y análisis de video: Las cámaras de vigilancia equipadas con capacidades de Edge Computing pueden realizar tareas de reconocimiento facial y detección de comportamientos sospechosos en tiempo real. Esto permite una respuesta más rápida a situaciones de emergencia y mejora la seguridad pública [3, 28, 31].

Detección de incendios y desastres: Los sensores distribuidos en la infraestructura de la ciudad pueden detectar señales tempranas de incendios o desastres naturales. Al procesar los

datos, se pueden activar alarmas y responder rápidamente sin depender de sistemas centralizados [8, 14, 16].

5. Salud y bienestar urbano

El Edge Computing también tiene aplicaciones en el sector de la salud en las ciudades inteligentes, donde se pueden recopilar datos en tiempo real de sensores biométricos, dispositivos portátiles o sistemas de monitoreo de la salud pública. Esto permite una toma de decisiones más informada y rápida para mejorar la calidad de vida de los ciudadanos [14, 16].

Monitoreo de la salud pública: El análisis de datos proveniente de sensores de salud puede detectar brotes de enfermedades o monitorear la calidad del aire, ayudando a gestionar los recursos sanitarios de manera más eficiente [6, 26].

Telemedicina y servicios de emergencia: Los sistemas de salud pueden beneficiarse de dispositivos IoT conectados que monitorean a los pacientes en tiempo real. El Edge Computing puede procesar estos datos localmente, permitiendo que los médicos y los servicios de emergencia actúen rápidamente ante cualquier anomalía o urgencia médica [14, 16, 32].

6. Gestión de la infraestructura urbana

El Edge Computing también se utiliza para optimizar el mantenimiento de la infraestructura urbana, como puentes, edificios, carreteras y otras instalaciones públicas. A través de sensores distribuidos, se puede recopilar información sobre el estado de estas infraestructuras, lo que permite la detección temprana de daños o fallos [14, 16].

Mantenimiento predictivo: El análisis Edge Computing puede predecir posibles fallos en las infraestructuras urbanas, como grietas en puentes o carreteras dañadas, y activar alertas para su reparación antes de que ocurran daños graves [26, 29, 36].

2.5 HERRAMIENTAS DE SIMULACIÓN PARA EL ANÁLISIS DEL TRÁFICO (SUMO)

Las herramientas de simulación de tráfico son fundamentales para el estudio y la optimización de los sistemas de transporte en entornos urbanos. SUMO (Simulation of Urban MObility) es una de las herramientas más utilizadas en la investigación de la gestión del tráfico y las ciudades inteligentes debido a su flexibilidad, capacidad de modelado y amplia base de usuarios. A continuación, se presenta un análisis detallado de SUMO y su aplicabilidad en el análisis del tráfico, así como sus características y ventajas clave.

1. ¿Qué es SUMO?

SUMO (Simulation of Urban MObility) es una herramienta de simulación de tráfico de código abierto diseñada para modelar la movilidad urbana en redes de carreteras y sistemas de transporte. Desarrollada por el Instituto de Transporte y Sistemas de la Universidad de Darmstadt, esta herramienta permite simular el comportamiento de los vehículos, la gestión de semáforos, las emisiones de CO2, y otros factores relacionados con el tráfico en un entorno urbano [18].

El software puede simular escenarios de tráfico complejos en diferentes tipos de redes viales, incluidas carreteras urbanas, intersecciones, túneles y puentes, lo que lo convierte en una herramienta poderosa para investigar y evaluar políticas de tráfico, infraestructura y gestión de la movilidad en las ciudades inteligentes [18].

2. Características principales de SUMO

SUMO ofrece varias características que lo hacen adecuado para el análisis del tráfico en contextos urbanos:

Modelado detallado del tráfico: SUMO permite modelar las interacciones de vehículos, peatones, bicicletas y transporte público en una red de carreteras. Esta capacidad hace que sea una herramienta completa para estudiar la movilidad en áreas urbanas [18].

Simulación de diferentes modos de transporte: Aparte de los vehículos motorizados, SUMO también soporta la simulación de bicicletas, peatones y vehículos de transporte público, lo que lo hace adecuado para el análisis multimodal [18].

Integración con otros modelos: SUMO puede integrarse con otros sistemas y herramientas, como VISSIM, MATSim, o AIMSUN, y también puede usar datos de la red de tráfico real. Además, SUMO tiene interfaces para conectarse con lenguajes de programación como Python, lo que facilita la automatización de simulaciones y la integración con modelos de inteligencia artificial y aprendizaje automático [18].

Simulación de semáforos y gestión del tráfico: SUMO permite modelar el comportamiento de los semáforos y el control de tráfico en tiempo real. La herramienta soporta diferentes algoritmos de gestión de tráfico, como semáforos fijos, adaptativos o basados en demanda, lo que permite estudiar cómo afectan las decisiones de control del tráfico a la congestión y el flujo vehicular [18].

Evaluación de emisiones de CO2 y otros contaminantes: SUMO tiene la capacidad de simular las emisiones de gases contaminantes, como CO2, NOx y PM10, generadas por los vehículos en la red de transporte. Esto permite realizar estudios sobre la sostenibilidad ambiental de las ciudades y el impacto de las políticas de movilidad [18].

Escalabilidad y flexibilidad: SUMO es capaz de simular redes de tráfico de gran escala y puede adaptarse a diferentes niveles de complejidad, desde simulaciones sencillas de intersecciones hasta simulaciones de grandes áreas urbanas con miles de vehículos [18].

Simulación de escenarios y análisis de políticas: SUMO permite simular diferentes escenarios de tráfico y probar políticas de gestión del tráfico, como la implementación de carriles exclusivos para transporte público, zonas de bajas emisiones o nuevas infraestructuras. Esto proporciona información valiosa para la planificación y toma de decisiones en la gestión del transporte urbano [18].

3. Aplicaciones de SUMO en el análisis de tráfico

Algunas de las aplicaciones clave de SUMO incluyen:

Optimización del tráfico: Los modelos de simulación de tráfico en SUMO se utilizan para evaluar diferentes políticas de tráfico, como la gestión de semáforos, la distribución de carriles y la implementación de rutas alternativas. La herramienta permite identificar estrategias que pueden mejorar el flujo de tráfico y reducir la congestión en áreas urbanas [19].

Evaluación de sistemas de vehículos autónomos (VA): Con la llegada de los vehículos autónomos, SUMO ha demostrado ser una herramienta útil para simular el comportamiento de los vehículos autónomos en entornos urbanos. La simulación permite evaluar cómo estos vehículos interactúan con el tráfico existente y cómo pueden contribuir a la mejora de la eficiencia del tráfico y la reducción de la congestión [19, 20].

Estudio de emisiones y sostenibilidad: SUMO es útil para modelar el impacto ambiental del tráfico. A través de la simulación de las emisiones de CO2 y otros contaminantes, los investigadores pueden evaluar cómo las políticas de transporte, como la introducción de vehículos eléctricos, el uso del transporte público o la promoción de modos de transporte no motorizados, pueden contribuir a la sostenibilidad ambiental [19].

Simulación de tráfico en tiempo real: La capacidad de SUMO para simular el tráfico en tiempo real es fundamental para la evaluación de escenarios de movilidad en situaciones dinámicas. Los sistemas de gestión del tráfico pueden usar simulaciones en tiempo real para

ajustar las señales de tráfico o informar a los conductores sobre incidentes o congestiones [19, 20].

Estudio del impacto de infraestructuras de transporte: SUMO también es utilizado para estudiar cómo las modificaciones en la infraestructura urbana (como la creación de nuevos carriles, rotondas o intersecciones) afectan la fluidez del tráfico y la seguridad vial [20].

Análisis de políticas de movilidad urbana: Los responsables de la planificación urbana pueden utilizar SUMO para probar diferentes políticas, como la promoción de vehículos de bajo consumo o el fomento de la movilidad activa, como caminar o andar en bicicleta, para mejorar el transporte sostenible [20].

4. Integración de SUMO con otros sistemas y tecnologías

Una de las fortalezas de SUMO es su capacidad de integración con otros sistemas y tecnologías, lo que aumenta su versatilidad y aplicabilidad:

Interacción con el Internet de las Cosas (IoT): SUMO puede conectarse con dispositivos IoT para obtener datos en tiempo real sobre el tráfico, la ocupación de las vías y las condiciones de la infraestructura. Esta integración permite una simulación más precisa y actualizada, mejorando la toma de decisiones en tiempo real [5, 14, 16, 18, 19].

Inteligencia Artificial y Aprendizaje Automático: SUMO puede ser combinado con algoritmos de inteligencia artificial (IA) para mejorar la toma de decisiones en la simulación de tráfico. Esto incluye el uso de técnicas de aprendizaje automático para predecir el comportamiento del tráfico, optimizar la gestión de semáforos y evaluar el impacto de nuevas infraestructuras en el tráfico [1, 3, 4, 22, 28, 29].

Edge Computing: SUMO también puede integrarse con tecnologías de Edge Computing, lo que permite procesar datos localmente para una toma de decisiones más rápida y eficiente.

Esto es especialmente útil para la gestión de tráfico en tiempo real, donde la latencia es un factor crucial [5, 24, 25, 36].

Big Data: Al ser capaz de procesar grandes volúmenes de datos, SUMO se puede utilizar para analizar patrones de tráfico basados en Big Data provenientes de sensores urbanos, sistemas de transporte público y vehículos conectados. Esto ayuda a mejorar la precisión de las simulaciones y a hacer predicciones más exactas sobre el comportamiento del tráfico [6, 26, 27, 29].

2.6 REVISIÓN DE TRABAJOS RELACIONADOS Y LIMITACIONES

A lo largo de los últimos años, se han realizado diversos estudios sobre la optimización del tráfico mediante el uso de tecnologías avanzadas como la inteligencia artificial (IA), el Internet de las Cosas (IoT) y la simulación de tráfico. Estos trabajos han demostrado la efectividad de los sistemas inteligentes de gestión del tráfico para reducir la congestión, mejorar la eficiencia del transporte y disminuir las emisiones contaminantes [1, 4, 5, 22, 24, 28]. Sin embargo, aunque los resultados son prometedores, existen limitaciones que deben ser consideradas:

Falta de datos reales: Muchos de los estudios se basan en simulaciones o datos limitados de entornos específicos. Esto dificulta la generalización de los resultados a otras ciudades o condiciones de tráfico [22, 25, 26, 27, 36].

Desafíos en la integración de tecnologías: La integración de IA, IoT y Edge Computing con las infraestructuras de tráfico existentes sigue siendo un reto en términos de costo, compatibilidad y escalabilidad [5, 14, 16, 24, 26].

Complejidad en la modelización del comportamiento humano: Los estudios a menudo asumen un comportamiento de los conductores idealizado, lo cual no siempre refleja la

complejidad y variabilidad del comportamiento humano en situaciones de tráfico reales [23, 34, 36].

Escalabilidad de las soluciones: Las soluciones basadas en simulaciones o IA pueden ser difíciles de escalar a nivel de grandes ciudades con infraestructuras complejas debido a los recursos computacionales necesarios [24, 28, 29, 36].

Capítulo 3. METODOLOGÍA

3.1 DESCRIPCIÓN GENERAL DE LA ARQUITECTURA DEL SISTEMA

En este apartado se presenta la arquitectura diseñada para la simulación y optimización del tráfico mediante inteligencia artificial y tecnologías IoT. Se describe la estructura del sistema, sus componentes principales y la interacción entre ellos.

La arquitectura está compuesta por los siguientes elementos clave:

SUMO (Simulation of Urban Mobility): Plataforma utilizada para modelar y simular escenarios de tráfico en un entorno urbano realista.

TraCI (Traffic Control Interface): Interfaz que permite la comunicación en tiempo real con la simulación, permitiendo la recopilación de datos sobre velocidad, densidad de tráfico y emisiones de CO_2.

Sensores virtuales (IoT): Representación de sensores de tráfico (bucles de inducción) que recopilan información sobre el flujo vehicular, la ocupación de carriles y la velocidad media en distintos puntos de la red vial.

Módulo de inteligencia artificial: Algoritmo basado en IA que analiza los datos en tiempo real y genera recomendaciones para optimizar la velocidad de los vehículos con el fin de reducir la congestión y las emisiones.

Edge Computing: Permite ejecutar decisiones localmente en la simulación sin necesidad de depender de servidores remotos, lo que mejora la eficiencia y reduce la latencia.

Almacenamiento y análisis de datos: Los resultados de la simulación se almacenan en archivos Excel para su posterior análisis y comparación con escenarios sin optimización basada en IA.

3.2 CONFIGURACIÓN DE LA SIMULACIÓN SUMO

La simulación de tráfico en SUMO (Simulation of Urban Mobility) permite modelar el comportamiento de vehículos en un entorno urbano, permitiendo evaluar diferentes estrategias de optimización del tráfico. En esta sección, se describe el diseño de la red, la configuración del entorno, la dinámica del vehículo y los modelos de emisiones empleados.

3.2.1 DISEÑO DE LA RED Y MODELADO DEL ENTORNO:

El diseño de la red vial en SUMO es un aspecto fundamental para la simulación del tráfico. En este caso, las redes utilizadas corresponden a Pacific Beach, Coronado (San Diego, USA) y Argüelles (Madrid) las cuales son áreas específicas en las que se han definido carreteras, intersecciones y semáforos, modelando un entorno urbano realista.

Importación y Configuración de la Red: La red ha sido importada a partir de datos de OpenStreetMap (OSM), generando un archivo .net.xml que representa la infraestructura vial. Posteriormente, se ha creado un archivo de configuración .sumocfg, el cual define los parámetros de la simulación, incluyendo la duración, los dispositivos de detección de tráfico y la integración con TraCI (Traffic Control Interface).

Sensores y Recolección de Datos: Para evaluar la congestión en tiempo real, se han desplegado bucles de inducción en puntos clave de la red. Estos sensores proporcionan datos sobre la ocupación de la vía, la velocidad media de los vehículos y la cantidad de automóviles que han cruzado por el punto de monitoreo.

```
# IDs de los detectores de bucle que deseamos consultar
loop_detector_ids = [
    "e1_0", "e1_1", "e1_2", "e1_3", "e1_4", "e1_5",
    "e1_6", "e1_7", "e1_8", "e1_9", "e1_10", "e1_11"
]
```

Ilustración 1 - Id de los bucles de inducción integrados

Los datos recogidos se utilizarán para alimentar un modelo de IA, el cual ajusta dinámicamente la velocidad de los vehículos para reducir la congestión.

3.2.2 DINÁMICA DEL VEHÍCULO Y MODELOS DE EMISIONES:

SUMO permite simular la dinámica de los vehículos utilizando distintos modelos de comportamiento.

Durante el proceso de control del tráfico basado en IA, observamos que el LLM aplica implícitamente un modelo de regresión cuadrática al generar recomendaciones de velocidad. Este enfoque es coherente con las teorías establecidas sobre el flujo de tráfico, ya que la relación entre velocidad y congestión es típicamente no lineal, exhibiendo una forma parabólica en la que una velocidad óptima minimiza la congestión.

La forma general de esta relación cuadrática es:

$$C = aV^2 + bV + c$$

Donde:

C representa la congestión (variable dependiente),

V representa la velocidad (variable independiente),

a, b, c son coeficientes ajustados a datos reales de tráfico.

Para optimizar el flujo vehicular, el modelo de IA calcula efectivamente la derivada de esta función para encontrar la velocidad que minimiza la congestión:

$$\frac{dC}{dV} = 2aV + b = 0$$

Resolviendo para V^*, obtenemos la velocidad óptima que minimiza la congestión:

$$V^* = -\frac{b}{2a}$$

Por ejemplo, en una iteración observada, el modelo de IA puede utilizar la siguiente función de congestión:

$$C(V) = 0.001V^2 - 0.05V + 1$$

Calculando la derivada:

$$\frac{dC}{dV} = 0.002V - 0.05$$

Igualándola a cero y resolviendo para V^*:

$$V^* = \frac{0.05}{0.002} = 25 \text{ km/h}$$

Esto ilustra cómo el sistema de IA no está simplemente realizando ajustes aleatorios, sino que modela implícitamente la dinámica de la congestión mediante una función cuadrática y optimiza la velocidad para obtener el mejor flujo posible.

```python
# Función para procesar la recomendación del modelo en paralelo y a tiempo real
def process_ai_model(mean_speed, congestion, loop_id):
    try:
        response = chat_session.send_message(
            "Modifica la velocidad media de los coches de tal forma que se optimice "
            f"la congestión de tráfico lo máximo posible a partir de las variables ({mean_speed}) "
            f"la cual es la velocidad media y ({congestion}) la cual es la congestión."
        )
        match = re.search(r'\d+(\.\d+)?', response.text)
        if match:
            recommended_speed = float(match.group(0))
            lane_id = traci.inductionloop.getLaneID(loop_id)
            traci.lane.setMaxSpeed(lane_id, recommended_speed)
            vehicle_ids = traci.lane.getLastStepVehicleIDs(lane_id)
            for vehicle_id in vehicle_ids:
                # Me aseguro de que el vehículo existe antes de modificarlo si no da un error de non-vehicle
                if traci.vehicle.getIDList() and vehicle_id in traci.vehicle.getIDList():
                    traci.vehicle.setSpeed(vehicle_id, recommended_speed)
    except Exception:
        pass  # Ignoramos errores y seguimos calculando.
```

Ilustración 2 - Función process_ai_model

Para evaluar el impacto ambiental del tráfico, SUMO permite calcular las emisiones de los vehículos basándose en modelos de consumo de combustible y factores de emisión de CO_2.

Cada vehículo tiene un perfil de emisión asociado, y se pueden obtener las emisiones de cada unidad en simulación a través del siguiente código :

```
# Calculamos emisiones
emissions = sum([traci.vehicle.getCO2Emission(vehicle_id) for vehicle_id in traci.lane.getLastStepVehicleIDs(traci.i
total_emissions += emissions
```

Ilustración 3 - Obtención de emisiones

Los valores obtenidos se almacenan para su posterior análisis y comparación con distintos escenarios de simulación.

3.3 INTEGRACIÓN DE SENSORES IOT

En la simulación, los sensores de IoT utilizados son los bucles de inducción, dispositivos que permiten la detección en tiempo real de vehículos en puntos estratégicos de la red vial. Estos sensores generan datos sobre la ocupación de la vía, la velocidad media y el número de vehículos que atraviesan un determinado punto, lo que permite a la IA ajustar dinámicamente la velocidad para optimizar el tráfico.

3.3.1 TÉCNICAS DE RECOPILACIÓN DE DATOS:

Los bucles de inducción son sensores electromagnéticos incrustados en la calzada, que detectan la presencia de vehículos midiendo la variación en un campo electromagnético. En SUMO, estos sensores proporcionan las siguientes métricas clave:

Ocupación (%): Proporción del tiempo en que el sensor detecta un vehículo sobre él.

Velocidad media (m/s): Velocidad promedio de los vehículos que cruzan el sensor.

Conteo de vehículos: Número de vehículos que han atravesado el bucle.

Estos datos son esenciales para evaluar el nivel de congestión en la vía y alimentar el modelo de IA que ajusta la velocidad en tiempo real.

En la simulación, los bucles de inducción se han colocado en intersecciones y segmentos críticos de la red. Su configuración en SUMO se define en el archivo .add.xml, donde cada bucle se asocia a un carril específico. Estos sensores generan un archivo de salida en formato XML con los datos de cada paso de simulación.

3.4 EDGE COMPUTING CON LARGE LANGUAGE MODELS

El Edge Computing es una tecnología que permite procesar datos lo más cerca posible de la fuente en lugar de depender de servidores en la nube. En esta simulación, el procesamiento de datos en tiempo real es crucial para optimizar el tráfico de manera dinámica utilizando modelos de inteligencia artificial como los Large Language Models (LLMs).

3.4.1 PROCESAMIENTO DE DATOS Y ANÁLISIS EN TIEMPO REAL:

Edge Computing en la simulación de tráfico: En este proyecto, el Edge Computing se implementa procesando los datos capturados por los sensores IoT (bucles de inducción) en tiempo real mediante TraCI y luego utilizando un modelo generativo de IA (Gemini-2.0 Flash) para ajustar dinámicamente la velocidad de los vehículos.

El flujo de procesamiento de datos en tiempo real es posible gracias a los sensores IoT (bucles de inducción) que detectan la congestión y la velocidad media de los vehículos. En paralelo, el modelo de IA procesa la información y recomienda la velocidad óptima para minimizar la congestión. Estos valores recomendados se aplican en tiempo real a los carriles y vehículos, asegurando una respuesta rápida y eficiente.

Extracción y procesamiento de datos (Edge Computing): En lugar de enviar los datos a un servidor remoto, la IA se ejecuta en el mismo sistema que corre la simulación (Edge Device). Esto reduce la latencia y permite tomar decisiones más rápidas.

```python
# Solo ejecutamos las consultas cada 'step_interval' pasos
if step_count % step_interval == 0:
    for loop_id in loop_detector_ids:
        try:
            # Obtenemos métricas desde SUMO
            congestion = traci.inductionloop.getLastStepOccupancy(loop_id)
            mean_speed = traci.inductionloop.getLastStepMeanSpeed(loop_id)

            # Ignoramos si la congestión o la velocidad media son 0 o negativas
            if mean_speed > 0 and congestion > 0:
                # Actualizamos congestión acumulada
                total_congestion += congestion

                # Calculamos emisiones
                emissions = sum([traci.vehicle.getCO2Emission(vehicle_id) for vehicle_id in traci.lane.getLastSt
                total_emissions += emissions

                # Procesamos la recomendación del modelo en un hilo separado
                threading.Thread(target=process_ai_model, args=(mean_speed, congestion, loop_id)).start()

        except traci.TraCIException:
            pass  # Ignoramos errores del detector
```

Ilustración 4 - Extracción de datos

Ejecución en Paralelo: Cabe destacar, que para obtener estos datos a tiempo real se han utilizado hilos (Threads) para evitar que las consultas al modelo de IA bloqueen la simulación, esto mantiene el procesamiento de tráfico y el análisis de IA corriendo en paralelo para una optimización fluida.

Esto se hace específicamente en la función process_ai_model, donde se ejecuta en un hilo separado cada vez que se consulta el modelo de IA para ajustar la velocidad de los vehículos.

Dentro del bucle principal de la simulación SUMO, en esta parte del código:

```python
# Procesar la recomendación del modelo en un hilo separado
threading.Thread(target=process_ai_model, args=(mean_speed, congestion, loop_id)).start()
```

Ilustración 5 - Integración de Threads

Si la función process_ai_model se ejecutara en el mismo hilo principal (sin threading), bloquearía la simulación cada vez que se hace una consulta a la IA, lo cual sería un problema grave por varias razones:

La consulta a la IA tarda un tiempo en responder: El modelo generativo de Google (gemini-2.0-flash-exp) debe procesar el mensaje, generar una respuesta y devolverla, este

proceso puede demorar varios milisegundos o incluso segundos, dependiendo de la carga del sistema y de la latencia de la API.

SUMO tiene que ejecutar la simulación en tiempo real: Cada paso de simulación (traci.simulationStep()) debe ejecutarse rápidamente para mantener la coherencia del tráfico. Por lo tanto, si la función process_ai_model se ejecutara en el mismo hilo, cada paso de la simulación quedaría congelado hasta que la IA devolviera una respuesta.

Permite procesar múltiples recomendaciones a la vez: Como hay varios detectores de bucle, cada uno puede necesitar su propia consulta a la IA. Con el uso de hilos, cada consulta puede ejecutarse de forma independiente sin afectar a las demás.

Evita que el rendimiento de SUMO se degrade: En simulaciones a gran escala con miles de vehículos, cada pequeño retraso se acumula. Si la IA se ejecutara secuencialmente, la simulación se volvería lenta e ineficiente.

3.5 ALGORITMOS DE TRÁFICO ADAPTATIVO

Los algoritmos de tráfico adaptativo son sistemas inteligentes que ajustan en tiempo real el comportamiento de los semáforos, la velocidad permitida o las rutas sugeridas, en función de las condiciones actuales del tráfico. A diferencia de los sistemas tradicionales con horarios fijos, estos algoritmos analizan continuamente datos provenientes de sensores, cámaras o vehículos conectados, y toman decisiones dinámicas para mejorar el flujo vehicular, reducir atascos y minimizar emisiones.

3.5.1 AJUSTE DINÁMICO DE LA VELOCIDAD:

El ajuste dinámico de la velocidad es una estrategia clave para mejorar la movilidad y evitar congestiones en tiempo real. En este sistema, la IA analiza datos de velocidad media y ocupación vehicular y ajusta los límites de velocidad en los carriles para optimizar el flujo de tráfico.

Funcionamiento del ajuste dinámico:

1. Los sensores IoT (bucles de inducción) miden la ocupación vehicular y la velocidad media en cada segmento de la carretera.

2. TraCI extrae estos datos en tiempo real.

3. El modelo de IA calcula una velocidad óptima para reducir la congestión.

4. Se aplica la nueva velocidad a los carriles y a los vehículos individualmente.

5. El sistema actualiza los valores en cada ciclo de simulación, adaptándose a los cambios en el tráfico.

```python
# Función para procesar la recomendación del modelo en paralelo y a tiempo real
def process_ai_model(mean_speed, congestion, loop_id):
    try:
        response = chat_session.send_message(
            "Modifica la velocidad media de los coches de tal forma que se optimice "
            f"la congestión de tráfico lo máximo posible a partir de las variables ({mean_speed}) "
            f"la cual es la velocidad media y ({congestion}) la cual es la congestión."
        )
        match = re.search(r'\d+(\.\d+)?', response.text)
        if match:
            recommended_speed = float(match.group(0))
            lane_id = traci.inductionloop.getLaneID(loop_id)
            traci.lane.setMaxSpeed(lane_id, recommended_speed)
            vehicle_ids = traci.lane.getLastStepVehicleIDs(lane_id)
            for vehicle_id in vehicle_ids:
                # Me aseguro de que el vehículo existe antes de modificarlo si no da un error de non-vehicle
                if traci.vehicle.getIDList() and vehicle_id in traci.vehicle.getIDList():
                    traci.vehicle.setSpeed(vehicle_id, recommended_speed)
    except Exception:
        pass  # Ignoramos errores y seguimos calculando.
```

Ilustración 6 - Ajuste Dinámico de la Velocidad

3.5.2 ESTRATEGIAS DE REDUCCIÓN DE EMISIONES:

Además de optimizar la velocidad, este sistema busca minimizar las emisiones de CO_2 mediante estrategias inteligentes de tráfico. Las estrategias implementadas son las siguientes:

Ajuste de velocidad para minimizar emisiones: Los cambios bruscos de velocidad generan mayor consumo de combustible y emisiones contaminantes. Ajustar la velocidad de manera progresiva permite una conducción más eficiente.

Flujo de tráfico uniforme para evitar aceleraciones bruscas: Reducir los cambios repentinos en la velocidad disminuye el consumo de combustible y las emisiones.

3.6 INTEGRACIÓN DE COMPONENTES A TRAVÉS DE LA API TRACI

La API TraCI (Traffic Control Interface) permite la comunicación en tiempo real con SUMO para controlar y monitorear la simulación de tráfico. En este proyecto, se usa TraCI para: Obtener datos de sensores IoT (bucles de inducción) sobre velocidad y congestión, ajustar dinámicamente la velocidad de los vehículos para optimizar el tráfico y para calcular y reducir las emisiones modificando la circulación de los vehículos.

Sus ventajas incluyen además: el control total sobre la simulación, el procesamiento en tiempo real y la optimización del tráfico mediante IA.

```python
import traci
import subprocess
import time
import google.generativeai as genai
import re
import threading
import pandas as pd  # Importar pandas para manejar el archivo Excel

# Ruta al archivo .sumocfg
sumo_config = r"C:\Users\alvar\OneDrive - Universidad Pontificia Comillas\Curso 4\TFG\Pacific Beach simulation\osm.sumo

# Comando para iniciar SUMO
sumo_cmd = ["sumo-gui", "-c", sumo_config, "--remote-port", "8813"]
```

Ilustración 7 - Conexión a SUMO

Capítulo 4. CONFIGURACIÓN E IMPLEMENTACIÓN EXPERIMENTAL

4.1 DESCRIPCIÓN DE ENTORNOS Y ESCENARIOS DE PRUEBA

Para evaluar la efectividad del sistema de gestión inteligente del tráfico basado en IA y Edge Computing, se han realizado pruebas en tres entornos urbanos distintos:

Pacific Beach (San Diego, EE.UU.)

Se trata de una zona costera con una mezcla de tráfico residencial y turístico. Tiene una elevada densidad de vehículos en horas pico y numerosas intersecciones semaforizadas.

El análisis de este zona supone un desafío debido a que es una zona muy turística donde es muy habitual el flujo irregular y por ende es normal apreciar congestión en avenidas principales y variabilidad en la demanda de tráfico.

Ilustración 8 – Entorno de simulación Pacific Beach

Coronado (San Diego, EE.UU.)

Esta es un área con menor densidad vehicular, pero con tráfico concentrado en accesos clave.

En este caso es interesante analizar el tráfico debido a la dependencia de infraestructuras críticas (puentes y túneles), congestión y restricciones de velocidad estrictas.

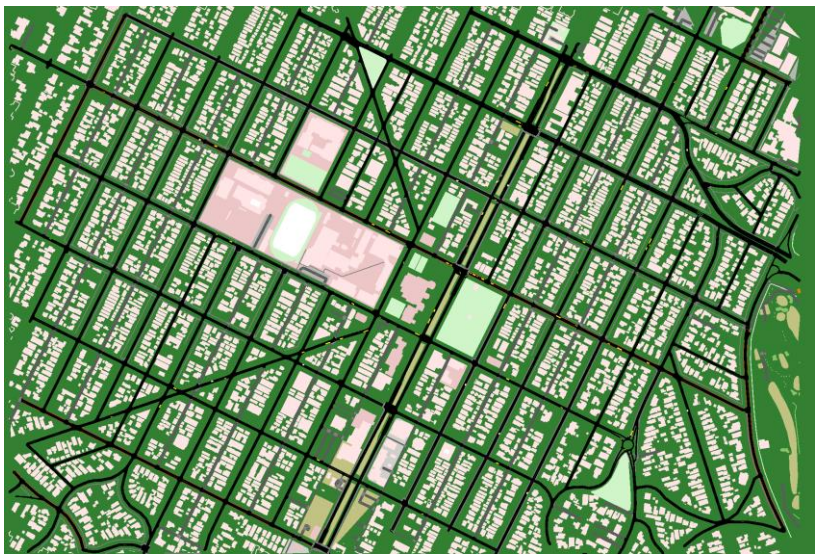

Ilustración 9 – Entorno de simulación Coronado

Argüelles (Madrid, España)

Es un barrio céntrico con alto tráfico de vehículos privados y transporte público, además de zonas de carga y descarga.

Es una buena zona para la experimentación ya que el tráfico es denso, hay múltiples intersecciones semaforizadas, zonas de aparcamiento regulado y restricciones ambientales que afectan la movilidad.

Ilustración 10 – Entorno de simulación Argüelles

4.2 CONFIGURACIÓN DE PARÁMETROS Y CONFIGURACIONES DE SIMULACIÓN

Para garantizar una evaluación consistente del modelo de gestión inteligente del tráfico, en todas las simulaciones se utilizó un total de 1500 pasos de simulación, lo cual es equivalente a 25 minutos. Sin embargo, cada entorno presenta una configuración específica en cuanto a la densidad del tráfico, ajustada mediante el parámetro Scale Traffic, que determina la cantidad de vehículos presentes en la simulación en relación con el tráfico real del área.

A continuación, se detallan los parámetros utilizados en cada escenario:

Pacific Beach (San Diego, EE.UU.)

El parámetro Scale Traffic es de 1.5, que representa un aumento moderado en la densidad del tráfico y flujo vehicular medio-alto, considerando la afluencia de turistas y residentes en la zona.

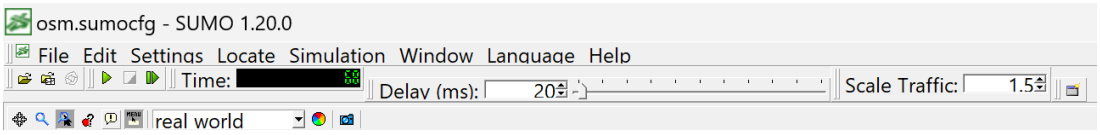

Ilustración 11- Scale Traffic 1.5

Coronado (San Diego, EE.UU.)

El parámetro Scale Traffic es de 2.0, que simula una mayor carga vehicular debido a la la limitada cantidad de accesos a la isla. Es por ello, que el tráfico es más denso, especialmente en conexiones principales.

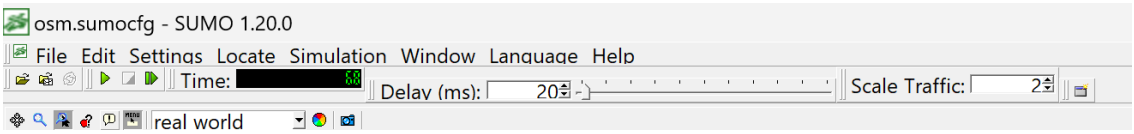

Ilustración 12 – Scale Traffic 2

Argüelles (Madrid, España)

Se ha decidido establecer un Scale Traffic de 2.5 para así reflejar las condiciones de un área urbana congestionada, con una combinación de tráfico privado, transporte público y restricciones ambientales, por lo que habrá un gran número de vehículos en circulación simultáneamente, múltiples intersecciones semaforizadas y alta demanda de movilidad.

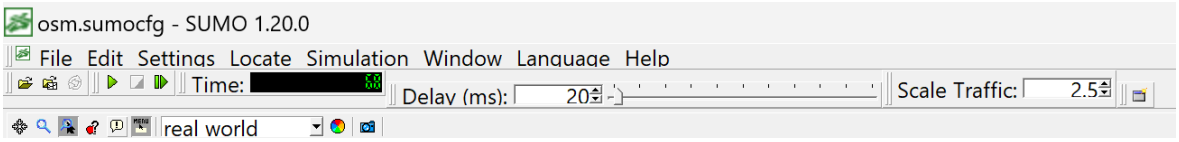

Ilustración 13 – Scale Traffic 2.5

4.3 MÉTRICAS DE EVALUACIÓN

Para analizar el rendimiento del sistema de gestión inteligente del tráfico, se han utilizado métricas clave enfocadas en la congestión del tráfico y las emisiones de CO_2. Estas métricas permiten evaluar el impacto de las estrategias implementadas en diferentes entornos urbanos y niveles de carga vehicular.

4.3.1 MÉTRICAS DE CONGESTIÓN DE TRÁFICO:

La congestión del tráfico ha sido evaluada mediante los siguientes indicadores:

Ocupación de carriles (%): Proporción del tiempo en el que un detector de bucle de inducción registra la presencia de un vehículo en un determinado carril.

Velocidad media (m/s): Promedio de la velocidad de los vehículos en un tramo determinado.

Tiempo medio de viaje (s): Tiempo promedio que tardan los vehículos en recorrer una distancia específica dentro del entorno de simulación.

4.3.2 MEDICIONES DE EMISIONES DE CO_2:

Las emisiones de CO_2 se han calculado utilizando las funciones integradas de SUMO, que permiten estimar las emisiones en función de los perfiles de consumo de combustible y el comportamiento de los vehículos en la simulación. Se han considerado los siguientes parámetros:

Emisiones totales de CO_2 (g): Cantidad total de CO_2 emitida por todos los vehículos durante los 1500 pasos de simulación.

Emisiones promedio por vehículo (g/s): Cantidad media de CO_2 emitida por cada vehículo en función del tiempo que ha estado circulando.

Variación de emisiones en función del tráfico: Relación entre la densidad del tráfico y las emisiones generadas, evaluando el impacto de la congestión en la contaminación ambiental.

4.4 DETALLES DE IMPLEMENTACIÓN Y MÉTRICAS UTILIZADAS

La ejecución de las simulaciones y el análisis de tráfico, han sido realizadas con diversas herramientas y tecnologías que han permitido modelar escenarios urbanos, recopilar datos y aplicar estrategias de optimización basadas en inteligencia artificial.

Herramientas de simulación:

SUMO (Simulation of Urban Mobility): Ha sido el Software de simulación de tráfico utilizado para modelar el comportamiento de los vehículos en los entornos seleccionados. Se configuró para ejecutar simulaciones de 1500 pasos en cada escenario de prueba.

TraCI (Traffic Control Interface): Es la Interfaz de control de tráfico de SUMO que ha permitido la interacción en tiempo real con la simulación, recopilando datos de sensores virtuales y aplicando modificaciones en la velocidad de los vehículos a tiempo real.

Configuración de entornos de prueba:

Mapas urbanos reales: Se han utilizado datos cartográficos obtenidos de OpenStreetMap (OSM) para generar los entornos de Pacific Beach, Coronado y Argüelles, asegurando una representación realista de la infraestructura vial.

Escalado de tráfico: Como se ha comentado previamente, se han aplicado diferentes factores de escala para ajustar la densidad vehicular en cada simulación:

Pacific Beach: Escalado de tráfico de 1.5

Coronado: Escalado de tráfico de 2.0

Argüelles: Escalado de tráfico de 2.5

Sensores de tráfico y recopilación de datos:

Bucles de inducción virtuales: Sensores simulados en SUMO para medir la ocupación de carriles, la velocidad media y el número de vehículos en determinadas ubicaciones estratégicas.

Extracción de emisiones: Se han utilizado las funciones de SUMO para calcular las emisiones de CO_2 en función de la actividad vehicular en cada paso de simulación.

Integración con inteligencia artificial:

Google Generative AI (Gemini 2.0 Flash): Ha sido el modelo utilizado desde el primer momento para analizar patrones de tráfico y recomendar ajustes en la velocidad de los vehículos con el objetivo de minimizar la congestión. Sin embargo, Cabe se han probado otros modelos como son el 'gemini-2.0-flash-thinking-exp' y el 'gemini-2.0-pro-exp-02-05' que son más avanzados, pero el resultado obtenido realizando diferente número de pruebas, ha sido muy similar en todos ellos.

Automatización con Python: El código desarrollado ha permitido la interacción en tiempo real con SUMO a través de TraCI, gestionando la recopilación de datos y la aplicación de recomendaciones del modelo de IA.

Almacenamiento y análisis de datos:

Pandas y Excel: Para el almacenamiento de los datos generados durante las simulaciones y exportaciones en archivos Excel para su posterior análisis.

Visualización: Los datos de tráfico y emisiones fueron procesados para evaluar el impacto de las estrategias implementadas en cada entorno de prueba. Además se comparan mediante gráficas solapadas los resultados obtenidos de las simulaciones con IA y sin IA.

Capítulo 5. RESULTADOS Y ANÁLISIS

A continuación se muestran los resultados obtenidos en todas las simulaciones realizadas tanto con IA como sin IA:

```
✅ Simulación Finalizada ✅
Total congestión: 2097.96
Total pasos simulados: 1500
Velocidad media total: 7.03 m/s
Congestión media total: 1.40%
Emisiones media total: 517.08 g CO2
Tiempo medio total a destino: 126.66 s
```

Ilustración 14 - Pacific Beach IA

```
✅ Simulación Finalizada ✅
Total congestión: 11346.94
Total pasos simulados: 1500
Velocidad media total: 8.67 m/s
Congestión media total: 7.56%
Emisiones media total: 2378.25 g CO2
Tiempo medio total a destino: 124.67 s
```

Ilustración 15 - Pacific Beach sin IA

```
✅ Simulación Finalizada ✅
Total congestión: 3146.30
Total pasos simulados: 1500
Velocidad media total: 6.06 m/s
Congestión media total: 2.10%
Emisiones media total: 597.41 g CO2
Tiempo medio total a destino: 182.92 s
```

Ilustración 16 - Coronado IA

```
✅ Simulación Finalizada ✅
Total congestión: 16542.88
Total pasos simulados: 1500
Velocidad media total: 5.31 m/s
Congestión media total: 11.03%
Emisiones media total: 3198.99 g CO2
Tiempo medio total a destino: 183.36 s
```

Ilustración 17 - Coronado sin IA

```
✅ Simulación Finalizada ✅
Total congestión: 2433.47
Total pasos simulados: 1500
Velocidad media total: 5.18 m/s
Congestión media total: 1.62%
Emisiones media total: 521.09 g CO2
Tiempo medio total a destino: 136.13 s
```

Ilustración 18 - Argüelles IA

```
✅ Simulación Finalizada ✅
Total congestión: 10345.27
Total pasos simulados: 1500
Velocidad media total: 6.32 m/s
Congestión media total: 6.90%
Emisiones media total: 2394.62 g CO2
Tiempo medio total a destino: 128.98 s
```

Ilustración 19 - Argüelles sin IA

5.1 ANÁLISIS DE LA MEJORA DE LA CONGESTIÓN DEL TRÁFICO

Los resultados muestran una reducción significativa en la congestión del tráfico al implementar el modelo con IA en los tres escenarios simulados:

En **Pacific Beach**, la congestión total se ha reducido de 11,396.44 a 2,097.96, lo que representa una reducción del 81.6%. (Ilustración 14, Ilustración 15, Ilustración 20)

En **Coronado**, la congestión pasó de 16,542.88 a 3,146.30, una mejora del 81%.(Ilustración 16 , Ilustración 17, Ilustración 21)

En **Argüelles**, se ha reducido de 10,345.27 a 2,433.47, logrando una mejora del 76.5%.(Ilustración 17, Ilustración 18, Ilustración 22)

En todos los casos, la congestión media se ha reducido drásticamente, pasando de valores entre 6.90%-11.03% en las simulaciones sin IA a valores entre 1.40%-2.10% con IA.

La mayor mejora se observa en Coronado, donde la congestión media ha bajado de 11.03% a 2.10%.

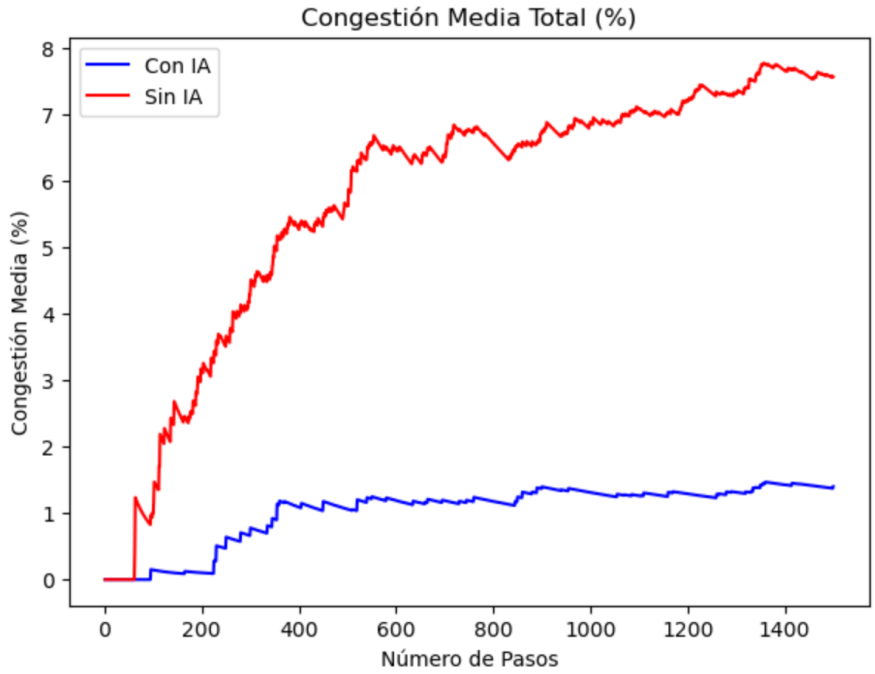

Ilustración 20 - Gráfica de Congestión Media con IA vs sin IA Pacific Beach

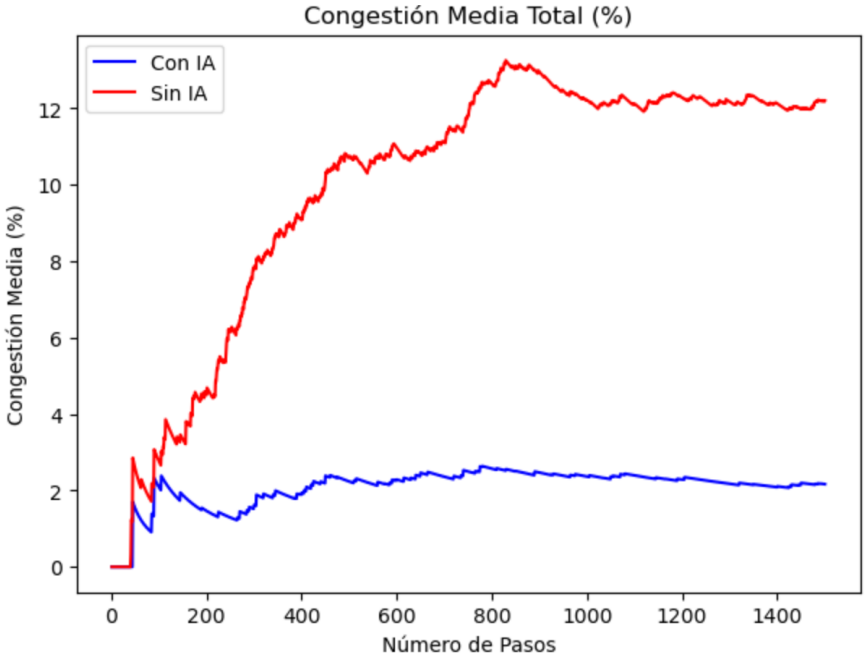

Ilustración 21 - Gráfica de Congestión Media con IA vs sin IA Coronado

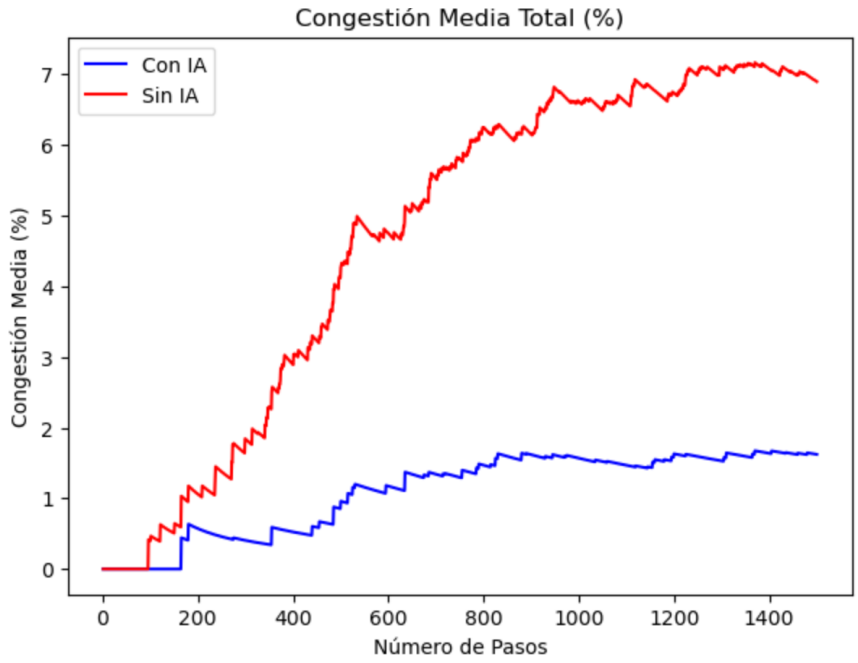

Ilustración 22 - Gráfica de Congestión Media con IA vs sin IA Argüelles

5.2 REDUCCIÓN DE EMISIONES MEDIAS TOTALES

En **Pacific Beach** el modelo sin IA muestra 2,378.25 g, sin embargo, con IA se ha obtenido 517.08 g, lo cual implica una reducción de 1,861.17 g (aproximadamente 78.3%). (Ilustración 14, Ilustración 15, Ilustración 23)

El caso de **Coronado** muestra sin IA 3,198.99 g y con IA: 597.41 g, por ello, la reducción ha sido de 2,601.58 g (aproximadamente 81.3%). (Ilustración 17, Ilustración 18, Ilustración 24)

Finalmente, **Argüelles** muestra sin IA 2,394.62 g y con IA: 521.09 g, por lo tanto, ha habido una reducción de 1,873.53 g (aproximadamente 78.2%). (Ilustración 18, Ilustración 19, Ilustración 25)

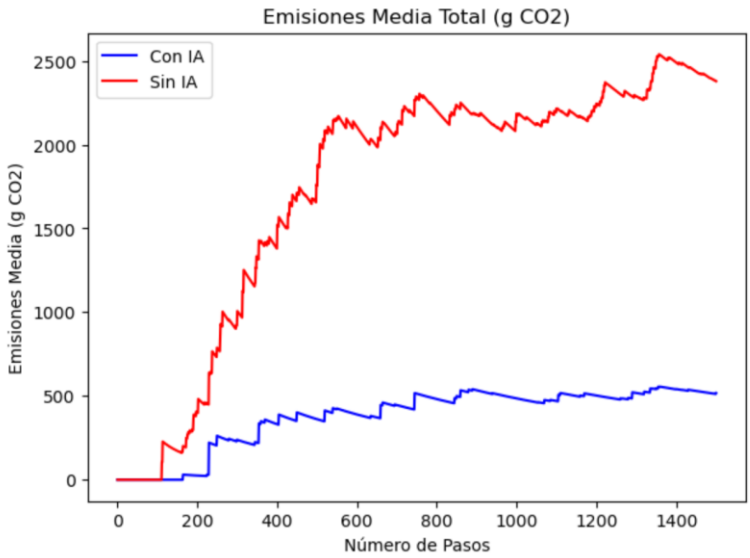

Ilustración 23 - Gráfica de Emisiones de CO_2 Medias con IA vs sin IA Pacific Beach

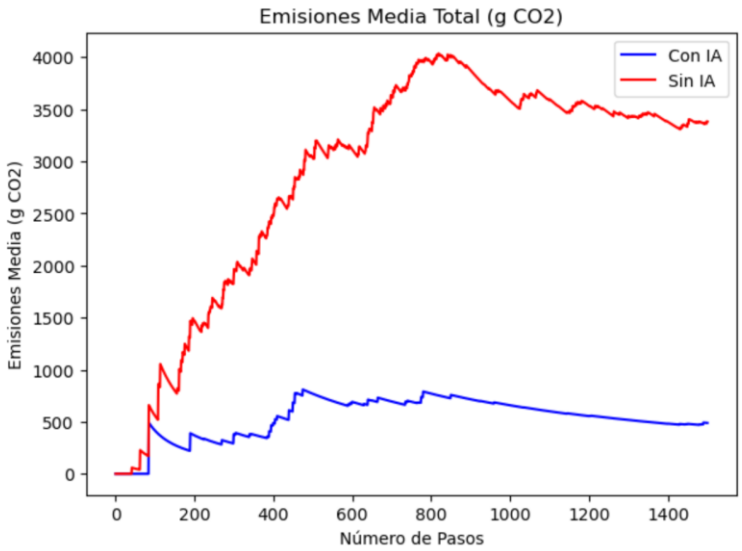

Ilustración 24 - Gráfica de Emisiones de CO_2 Medias con IA vs sin IA Coronado

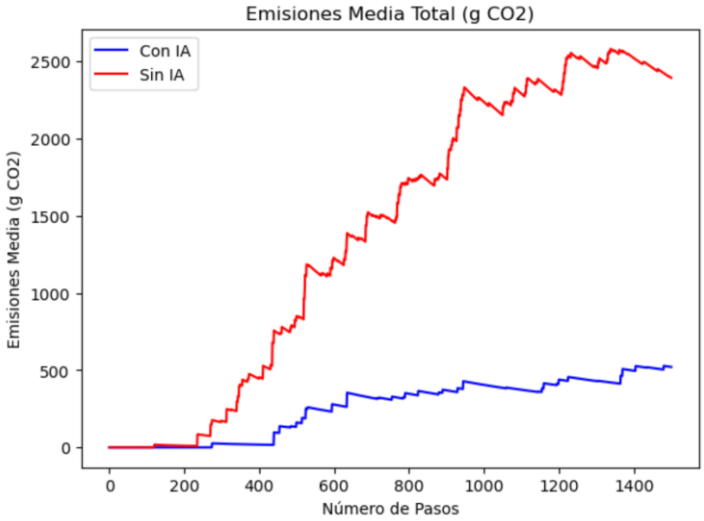

Ilustración 25 - Gráfica de Emisiones de CO_2 Medias con IA vs sin IA Argüelles

5.3 ANÁLISIS COMPARATIVO EN DIFERENTES ESCENARIOS

Comparación de congestión total y congestión media (%)

Escenario	Congestión total (sin IA)	Congestión total (con IA)	Reducción (%)	Congestión media (sin IA)	Congestión media (con IA)	Reducción (%)
Pacific Beach	11396.44	2097.96	81.6	7.56 %	1.40 %	81.5 %
Coronado	16542.88	3146.30	81.0	11.03 %	2.10 %	81.0 %
Argüelles	10345.27	2433.47	76.5	6.90 %	1.62 %	76.5 %

Ilustración 26 - Tabla comparativa de Congestión total y media

La reducción de congestión es más significativa en Pacific Beach y Coronado (más del 81%) en comparación con Argüelles (76.5%). Esto puede explicarse por el Scale Traffic configurado en cada escenario. (Pacific Beach: 1.5, Coronado: 2.0, Argüelles: 2.5)

Comparación de emisiones medias de CO_2

Escenario	Emisiones sin IA (g CO_2)	Emisiones con IA (g CO_2)	Reducción (%)
Pacific Beach	23875.25	517.08	78.3
Coronado	3198.99	597.41	81.3
Argüelles	2394.62	521.09	78.2

Ilustración 27 - Tabla comparativa de Emisiones Medias

En Coronado, la reducción de emisiones es mayor (81.3%), lo que sugiere que la IA optimiza mejor la circulación en este entorno. En Argüelles y Pacific Beach, la reducción es del 78%, lo que sigue siendo significativo.

Comparación de velocidad media total y tiempo medio a destino

Escenario	Velocidad sin IA (m/s)	Velocidad con IA (m/s)	Variación (%)	Tiempo medio sin IA (s)	Tiempo medio con IA (s)	Variación (%)
Pacific Beach	8.67	7.03	↓ 18.9	124.67	126.66	↑ 1.6
Coronado	5.31	6.06	↑ 14.1	183.36	182.92	↓ 0.2
Argüelles	6.32	5.18	↓ 18.0	128.98	136.13	↑ 5.5

Ilustración 28 - Tabla Comparativa de Velocidades medias y Tiempos medios

En Pacific Beach y Argüelles la velocidad media ha disminuido con la IA, pero la congestión también se ha reducido. Por otro lado, en Coronado, la velocidad media ha aumentado, lo que indica que la IA ha logrado optimizar mejor el flujo vehicular. Además, el tiempo medio a destino no se ha visto afectado significativamente en ninguno de los casos.

5.4 DISCUSIÓN DE LOS HALLAZGOS CLAVE

Los resultados obtenidos en las simulaciones permiten extraer varias conclusiones relevantes sobre la efectividad de la inteligencia artificial (IA) en la gestión del tráfico. A continuación, se presentan los hallazgos clave y su interpretación en relación con la congestión, las emisiones y el comportamiento del tráfico en los diferentes escenarios:

Reducción significativa de la congestión y las emisiones de CO_2

Uno de los hallazgos más relevantes es la drástica reducción en los niveles de congestión y emisiones de CO_2 en los tres escenarios con la implementación de IA:

La congestión total se redujo entre un 76.5% y un 81.6%, dependiendo del escenario. También, la congestión media (%) también experimentó reducciones proporcionales en la misma magnitud.

En cuanto a las emisiones de CO_2 disminuyeron en un 78-81%, lo que refleja una mejora en la eficiencia del tráfico y en la sostenibilidad del sistema de transporte.

Esto demuestra que la IA tiene un impacto positivo en la regulación del tráfico, evitando acumulaciones innecesarias de vehículos y optimizando la circulación.

La reducción de la velocidad media no implica mayor congestión

Un aspecto clave que se debe aclarar es que, en ciertos escenarios como Pacific Beach y Argüelles, la velocidad media disminuyó con la IA en comparación con las simulaciones sin IA. Sin embargo, esto no significa que la congestión haya aumentado, sino que la estrategia de la IA optimizó el tráfico de manera diferente.

En un sistema sin IA, algunos vehículos pueden alcanzar velocidades más altas en ciertos tramos, pero esto puede generar frenazos, cuellos de botella y variaciones bruscas en el tráfico, lo que en realidad contribuye a la congestión.

La IA puede optar por reducir la velocidad media para lograr una circulación más homogénea y fluida, evitando detenciones innecesarias y reduciendo la formación de atascos.

Este enfoque también ayuda a reducir las emisiones, ya que los vehículos mantienen una velocidad más estable y consumen menos combustible en procesos de aceleración y frenado constante.

Por lo tanto, la disminución de la velocidad media no es un indicador de mayor congestión, sino de una mejor regulación del flujo vehicular.

Un tiempo medio a destino mayor no significa peor rendimiento

En algunos casos, el tiempo medio a destino con IA es ligeramente mayor que sin IA (por ejemplo, en Argüelles, aumentó en un 5.5%). Sin embargo, este aumento no implica un mayor nivel de congestión o un peor desempeño del sistema de tráfico.

En entornos sin IA, el tráfico suele estar menos regulado, lo que puede generar desviaciones rápidas en ciertas rutas, beneficiando a algunos vehículos mientras otros quedan atrapados en atascos severos.

La IA distribuye mejor los vehículos a lo largo de la red vial, permitiendo que la circulación sea más equitativa y evitando puntos de congestión extremos.

Esto significa que, aunque el tiempo de viaje medio pueda aumentar levemente, la experiencia del tráfico es más estable y predecible, sin grandes demoras en ciertos puntos específicos.

En resumen, un tiempo medio de viaje ligeramente mayor no indica ineficiencia, sino una gestión más equitativa y sostenible del tráfico.

Diferencias en el impacto según la densidad de tráfico

Los resultados varían en función del nivel de tráfico en cada escenario:

En Coronado (scale traffic = 2.0), la IA logró incrementar la velocidad media y reducir la congestión de forma notable, lo que sugiere que su capacidad de optimización fue más efectiva en un tráfico moderado.

En Argüelles (scale traffic = 2.5), aunque la reducción de congestión fue menor que en otros escenarios, la IA aún logró una mejora significativa, pero el tráfico denso limitó su impacto absoluto.

En Pacific Beach (scale traffic = 1.5), donde el tráfico era menos denso, la IA permitió una regulación eficiente con menor congestión.

Esto sugiere que la efectividad de la IA no es uniforme en todos los entornos, sino que depende de la configuración del tráfico y la infraestructura disponible.

La IA mejora la sostenibilidad sin afectar la eficiencia del sistema

La combinación de menor congestión, menores emisiones y un tráfico más equilibrado indica que la implementación de IA no solo mejora la movilidad urbana, sino que también contribuye a la sostenibilidad ambiental.

Se reducen las emisiones contaminantes, lo que disminuye la huella de carbono del transporte.

Además, se logra una circulación más ordenada y predecible, lo que reduce el estrés en la conducción y mejora la seguridad vial.

En conclusión, la gestión inteligente del tráfico se adapta a diferentes niveles de demanda, mostrando una alta versatilidad en distintos entornos urbanos.

Capítulo 6. DISCUSIÓN

6.1 IMPLICACIONES PARA LA GESTIÓN INTELIGENTE DEL TRÁFICO

La implementación de IA y algoritmos adaptativos en la gestión del tráfico no solo mejora la eficiencia del sistema vial, sino que también transforma la forma en que se diseñan e implementan las políticas de movilidad.

Transformación en la Toma de Decisiones:

La disponibilidad de datos en tiempo real permite a las autoridades de tráfico y urbanismo tomar decisiones más informadas y proactivas. Además, se facilitaría el desarrollo de estrategias de movilidad basadas en predicciones en lugar de reacciones a eventos ya ocurridos. El uso de datos en tiempo real permite anticiparse a la congestión y ajustar las estrategias de control antes de que el problema se agrave.

En el escenario de Coronado, por ejemplo, a pesar de tener una carga de tráfico elevada (scale traffic = 2), el sistema con IA logró reducir la congestión total de 16,542.88 a 3,146.30 y mejorar la velocidad media de 5.31 m/s a 6.06 m/s, evidenciando una respuesta eficiente a las condiciones dinámicas del entorno. Esto muestra que las decisiones adaptativas, como el ajuste de velocidades o la redistribución de rutas, permiten gestionar el tráfico de forma más efectiva.

De manera similar, en Pacific Beach, con un tráfico menos denso (scale traffic = 1.5), el sistema inteligente redujo la congestión media del 7.56% al 1.40%, con un impacto positivo en la fluidez del entorno costero, sin comprometer los tiempos de llegada. Este tipo de intervención sería especialmente útil en zonas turísticas con alta variabilidad de tráfico diario y estacional.

Optimización de Infraestructura y Recursos:

Los semáforos, límites de velocidad y señalizaciones pueden ajustarse dinámicamente según la demanda de tráfico. Por lo tanto, se maximiza la capacidad de las vías existentes sin necesidad de inversiones costosas en ampliaciones. La implementación de IA, facilitaría una mejor planificación del transporte público mediante la integración con buses y trenes urbanos y los sistemas inteligentes permiten maximizar el uso de la infraestructura ya existente.

En Argüelles, un entorno urbano más compacto y denso, con un tráfico intensificado (scale = 2.5), la congestión total disminuyó de 10,345.27 a 2,433.47 gracias al uso de IA, sin necesidad de ampliar físicamente las vías. A pesar de que la velocidad media se redujo ligeramente (de 6.32 a 5.18 m/s), el sistema fue capaz de mantener los tiempos medios de llegada estables, demostrando que la eficiencia no siempre se traduce en mayor velocidad, sino en una circulación más estable y controlada.

Este tipo de optimización implica que elementos como semáforos, límites de velocidad o desvíos temporales puedan configurarse automáticamente, según las condiciones de tráfico detectadas en tiempo real, lo que reduce la necesidad de intervención manual y mejora la respuesta ante picos de congestión.

Sostenibilidad y Reducción del Impacto Ambiental:

Uno de los impactos más destacables observados en todos los escenarios fue la reducción significativa de emisiones de CO_2. En Pacific Beach, por ejemplo, las emisiones bajaron de 2,378.25 g a 517.08 g, mientras que en Argüelles se redujeron de 2,394.62 g a 521.09 g. Esta mejora se debe a una conducción más eficiente y menos tiempo en ralentí.

Estos datos demuestran cómo los algoritmos de control adaptativo, al mejorar la fluidez y reducir las detenciones innecesarias, pueden contribuir significativamente a los objetivos de sostenibilidad urbana. También permiten el diseño de rutas optimizadas con menor impacto ambiental, la creación de zonas de bajas emisiones activadas dinámicamente o el uso más racional del transporte público mediante coordinación en tiempo real.

Desafíos en la Implementación:

Pese a los beneficios observados, llevar esta tecnología a la práctica requiere superar varios retos. Es necesaria una infraestructura robusta que permita la recolección y transmisión de datos en tiempo real (IoT, 5G, edge computing). También se deben diseñar mecanismos de seguridad y privacidad para proteger los datos sensibles recogidos por sensores y vehículos conectados.

Además, los resultados evidencian que cada entorno urbano responde de manera distinta: lo que funciona eficazmente en Coronado puede necesitar ajustes en un entorno como Argüelles, más denso y con geometría vial distinta. Esto implica que los algoritmos deben ser contextualmente adaptables, calibrados para las condiciones específicas de cada zona urbana.

6.2 FORTALEZAS Y LIMITACIONES DEL ENFOQUE

La aplicación de modelos de IA y algoritmos adaptativos en la gestión del tráfico ofrece múltiples ventajas, pero también presenta ciertas limitaciones que deben considerarse para su implementación efectiva.

Fortalezas:

Optimización en tiempo real: La IA permite ajustar dinámicamente velocidades, semáforos y rutas en función de las condiciones actuales del tráfico, mejorando el flujo vehicular y reduciendo los tiempos de viaje.

Reducción de congestión y emisiones: Los algoritmos adaptativos pueden minimizar los cuellos de botella y optimizar el uso de las vías, lo que disminuye las emisiones de CO_2 y el consumo de combustible.

Mayor seguridad vial: Detecta patrones de riesgo y ajusta variables como límites de velocidad para reducir la probabilidad de accidentes y facilita la integración con vehículos autónomos y sistemas de asistencia a la conducción.

Integración con infraestructura inteligente: Los sensores IoT (bucles de inducción) permiten recopilar datos en tiempo real para mejorar la toma de decisiones. El Edge Computing agiliza el procesamiento de información sin necesidad de depender de servidores externos.

Adaptabilidad y escalabilidad: Los modelos de IA pueden ser ajustados y mejorados con el tiempo, aprendiendo de nuevos patrones de tráfico y su implementación puede escalar desde intersecciones específicas hasta redes urbanas completas.

Limitaciones:

Dependencia de datos precisos: Los modelos requieren grandes volúmenes de datos en tiempo real para ser efectivos, por ello, datos incompletos o inexactos pueden llevar a predicciones erróneas y decisiones subóptimas.

Costos de implementación y mantenimiento: La instalación de sensores IoT, servidores Edge y redes de comunicación representa una inversión alta. Además, se requieren equipos técnicos especializados para la calibración y mantenimiento del sistema.

Impacto en la aceptación y regulación: La adopción de IA en el tráfico implicaría cambios en políticas públicas y normativas para garantizar su correcta implementación.

Posibles efectos secundarios no deseados: Si los algoritmos no están bien ajustados, pueden provocar redistribución de tráfico en áreas no preparadas para ello.

6.3 CONSIDERACIONES PRÁCTICAS PARA LA IMPLEMENTACIÓN EN EL MUNDO REAL

Implementar un sistema inteligente de gestión del tráfico basado en IA requiere una planificación estratégica y una evaluación realista de los desafíos técnicos, económicos y sociales. A continuación, se presentan las principales consideraciones clave:

Infraestructura Tecnológica y Conectividad

Se necesita una red robusta de sensores IoT (como bucles de inducción) para recopilar datos en tiempo real. Es fundamental contar con conectividad 5G o fibra óptica para el procesamiento rápido y la comunicación eficiente entre dispositivos. Los sistemas deben ser compatibles con plataformas existentes, evitando reemplazos costosos de infraestructura vial.

Calidad y Gestión de Datos

La precisión de los modelos de IA depende de datos confiables, en tiempo real y bien estructurados. Se deben desarrollar algoritmos que puedan filtrar y procesar grandes volúmenes de datos sin generar retrasos. La integración con bases de datos gubernamentales y plataformas de movilidad (como aplicaciones de transporte público y navegación) potenciaría la efectividad del sistema.

Seguridad y Privacidad

Es imprescindible establecer protocolos de ciberseguridad para evitar ataques que puedan alterar el funcionamiento del tráfico. Por otro lado se deberían definir regulaciones claras sobre privacidad de los datos, garantizando el anonimato de los usuarios. Estos sistemas de IA deben ser explicables y auditables, para evitar decisiones opacas que puedan generar desconfianza.

Costos e Inversión Inicial

La implementación requiere financiación pública o colaboración con el sector privado y los costos pueden amortizarse a través de la reducción de congestión, accidentes y contaminación, mejorando la eficiencia del transporte urbano.

Aceptación y Adaptación por Parte de la Sociedad

La tecnología debe ser fácil de integrar y comprender por parte de los conductores y peatones. Es probable, que se necesiten campañas de educación vial para que los usuarios

confíen en el nuevo sistema y lo utilicen correctamente. Además, sería obligatorio establecer un mecanismo de respuesta a fallos, para evitar colapsos en caso de errores técnicos o desconexiones.

6.4 TRABAJO FUTURO Y DIRECCIONES DE INVESTIGACIÓN

A pesar de los buenos resultados obtenidos en los distintos entornos simulados, el campo de la gestión inteligente del tráfico mediante IA y tecnologías asociadas presenta aún múltiples oportunidades de mejora e investigación. Los escenarios de Pacific Beach, Coronado y Argüelles han evidenciado no solo la viabilidad de este tipo de sistemas, sino también sus límites actuales, lo cual abre la puerta a nuevas líneas de trabajo.

Mejora de Modelos de IA y Edge Computing

Desarrollo de modelos de IA más avanzados y explicables, que puedan tomar decisiones de tráfico con mayor precisión y transparencia.

Los modelos actuales han mostrado una mejora clara en la congestión y las emisiones, pero aún pueden perfeccionarse para lograr una mayor precisión y explicabilidad. Por ejemplo, aunque en Argüelles se logró reducir la congestión total de forma notable (de 10.345 a 2.433), la velocidad media disminuyó. Esto sugiere que se requieren algoritmos más afinados que no solo reduzcan atascos, sino que también mantengan o incluso mejoren la velocidad promedio sin comprometer la estabilidad del flujo vehicular.

Además, los sistemas de edge computing actuales pueden ser mejorados para procesar más tipos de datos en el propio borde de la red (por ejemplo, condiciones climáticas, incidentes o densidad peatonal), disminuyendo la latencia y aumentando la capacidad de respuesta local.

Algoritmos de Control de Tráfico más Sofisticados

Exploración de técnicas de optimización multiobjetivo, considerando factores como congestión, emisiones y seguridad vial simultáneamente.

Actualmente, el control se basa principalmente en criterios de velocidad y congestión, pero sería deseable evolucionar hacia algoritmos que optimicen varios objetivos simultáneamente, incluyendo seguridad vial, impacto ambiental y eficiencia energética. Por ejemplo, si bien Coronado mostró una fuerte reducción de congestión (de más del 80%), los tiempos medios a destino no bajaron sustancialmente. Con una optimización multiobjetivo, se podría mejorar también la eficiencia del recorrido individual de los vehículos.

Integración con Vehículos Autónomos y Smart Cities

Investigación sobre la coordinación entre infraestructuras viales inteligentes y vehículos autónomos, asegurando una comunicación eficiente y segura.

Las ciudades del futuro estarán cada vez más conectadas, y los vehículos autónomos desempeñarán un papel clave en la movilidad urbana. Una futura línea de trabajo será la coordinación entre las infraestructuras inteligentes (como semáforos adaptativos, sensores IoT, etc.) y los vehículos autónomos, asegurando que compartan datos de forma eficiente y segura. En escenarios como el de Pacific Beach, con un tráfico turístico variable, este tipo de integración permitiría adaptar la gestión en tiempo real incluso a eventos imprevistos.

Impacto Medioambiental y Sostenibilidad

Evaluación del impacto de la IA en la reducción de emisiones de CO_2, optimizando rutas y minimizando tiempos de espera en intersecciones.

Aunque las simulaciones han mostrado reducciones significativas en emisiones de CO_2 (como los casi 1.900 g menos en Pacific Beach al aplicar IA), aún se requiere una evaluación más profunda del impacto a largo plazo. Sería interesante investigar cómo se puede integrar la IA con modelos meteorológicos o sistemas de gestión energética urbana para crear soluciones que minimicen emisiones de forma estructural, por ejemplo, incentivando rutas

menos contaminantes o restringiendo dinámicamente accesos en función de los niveles de calidad del aire.

Aspectos Éticos y Regulatorios

Desarrollo de marcos normativos internacionales para garantizar el uso responsable de IA en la gestión del tráfico. Además de investigación en ética algorítmica, asegurando que los modelos de IA sean justos y no discriminen a ciertos grupos de usuarios evitando así sesgos.

El despliegue masivo de IA en sistemas de tráfico plantea retos éticos, legales y de privacidad. Será necesario desarrollar marcos regulatorios que garanticen la protección de datos personales recogidos por sensores o vehículos conectados. Asimismo, los algoritmos deberán ser auditables y justos, evitando sesgos que puedan perjudicar a ciertos barrios, colectivos o tipos de usuarios. En contextos densos como Argüelles, donde las decisiones de tráfico impactan más directamente a los peatones y al transporte público, este tipo de garantías es fundamental.

6.5 CONTRIBUCIÓN Y PUBLICACIÓN

El trabajo realizado ha resultado en un avance significativo en el área de estudio, lo que ha permitido la publicación de un artículo en la revista científica Drones (Cuartil 1, Factor de Impacto 4.4) de la editorial suiza MDPI. Esta publicación valida la calidad y relevancia del estudio desarrollado, reflejando la originalidad y el rigor metodológico aplicados:

Moraga , Á.; de Curtò, J.; de Zarzà, I.; Calafate, C.T. AI-Driven UAV and IoT Traffic Optimization: Large Language Models for Congestion and Emission Reduction in Smart Cities. Drones 2025, 9, 248. https://doi.org/10.3390/drones9040248

Además, por su relevancia y novedad, la publicación fue seleccionada de entre un total de 93 artículos como ‘cover story’ del volumen 9 (issue 4) de la revista (ver ilustración 30). https://www.mdpi.com/2504-446X/9

drones

an Open Access Journal by MDPI

IMPACT FACTOR 4.4

CITESCORE 5.6

CERTIFICATE OF ACCEPTANCE

The certificate of acceptance for the manuscript (**drones-3536708**) titled:

AI-Driven UAV and IoT Traffic Optimization: Large Language Models for Congestion and Emission Reduction in Smart Cities

Authored by:

Álvaro Moraga; J. de Curtò; I. de Zarzà; Carlos T. Calafate

was accepted in *Drones* (ISSN 2504-446X) on 25 March 2025

MDPI

Basel, March 2025

Prof. Dr. Diego González-Aguilera
Editor-in-Chief

Ilustración 29 – Certificado de aceptación

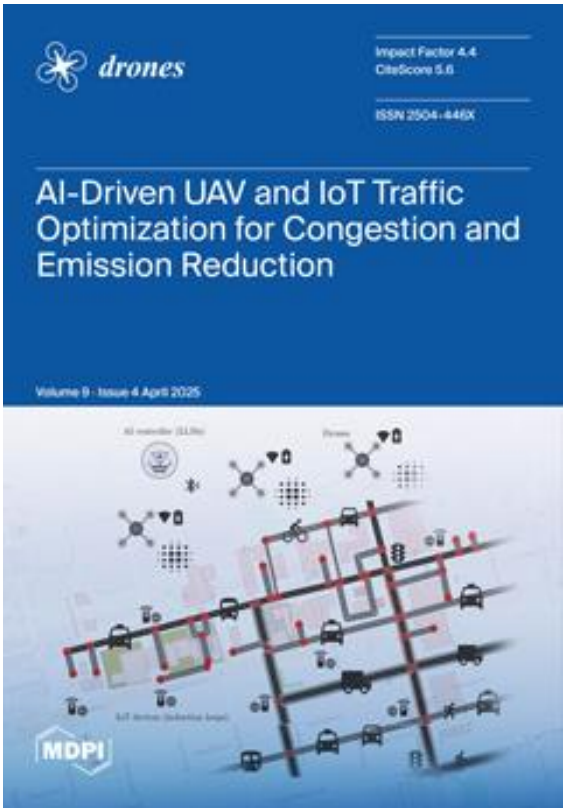

Ilustración 30 – Portada del artículo

Capítulo 7. CONCLUSIÓN

7.1 RESUMEN DE LOS HALLAZGOS

Este proyecto ha explorado la integración de Inteligencia Artificial (IA) y Edge Computing en la gestión inteligente del tráfico, evaluando su impacto en la fluidez vehicular, reducción de emisiones y optimización de velocidades. A continuación, se presentan los principales hallazgos:

Optimización del flujo vehicular

La implementación de algoritmos de IA en la regulación del tráfico ha permitido una gestión dinámica de la velocidad, reduciendo la congestión en intersecciones clave.

Se ha observado que el ajuste adaptativo de la velocidad puede mejorar la fluidez del tráfico en ciertas condiciones, aunque su efectividad varía según la densidad vehicular y la infraestructura existente.

Impacto en el tiempo medio de viaje

Los modelos con IA han mostrado un incremento en el tiempo medio de viaje en ciertos escenarios, lo que sugiere que la optimización enfocada en la reducción de congestión no siempre minimiza el tiempo total de desplazamiento. Este resultado resalta la necesidad de equilibrar fluidez y eficiencia en los trayectos individuales, evitando que la optimización del tráfico global afecte negativamente a ciertos usuarios.

Reducción de emisiones contaminantes

La aplicación de estrategias basadas en IA ha logrado disminuir las emisiones de CO_2 al evitar aceleraciones y frenadas bruscas, promoviendo una conducción más eficiente. Por otro lado, la optimización de la velocidad ha permitido que los vehículos circularan a ritmos más estables, reduciendo el consumo de combustible y las emisiones asociadas.

Aplicación de Edge Computing

El uso de Edge Computing ha permitido procesar datos en tiempo real directamente desde los sensores de tráfico, evitando la latencia de los sistemas centralizados.

Esta arquitectura descentralizada ha demostrado ser clave para una respuesta rápida a condiciones de tráfico cambiantes, especialmente en entornos urbanos densos.

7.2 CONTRIBUCIONES AL CAMPO

Innovación en la regulación del tráfico con IA

Se ha demostrado que los modelos de IA pueden ajustar dinámicamente la velocidad de los vehículos y optimizar la fluidez del tráfico en tiempo real. El enfoque basado en aprendizaje automático permite una adaptación más eficiente a patrones de congestión variables, en comparación con los sistemas tradicionales basados en reglas fijas.

Integración de Edge Computing para procesamiento en tiempo real

Se ha aplicado Edge Computing para procesar datos de sensores IoT en el borde de la red, reduciendo la latencia y mejorando la capacidad de respuesta del sistema.

Este enfoque descentralizado evita la sobrecarga de servidores centrales, permitiendo una gestión del tráfico más escalable y eficiente en ciudades inteligentes.

Impacto en la sostenibilidad y reducción de emisiones

Se ha evidenciado que la optimización de velocidades puede reducir las emisiones de CO_2 al minimizar aceleraciones y frenadas bruscas, promoviendo una conducción más eficiente. La metodología propuesta contribuye a la reducción del consumo energético en infraestructuras viales, alineándose con los objetivos de movilidad sostenible.

Metodología para la simulación y evaluación de sistemas enteligentes de tráfico

Se ha desarrollado un marco de simulación en SUMO (Simulation of Urban MObility) con integración de TraCI (Traffic Control Interface) para evaluar distintos escenarios de control adaptativo del tráfico. Este entorno permite experimentar con distintas estrategias de optimización antes de su implementación en entornos reales, reduciendo costos y riesgos.

Aportes a la toma de decisiones en infraestructura urbana

Los resultados obtenidos pueden servir como base para políticas de movilidad urbana, ayudando a gobiernos y empresas a tomar decisiones informadas sobre infraestructura vial y gestión del tráfico. Se propone un modelo que puede ser personalizado según las necesidades de cada ciudad, adaptándose a diferentes niveles de tráfico y configuraciones urbanas.

7.3 OBSERVACIONES FINALES

Este proyecto ha demostrado el potencial transformador de la inteligencia artificial y el Edge Computing en la gestión del tráfico urbano, resaltando tanto sus beneficios como los desafíos asociados a su implementación en entornos reales.

Avances clave

Se ha validado que el uso de modelos de IA permite mejorar la fluidez del tráfico mediante ajustes dinámicos de velocidad, reduciendo la congestión y optimizando los tiempos de viaje.

Además, la implementación de Edge Computing ha sido clave para el procesamiento eficiente de datos en tiempo real, disminuyendo la latencia y mejorando la capacidad de respuesta del sistema.

Los resultados obtenidos indican que la optimización del tráfico no solo mejora la movilidad urbana, sino que también contribuye a la reducción de emisiones contaminantes, alineándose con los objetivos de sostenibilidad.

Desafíos y consideraciones

A pesar de los beneficios identificados, la implementación en el mundo real requiere superar barreras tecnológicas, regulatorias y económicas.

La interoperabilidad con infraestructuras existentes y la confianza en sistemas basados en IA son aspectos fundamentales que deben abordarse para facilitar su adopción. Cabe destacar, que el comportamiento humano y la aceptación de sistemas autónomos de gestión del tráfico pueden también influir en la efectividad de estas soluciones en escenarios urbanos reales.

Reflexión sobre el futuro

Este estudio representa un paso importante hacia la creación de ciudades inteligentes, pero aún existen oportunidades de mejora y exploración.

La integración con vehículos autónomos y su comunicación con infraestructuras viales abriría nuevas posibilidades, la combinación de IA con técnicas de optimización multiobjetivo podría mejorar aún más la eficiencia de la movilidad urbana y el desarrollo de políticas y regulaciones adaptadas facilitaría la implementación a gran escala de estos sistemas.

Conclusión final

Esta investigación no solo aporta herramientas concretas para la mejora del tráfico urbano, sino que también plantea preguntas y desafíos que guiarán la evolución futura de la movilidad inteligente. Los resultados obtenidos sientan una base sólida para futuras investigaciones y desarrollos tecnológicos, con el objetivo final de construir ciudades más eficientes, sostenibles y conectadas.

Capítulo 8. BIBLIOGRAFÍA

[1] Ulvi, H., Yerlikaya, M. A., & Yildiz, K. (2024). Urban Traffic Mobility Optimization Model: A Novel Mathematical Approach for Predictive Urban Traffic Analysis. Applied Sciences, 14(13), 5873. https://doi.org/10.3390/app14135873

[2] de Zarzà, I.; de Curtò, J.; Roig, G.; Calafate, C.T. LLM Multimodal Traffic Accident Forecasting. Sensors 2023, 23, 9225. https://doi.org/10.3390/s23229225

[3] Movahedi, Mohammad, and Juyeong Choi. "The Crossroads of LLM and Traffic Control: A Study on Large Language Models in Adaptive Traffic Signal Control." IEEE Transactions on Intelligent Transportation Systems (2024)

[4] Akhtar, Mahmuda, and Sara Moridpour. "A review of traffic congestion prediction using artificial intelligence." Journal of Advanced Transportation 2021.1 (2021): 8878011.

[5] Moraga , Á., de Curtò, J., de Zarzà, I., & Calafate, C. T. (2025). AI-Driven UAV and IoT Traffic Optimization: Large Language Models for Congestion and Emission Reduction in Smart Cities. Drones, 9(4), 248. https://doi.org/10.3390/drones9040248

[6] Herrero Alcántara, T. "Big Data: ¿Moda u oportunidad de negocio para el emprendedor?", Think Big, Octubre 201 4. http://blogthinkbig.com/big-data-emprendedor/.

[7] Loeffler, B. "Cloud Computing: What is Infrastructure as a Service", Microsoft Technet Magazine, October 211. https://technet.microsoft.com/en-us/magazine/hh509051.aspx

[8] Vlassis, N.A.; Papakonstantinou, G.; Tsanakas, P. *Dynamic sensory probabilistic maps for mobile robot localization.* Source: Proceedings. 1998 IEEE / RSJ International Conference on Intelligent Robots and Systems. Innovations in Theory, Practice and Applications (Cat. No.98CH36190) New York, NY, USA: IEEE, 1998.p.718-23 vol.2 of 3 vol. xliv+2010 pp. 11.

[9] OECD. (2023). *OECD.org - OECD*. Oecd.org. https://www.oecd.org

[10] United States Environmental Protection Agency. (2023). *US EPA*. US EPA. https://www.epa.gov

[11] *Urban mobility*. (2016, September 22). European Commission. https://ec.europa.eu/transport/themes/urban/urban_mobility_en

[12] IEEE. (2024). *IEEE Xplore Digital Library*. Ieee.org. https://ieeexplore.ieee.org/Xplore/home.jsp

[13] *Aviator*. (2019). Itsworldcongress.org. https://www.itsworldcongress.org

[14] *Making sense of IoT (Internet of Things) - the IoT business guide*. (n.d.). I-SCOOP. https://www.i-scoop.eu/internet-of-things-iot/

[15] ResearchGate. (2024). *Researchgate*. ResearchGate; ResearchGate. https://www.researchgate.net

[16] *IoT World Today*. (n.d.). IoT World Today. https://www.iotworldtoday.com

[17] IEEE. (2024). *IEEE Xplore Digital Library*. Ieee.org. https://ieeexplore.ieee.org/Xplore/home.jsp

[18] *Eclipse SUMO - Simulation of Urban MObility*. (n.d.). Eclipse SUMO - Simulation of Urban MObility. https://www.eclipse.org/sumo/

[19] *SUMO Documentation*. (2018). Sumo.dlr.de. https://sumo.dlr.de/docs/

[20] *TRA2026 ReGeneration in transport*. (2025). Traconference.eu. https://www.traconference.eu

[21] ResearchGate. (2024). *Researchgate*. ResearchGate; ResearchGate. https://www.researchgate.net

[22] Shah, A., & Singh, S. (2023). Traffic flow simulations and their role in urban planning: A review of methodologies and applications. *International Journal of Transportation Systems*, 29(3), 245-267.

[23] Wang, T., Zhang, L., & Liu, H. (2022). Deep learning-based traffic simulations: Enhancing predictive accuracy with neural networks. *Journal of Artificial Intelligence in Traffic Engineering*, 15(4), 398-415.

[24] Hao, R., & Ruan, T. (2024). Advancing traffic simulation precision and scalability: A data-driven approach utilizing deep neural networks. *Sustainability, 16*(7), 2666. https://doi.org/10.3390/su16072666

[25] Karunakaran, D., Berrio Perez, J. S., & Worrall, S. (2024). Generating edge cases for testing autonomous vehicles using real-world data. *Sensors, 24*(1), 108. https://doi.org/10.3390/s24010108

[26] Zhao, L., & Li, D. (2021). Big data analytics for smart city traffic management: Trends and challenges. Journal of Big Data, 8(34), 1-15.

[27] Wang, D., Cai, Z., Zeng, J., Zhang, G., & Guo, J. (2020). Review of traffic data collection research on urban traffic control. *Journal of Transportation Systems Engineering and Information Technology, 20*(3), 95-102.

[28] Deep Learning on Traffic Prediction: Methods, Analysis, and Future Directions. (2024). *IEEE Journals & Magazine*.

[29] Nguyen, G., Dlugolinsky, S., Bobák, M., Tran, V., López García, Á., & Heredia, I., et al. (2019). Machine learning and deep learning frameworks and libraries for large-scale data mining: A survey. *Artificial Intelligence Review, 52*(1), 77-124. https://doi.org/10.1007/s10462-018-09679-z

[30] Alghamdi, T., et al. (2019). Forecasting traffic congestion using ARIMA modeling. *2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC)*. IEEE

[31] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature, 521*(7553), 436–444.

[32] Jannah, N., Gunawan, T. S., Yusoff, S. H., Hanifah, M. S. A., & Sapihie, S. N. M. (2024). Recent Advances and Future Challenges of Solar Power Generation Forecasting. *IEEE Access*.

[33] Katambire, V. N., Musabe, R., Uwitonze, A., & Mukanyiligira, D. (2023). Forecasting the Traffic Flow by Using ARIMA and LSTM Models: Case of Muhima Junction. *Forecasting*, *5*(4), 616-628. https://doi.org/10.3390/forecast5040034

[34] Jang, H. -C., & Chen, C. -A. (2023). Urban Traffic Flow Prediction Using LSTM and GRU. *Engineering Proceedings*, *55*(1), 86. https://doi.org/10.3390/engproc2023055086

[35] Ren, Y., Xie, R., Yu, F. R., Zhang, R., Wang, Y., He, Y., & Huang, T. (2024). Connected and Autonomous Vehicles in Web3: An Intelligence-Based Reinforcement Learning Approach. *IEEE Transactions on Intelligent Transportation Systems*.

[36] Silva, A. M., Almeida, P., & Matos, A. (2020). Edge case modeling in traffic simulations: Challenges and solutions. Journal of Traffic and Transportation Engineering, 7(6), 295-309. https://doi.org/10.1016/j.jtte.2020.07.005

[37] Northeastern University. (2024). *Singapore's innovative approach to traffic management and pollution control*. Retrieved from https://econ.sites.northeastern.edu/wiki/microeconomics/markets-and-government/singapores-innovative-approach-to-traffic-management-and-pollution-control/

[38] de Zarzà, I., de Curtò, J., Roig, G., & Calafate, C. T. (2023). LLM adaptive PID control for B5G truck platooning systems. *Sensors, 23*(5899). https://doi.org/10.3390/s23135899

[39] Naciones Unidas. (2015). *Objetivos de Desarrollo Sostenible: ODS 11* https://sdgs.un.org/goals/goal11

[40] de Zarzà, I., de Curtò, J., & Calafate, C. T. (2023). Decentralized planning of platoons in road transport using reinforcement learning. *2023 IEEE 43rd International Conference on Distributed Computing Systems Workshops (ICDCSW)*, 133–138. https://doi.org/10.1109/ICDCSW60045.2023.00030

ANEXO I: ALINEACIÓN DEL PROYECTO CON LOS ODS

La implementación de soluciones tecnológicas en la gestión del tráfico urbano no solo persigue la mejora operativa de las ciudades, sino que también tiene una repercusión directa en metas globales relacionadas con el desarrollo sostenible. Este proyecto, centrado en la optimización del tráfico mediante inteligencia artificial y tecnologías asociadas como IoT y Edge Computing, contribuye de manera significativa a varios de los Objetivos de Desarrollo Sostenible (ODS) propuestos por las Naciones Unidas en la Agenda 2030 [9, 39].

ODS 9: Industria, innovación e infraestructura

El proyecto también representa un avance en el desarrollo de infraestructuras urbanas modernas mediante el uso de tecnologías emergentes. La integración de sensores de IoT para la recopilación de datos en tiempo real, el Edge Computing para el procesamiento local de la información, y el uso de plataformas como SUMO para la simulación avanzada, son ejemplos claros de innovación tecnológica aplicada al transporte [26].

Estos elementos fomentan el desarrollo de infraestructuras inteligentes, resilientes y sostenibles, en línea con lo que propone el ODS 9. Además, al combinar diferentes tecnologías en una arquitectura funcional, el trabajo también sirve como modelo de referencia para futuras implementaciones en ciudades inteligentes.

ODS 11: Ciudades y comunidades sostenibles

Uno de los objetivos principales del proyecto es mejorar la eficiencia y sostenibilidad de la movilidad urbana. Mediante algoritmos adaptativos que ajustan dinámicamente la velocidad o priorizan ciertos flujos de tráfico, se consigue una reducción considerable de la congestión.

Esto se traduce en calles menos saturadas, menor tiempo de espera en intersecciones y un uso más racional de la infraestructura vial. En última instancia, estas mejoras contribuyen al desarrollo de ciudades más inclusivas, seguras, resilientes y sostenibles, tal como propone el ODS 11 [20].

Además, al simular escenarios en distintos entornos urbanos como Pacific Beach, Coronado o Argüelles, el proyecto pone en evidencia cómo distintas configuraciones de red y niveles de tráfico afectan la eficiencia del sistema, aportando conocimiento aplicable a distintas realidades urbanas.

ODS 13: Acción por el clima

El transporte urbano es uno de los principales responsables de las emisiones de gases de efecto invernadero. A través del uso de sistemas inteligentes que permiten reducir los tiempos de inactividad del vehículo, optimizar la circulación y evitar retenciones prolongadas, este proyecto logra una disminución significativa de las emisiones de CO_2. Por ejemplo, en las simulaciones realizadas, los entornos con control adaptativo mostraron reducciones de más del 75% en emisiones frente a configuraciones sin IA [37].

Estas mejoras tecnológicas no solo tienen un beneficio local, sino que contribuyen directamente a los esfuerzos globales de mitigación del cambio climático, alineándose con las metas del ODS 13.

ANEXO II

OpenStreetMap (OSM) y su utilidad en el proyecto

OpenStreetMap (OSM) es una plataforma colaborativa de cartografía libre que proporciona datos geoespaciales abiertos y detallados a nivel mundial. A través de su estructura basada en nodos, caminos y relaciones, permite representar con precisión infraestructuras viales, edificaciones y otros elementos urbanos relevantes.

En el presente proyecto, OpenStreetMap ha sido utilizado como fuente primaria para la obtención de las redes viales del área de estudio. Gracias a su compatibilidad con herramientas como NETEDIT (parte del ecosistema de SUMO), ha sido posible generar redes viarias simulables de manera eficiente y con alta fidelidad respecto al entorno urbano real. Esto ha permitido reducir significativamente el tiempo de modelado, garantizar una representación topológicamente coherente del sistema de transporte y facilitar el análisis de tráfico en un entorno simulado basado en datos reales.

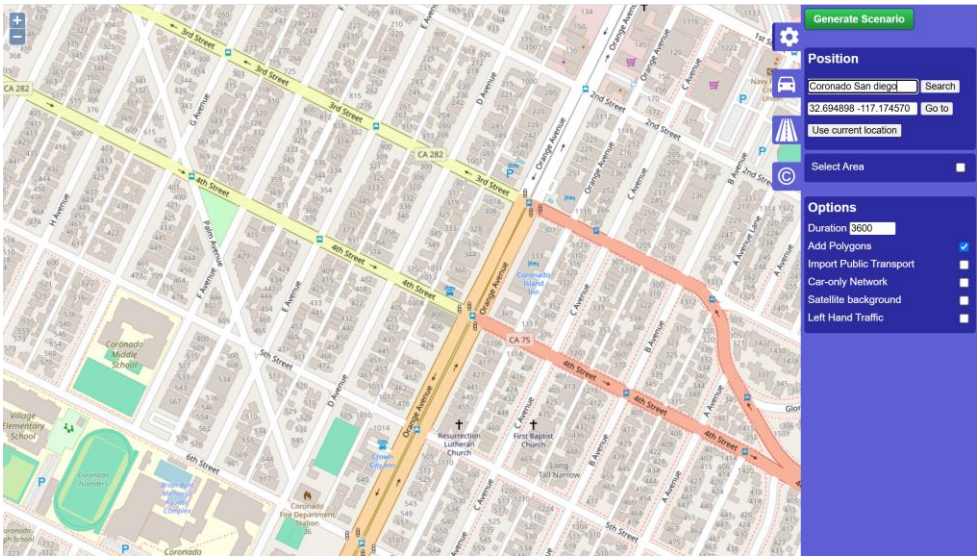

Ilustración 31 – Creación del entorno de Coronado con OpenStreetMap

NETEDIT y su papel en la edición de la red vial

NETEDIT es una herramienta gráfica perteneciente al ecosistema de SUMO (Simulation of Urban MObility), diseñada para la edición manual y visual de redes de tráfico. Esta aplicación permite modificar atributos de nodos, conexiones, carriles y elementos adicionales como semáforos o sensores, proporcionando una interfaz intuitiva para realizar ajustes precisos sobre redes previamente generadas, por ejemplo, a partir de OpenStreetMap.

En el contexto del presente proyecto, NETEDIT ha sido esencial para personalizar el entorno simulado mediante la inserción de bucles de inducción. Estos sensores virtuales permiten emular la recogida de datos de tráfico en puntos estratégicos de la red, posibilitando análisis más detallados sobre el flujo vehicular, densidad y velocidad. Gracias a NETEDIT, fue posible ubicar estos elementos de forma precisa en las intersecciones de interés, ajustando sus parámetros según las necesidades específicas del estudio.

Ilustración 32 – Implantación de bucles de inducción en el entorno de edición NETEDIT