

IMPACTO DE LA PROXIMIDAD DE LOS PUNTOS DE INTERÉS EN LA CONGESTIÓN DE TRÁFICO: UN ENFOQUE BASADO EN LA DENSIDAD DE KERNEL

Ernesto de la Cruz-Nicolás^{1,2}, Hugo Estrada-Esquível¹, Alicia Martínez-Rebollar¹, Odette Pliego-Martínez^{1,3}

¹*Tecnológico Nacional de México/Centro Nacional de Investigación y Desarrollo Tecnológico, (MÉXICO).*

²*Tecnológico Nacional de México / Tecnológico de Cuautla (MÉXICO)*

³*Tecnológico Nacional de México / Tecnológico de Milpa Alta (MÉXICO)*

Resumen

Esta investigación examina cómo la proximidad de puntos de interés, como tiendas, restaurantes, hospitales, escuelas, parques y oficinas, influye en la congestión del tráfico en áreas urbanas. Utilizando un enfoque de Densidad de Kernel, el análisis busca entender cómo la concentración de estos puntos afecta los patrones de tráfico y la densidad en diferentes zonas. El método de Densidad de Kernel permite estimar la intensidad del tráfico en áreas específicas, creando centroides de áreas dinámicas que muestra las regiones con mayor y menor congestión. El estudio integra datos geoespaciales sobre la ubicación de puntos de interés y los patrones de tráfico, identificando correlaciones entre la cercanía de estos puntos y los niveles de congestión. Los resultados indican que una alta densidad de puntos de interés en una zona tiende a incrementar el tráfico y la congestión, especialmente en áreas de alto atractivo comercial o recreativo. El estudio proporciona información valiosa para urbanistas y responsables de transporte al ofrecer alternativas sobre cómo la ubicación de puntos de interés puede ser optimizada para mejorar la fluidez del tráfico y reducir la congestión en áreas urbanas.

Palabras clave: Congestión de tráfico, densidad, kernel, puntos de interés.

Abstract

This research examines how the proximity of points of interest, such as shops, restaurants, hospitals, schools, parks, and offices, influences traffic congestion in urban areas. Using a Kernel Density approach, the analysis seeks to understand how the concentration of these points affects traffic patterns and density in different zones. The Kernel Density method allows for estimating traffic intensity in specific areas, creating centroids of dynamic areas that highlight regions with higher and lower congestion. The study integrates geospatial data on the location of points of interest and traffic patterns, identifying correlations between the proximity of these points and congestion levels. The results indicate that a high density of points of interest in an area tends to increase traffic and congestion, especially in zones with high commercial or recreational appeal. The study provides valuable insights for urban planners and transportation officials by offering perspectives on how the location of points of interest can be optimized to improve traffic flow and reduce congestion in urban areas.

Keywords: Traffic congestion, density, kernel, points of interest.

1 INTRODUCCIÓN

La congestión del tráfico es uno de los problemas más preocupantes que enfrentan las ciudades modernas [1]. A medida que las áreas urbanas crecen y se desarrollan, el aumento en la densidad de población y el crecimiento económico generan una presión adicional sobre las infraestructuras de transporte, intensificando los problemas de congestión de tráfico [2]. En este contexto, los puntos de interés (POIs) tales como centros comerciales, restaurantes, escuelas, hospitales, oficinas y lugares de entretenimiento juegan un papel importante en la movilidad vehicular. La ubicación y concentración de estos POIs pueden

influir significativamente en los patrones de movilidad y en los niveles de congestión en distintas zonas geográficas de la ciudad [3], [4].

Esta investigación se centra en la relación entre la proximidad de POIs y la congestión del tráfico de las calles mediante el uso de una técnica avanzada de análisis espacial. Utilizando un enfoque de Densidad de Kernel, el estudio busca proporcionar una comprensión de cómo la distribución espacial de estos puntos impacta en la intensidad del tráfico en diferentes calles urbanas. El método de Densidad de Kernel es una técnica estadística que permite la visualización de datos espaciales en forma de mapas de calor [5], facilitando la identificación de patrones y áreas de alta congestión.

La relevancia de este análisis radica en su capacidad para ofrecer una perspectiva clara sobre cómo la concentración de POIs puede contribuir a la congestión del tráfico. Al integrar datos sobre la ubicación de POIs con información sobre patrones de tráfico, el estudio no solo proporciona una visión detallada de las interacciones entre estos factores, sino que también ofrece un modelo de función de kernel. La comprensión de estas interacciones es esencial para desarrollar estrategias efectivas que puedan mitigar los problemas de congestión y mejorar la movilidad en las ciudades.

Además, los resultados de este estudio pueden informar a los responsables de la formulación de políticas y a los planificadores urbanos sobre cómo la disposición de POIs en el entorno urbano puede ser optimizada para promover un flujo de tráfico más eficiente. Al identificar las calles donde la proximidad de POIs genera una mayor congestión, se pueden implementar intervenciones más específicas y orientadas a reducir los embotellamientos y mejorar la calidad de vida urbana. En última instancia, este estudio contribuye a una comprensión más profunda de los POIs que afectan la congestión del tráfico y proporciona una base sólida para la toma de decisiones informadas en el ámbito del urbanismo y el transporte.

1.1 Trabajos relacionados

La congestión de tráfico es un problema urbano significativo que existe en grandes ciudades del mundo. La rápida urbanización, y el incremento de la demanda de transporte, ha llevado a una mayor necesidad de comprender las dinámicas que contribuyen a la congestión vial. Un aspecto relevante es el impacto de la proximidad de los POIs a las redes viales en la congestión del tráfico, debido al desequilibrio en la distribución de empleos, puntos de recreación, salud, educación y viviendas [6].

El enfoque de Densidad de Kernel se ha utilizado para mapear la distribución espacial de los POIs y evaluar su impacto en la congestión del tráfico. Los estudios han demostrado que los POIs cercanos a las principales vías de transporte pueden tener un impacto significativo en la congestión vial [7]. La investigación de [8] ha mostrado que, en áreas urbanas densamente pobladas, los POIs que se relacionan con las actividades sociales, como centros comerciales y zonas recreativas, contribuyen significativamente a la congestión debido a los altos flujos de tráfico generados en estas zonas.

En la investigación de [9] analizaron los POIs con flujos bidireccionales, como los centros comerciales que atraen tanto a los residentes locales como a los visitantes, son más propensos a causar congestión que los POIs con flujos unidireccionales, como las oficinas y fábricas que operan principalmente durante las horas laborales [10]. El uso de Densidad de Kernel se ha utilizado en varios enfoques como el trabajo de [11] ha desarrollado un modelo para el reconocimiento de puntos críticos de accidentes utilizando un enfoque basado en la estimación de Densidad de Kernel adaptativa combinado con un índice de riesgo vial. Este modelo emplea el método de estimación de Densidad de Kernel adaptativa para identificar y analizar la concentración de accidentes en áreas específicas, permitiendo así determinar el porcentaje de accidentes ocurridos en distintos agrupamientos de calles.

La investigación de [12] identifica y clasifica las zonas de alta densidad de accidentes empleando métodos como la Estimación de Densidad de Kernel y la delimitación de áreas de alta densidad. El objetivo principal es localizar las áreas con mayor peligro y congestión de tráfico. La Densidad de Kernel destaca como una herramienta particularmente adecuada para analizar el impacto de la proximidad de los POI en la congestión del tráfico, ya que permite estimar la densidad espacial de manera no paramétrica. Esta técnica facilita la evaluación de cómo la concentración de POI en diferentes áreas afecta los niveles de congestión en las vialidades.

2 METODOLOGÍA

Esta sección describe la metodología utilizada para estudiar el impacto de la proximidad de Puntos de Interés (POI) en la congestión del tráfico. La metodología se estructura en cinco fases: la Fase 3.1 presenta el caso de estudio, proporcionando el contexto y alcance del análisis. En la Fase 3.2, se detalla la recopilación de datos, incluyendo información sobre los POI y los datos relacionados con la congestión del tráfico. La Fase 3.3 aborda el preprocesamiento de los datos para asegurar su calidad, consistencia y uniformidad. La Fase 3.4 describe la estimación de la Densidad de Kernel como método clave para analizar la relación entre la proximidad de los POI y la congestión del tráfico. Finalmente, en la Fase 3.5, se realiza el análisis de los resultados, ofreciendo una interpretación detallada de las correlaciones identificadas entre la densidad de los POI y los niveles de congestión

2.1 Caso de estudio

La Ciudad de México, una de las urbes más grandes y congestionadas del mundo según [13], ofrece un escenario clave para examinar el impacto de la proximidad de los puntos de interés (POI) en la congestión vial. Con una alta densidad poblacional y redes de transporte complejas, la ciudad enfrenta grandes retos en la gestión del tráfico [14]. Según el informe de INRIX 2023, la Ciudad de México se mantiene entre las ciudades más congestionadas del mundo. El comportamiento del tráfico en sus calles varía dinámicamente a lo largo de la semana, como se ilustra en la Figura 1.

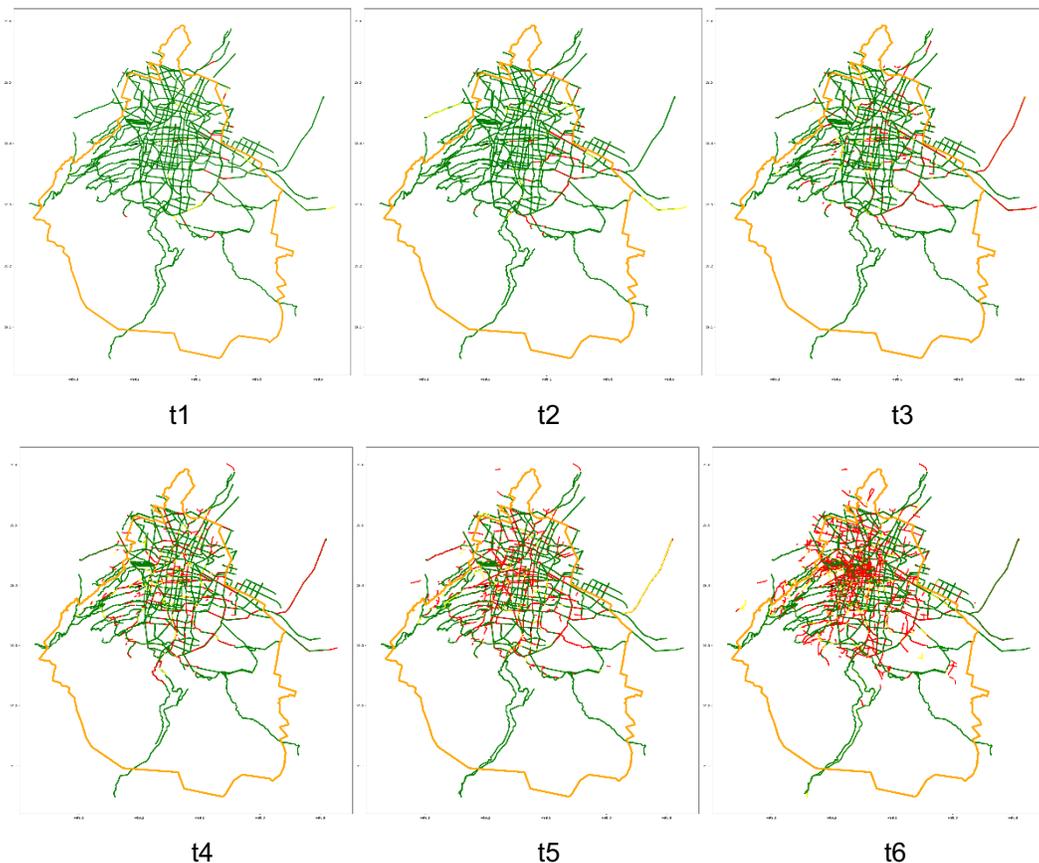


Figura 1. En distintos momentos (t1-t6), las calles presentan un alto nivel de fluidez en la movilidad; sin embargo, en ciertos periodos, esas mismas vías pueden volverse completamente congestionadas.

2.2 Recopilación de datos

Se recopilan datos extensivos sobre POIs en las 16 alcaldías de la Ciudad de México, abarcando centros comerciales, restaurantes, oficinas y atracciones culturales, utilizando la fuente Geoapify [15]. Concurrentemente, se obtienen datos de congestión del tráfico a través de aplicaciones de mapas, como TomTom Traffic [16] y Here Maps [17], con intervalos de cinco minutos. Estos datos se recogen durante el período de febrero a julio de 2024, las 24 horas del día, acumulando aproximadamente 1 gigabyte de información sobre el tráfico de manera diaria.

2.2.1 Datos de puntos de interés

Para la recolección de datos de POIs en la Ciudad de México, se utilizó la plataforma Geoapify, que ofrece información detallada sobre una amplia variedad de POI en las 16 alcaldías de la ciudad. Esta fuente cubre diversas categorías, incluyendo alojamiento, comercios, restaurantes, educación, cuidado infantil, entretenimiento, atención sanitaria, ocio, oficinas, turismo, y servicios, entre otros, asegurando una cobertura exhaustiva de los principales lugares de interés. Se extrajeron los datos para representar de manera precisa la distribución y densidad de los POI en cada área, colocando 10 centroides en cada alcaldía, obteniendo un total de 160 centroides colocados en la Ciudad de México. La información obtenida se centró en la proximidad entre los POI y las calles situadas en el área de cada centroide de cada calle, en la figura 2 se muestran en puntos de diferentes colores los puntos de interés recolectados de la ciudad de México.

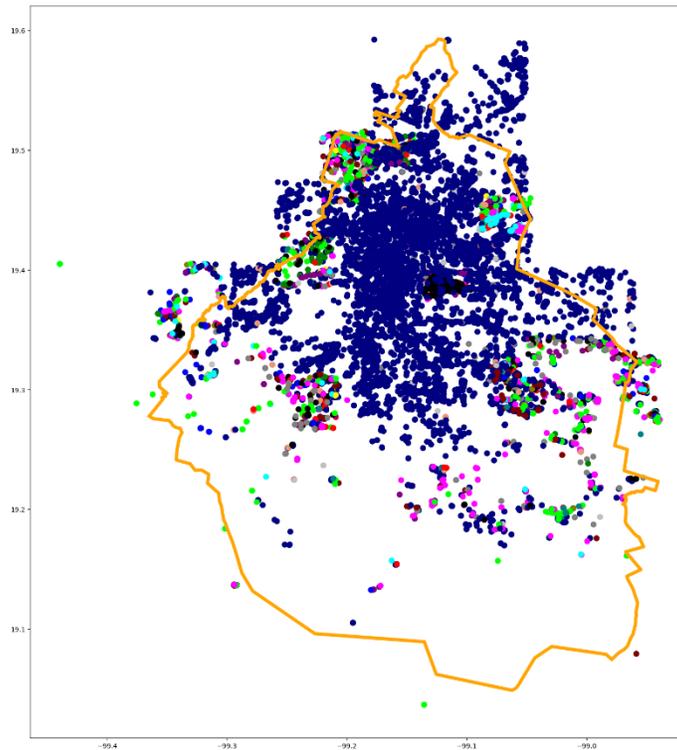


Figura 2. Puntos de interés que se encuentran en las distintas calles de la Ciudad de México.

2.2.2 Datos de congestión del tráfico

Se realizó la recolección de datos de tráfico en 7,024 calles principales de la Ciudad de México, distribuidas por alcaldía como se muestra en la Tabla 1. Para esta tarea, se emplearon las aplicaciones de mapas Here Maps y TomTom Traffic, capturando datos de flujo de tráfico las 24 horas del día en intervalos de 5 minutos. Este enfoque permitió la generación diaria de aproximadamente 1,000,000 de registros sobre el flujo de tráfico, resultando en un conjunto de datos total de 180,000,000 de registros, denominado Tráfico-POI, que abarca el período de febrero a julio de 2024. Las variables recopiladas, que se detallan en la Tabla 2, abarcan una amplia gama de indicadores para el análisis de la congestión de tráfico.

Tabla 1. Obtención de datos de congestión de tráfico de las calles de las 16 alcaldías de la Ciudad de México.

Número	Alcaldía	Número de calles
1	Azcapotzalco	316
2	Coyoacán	488
3	Cuajimalpa de Morelos	199
4	Gustavo A Madero	825
5	Iztacalco	431
6	Iztapalapa	795
7	La Magdalena Contreras	105
8	Milpa Alta	27
9	Alvaro Obregon	682
10	Tláhuac	150
11	Tlalpan	307
12	Xochimilco	382
13	Benito Juárez	512
14	Cuauhtémoc	615
15	Miguel Hidalgo	698
16	Venustiano Carranza	492

Tabla 2. Variables del flujo de tráfico.

Número	Variable	Descripción
1	freeFlow	Velocidad máxima permitida, sin encontrar obstáculos significativos como congestiones, paradas frecuentes, o interrupciones en el flujo vehicular.
2	jamFactor	Es una escala que indica qué tan congestionada está un segmento de la calle en un momento dado.
3	length	Se refiere a la longitud de un segmento de carretera o vía en unidades de distancia, como metros o kilómetros.
4	numsegments	Representa una porción individual de la carretera o vía.
5	speed	Se refiere a la velocidad a la que se desplazan los vehículos en un segmento de carretera.
6	speedUncapped	Se refiere a la velocidad real a la que se desplazan los vehículos en un segmento de carretera, sin estar limitada o ajustada por restricciones externas.

2.3 Preprocesamiento de datos

El preprocesamiento de los datos de tráfico y de los puntos de interés se realizó en dos etapas, con el objetivo de mejorar la calidad y la uniformidad de los datos. Este proceso incluyó la transformación de datos para mejorar su distribución y la estandarización para corregir las diferentes escalas de las variables. A continuación, se describen en detalle los pasos llevados a cabo:

Paso 1, transformar los datos: Se utilizó la transformación cúbica [18], aplicada mediante la ecuación 1, en el conjunto de datos de Tráfico-POI.

$$\text{Variable normalizada} = \sqrt[3]{\text{Variable original}} \quad (1)$$

Los hallazgos derivados de la normalización del conjunto de datos de tráfico y puntos de interés indican que la aplicación de una transformación cúbica ha producido una mejora significativa en la normalidad de los datos. Esta transformación ha permitido una distribución más simétrica y cercana a la normalidad, lo que facilita un análisis más preciso y fiable.

Paso 2, estandarizar los datos: Se realizó la estandarización Z-score [19] en el conjunto de datos de Tráfico-POI, en una escala común con una media de 0 y una desviación estándar de 1. Esta estandarización se efectuó utilizando la ecuación número 2.

$$z = \frac{x - \mu}{\sigma} \quad (2)$$

Dónde:

z es el valor estandarizado.

x es el valor original del dato que se está estandarizando.

μ es la media del conjunto de datos.

σ es la desviación estándar del conjunto de datos.

La estandarización ajustó todas las variables del conjunto de datos de Tráfico-POI a una media de 0 y una desviación estándar de 1. Este proceso asegura que todas las variables estén en una escala uniforme, permitiendo comparaciones directas y consistentes entre ellas.

2.4 Estimación de la densidad de kernel para la congestión del tráfico

Para modelar cómo los puntos de interés (POIs) afectan la densidad del tráfico en las calles según su proximidad, se propone una modificación de la función de kernel, tal como se muestra en la ecuación 3, que integre la distancia de cada servicio a los centroides de las calles.

$$C_j = C_{base} + k \cdot \left(\sum_{i=1}^N \frac{P_i}{d(i,j)} \right) \quad (3)$$

Dónde:

C_j es el nivel de congestión en la calle j .

C_{base} es un nivel base de congestión que depende de condiciones inherentes a la calle, como su capacidad o nivel de uso.

k : es un factor de ponderación que determina cuánto afectan los puntos de interés a la congestión.

P_i es el número de puntos de interés en la posición i , dentro del área del centroide.

$d(i,j)$ distancia en metros entre el punto de interés i y la calle j .

N es el número de puntos de interés en el área del centroide.

Se ubicaron tres centroides con un diámetro de 500 metros en cada calle: uno al inicio, uno en el punto medio y uno al final de la calle, obteniendo un total de 21,072 centroides para toda la Ciudad de México. Se obtuvieron las distancias en metros entre los centroides de las calles y los puntos de interés (POIs) dentro del radio de cada centroide, utilizando el trazado de rutas de Geoapify. Las variables de las distancias se muestran en la Tabla 3.

Tabla 3. Variables de distancia entre los centroides de las calles y POIs situados en su área.

Variable	Descripción
C1_dn_POIn	Distancia en metros entre el centroide situado al inicio de la calle y el POI.
C2_dn_POIn	Distancia en metros entre el centroide situado a la mitad de la calle y el POI.
C3_dn_POIn	Distancia en metros entre el centroide situado al final de la calle y el POI.

Aplicando la ecuación 3, se generó un conjunto de datos que representa las distancias entre un centroide y los n POI circundantes dentro de un área de 500 metros. Esta estrategia se aplicó a los 21,072 centroides. En la tabla 4 se presenta un fragmento de las distancias entre el centroide y los puntos de interés (POI). Se utilizó la nomenclatura $C_n_dn_POIn$ donde C_n indica la ubicación del centroide: C1 para el inicio de la calle, C2 para el centro de la calle y C3 para el final de la calle. Por otro lado, dn y $POIn$ representan el número de la distancia entre el centroide y el POI. Por ejemplo, el centroide con el POI 1 corresponde a d_1 , el centroide con el POI 2 corresponde a d_2 , y así sucesivamente.

Table 4. Distancias entre los centroides y los POI que se encuentran en su área.

Centroide	Distancia con POI	Centroide	Distancia con POI
C1_d1_POI1	301	C1_d8_POI8	79
C1_d2_POI2	422	C1_d9_POI9	96
C1_d3_POI3	467	C1_d10_POI10	387
C1_d4_POI4	104	C1_d11_POI11	120
C1_d5_POI5	75	C1_d12_POI12	450
C1_d6_POI6	30	C1_d13_POI13	252
C1_d7_POI7	81	C1_d14_POI14	67

2.5 Análisis

La congestión de tráfico en las ciudades está influenciada por múltiples factores, entre ellos la cantidad y proximidad de POIs como comercios, oficinas y centros de servicio. La concentración de estos POIs en determinadas áreas puede generar un aumento en el tráfico, afectando la fluidez vehicular en las calles cercanas. Para modelar esta influencia, se propone la ecuación 3, es importante considerar tanto la cantidad de POIs como su distancia relativa a las calles. A continuación, se describe cómo la proximidad de los POIs afecta el nivel de congestión de las calles, representado por la variable C_j .

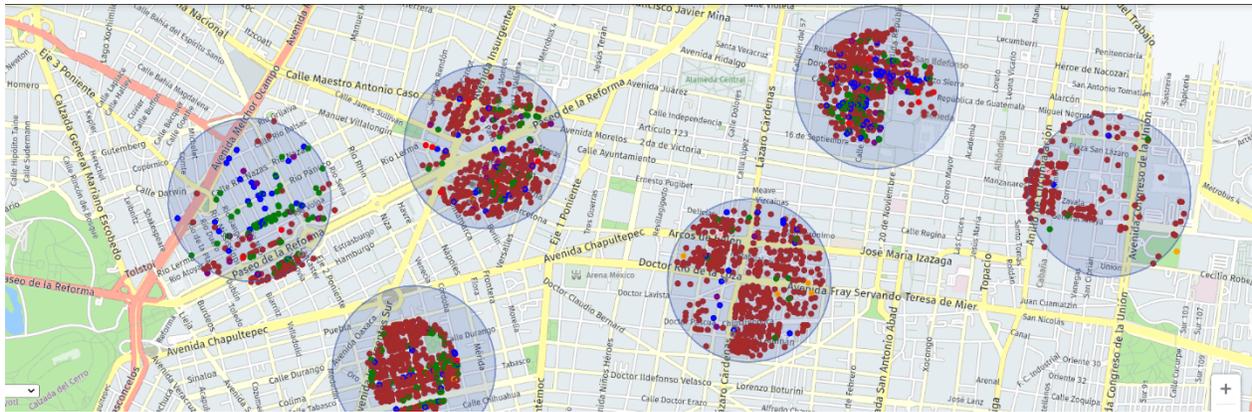
Si hay muchos puntos de interés cerca de la calle j , entonces la suma $\sum_{i=1}^N \frac{P_i}{d(i,j)}$ será alta, lo que aumentará el valor de C_j generando más congestión en la calle. Por lo contrario, si los puntos de interés están alejados de la calle j , entonces la afectación en C_j se reduce debido al aumento de $d(i,j)$, generando menor congestión en la calle. Por lo anterior con la teoría difusa se presenta una escala de valores para representar

Congestión baja (calles en color verde): Si $C_j < 0.3$, la calle tiene un tráfico fluido.

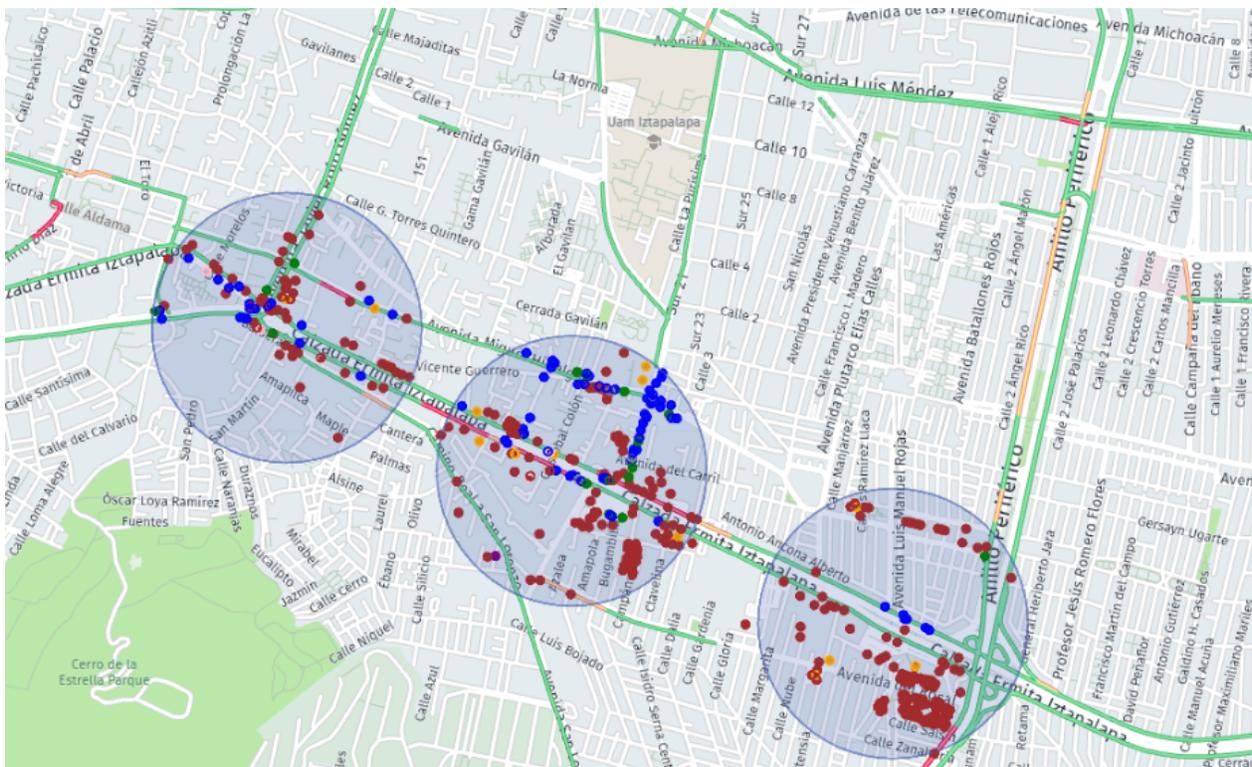
Congestión moderada (calles en color amarillo): Si $0.3 \leq C_j < 0.6$, la calle experimenta una congestión leve.

Congestión alta (calles en color rojo): Si $C_j \geq 0.6$, la calle está altamente congestionada.

Este enfoque difuso nos permite modelar la relación entre la densidad de puntos de interés y la congestión de tráfico dentro de un área delimitada por el centroide. La idea clave es que, a mayor densidad de puntos de interés, mayor será la afectación en la congestión de las calles dentro de esa área, como se muestra en la Figura 3.



a)



b)

Figura 3. Las calles asociadas con el centroide 2 muestran una mayor congestión de tráfico en comparación con los centroides 1 y 3. Esto se debe a la mayor cantidad de POIs ubicados en el área del centroide, que se representan mediante puntos de varios colores.

3 RESULTADOS

Los resultados revelan que la proximidad de POIs a las redes viales tiene un efecto notable en la congestión del tráfico. La aplicación del enfoque de Densidad de Kernel mostró que áreas con alta concentración de POIs tienden a experimentar mayores niveles de congestión. Los POIs vinculados a actividades sociales y comerciales, como centros comerciales y zonas recreativas, incrementan significativamente la congestión en comparación con otros POIs, como oficinas. Además, se observó que los POIs con flujos bidireccionales, como los centros comerciales que atraen tanto a residentes como a visitantes, contribuyen más a la congestión que los POIs con flujos unidireccionales, como oficinas y fábricas. Los POIs con tráfico flexible,

como restaurantes, generan un impacto mayor en la con-gestión en comparación con los POIs con patrones de tráfico más predecibles, como oficinas gubernamentales. La discusión destaca la importancia de integrar estos hallazgos en la planificación urbana para mitigar la congestión, sugiriendo estrategias como la redistribución de POIs y la mejora de la infraestructura vial en áreas con alta concentración de POIs. Estas recomendaciones buscan mejorar la eficiencia del tráfico y reducir la congestión en las ciudades.

4 CONCLUSIONES

La proximidad de POIs a las redes viales tiene un impacto significativo en la congestión del tráfico. Los resultados indican que las áreas con alta concentración de POIs, especialmente aquellos relacionados con actividades sociales y comerciales, experimentan mayores niveles de congestión. Los POIs con flujos bidireccionales y tráfico flexible contribuyen más a la congestión que aquellos con flujos unidireccionales y tráfico predecible. La discusión subraya la necesidad de considerar estos factores en la planificación urbana para mitigar la congestión, sugiriendo estrategias como la redistribución de POIs y la mejora de la infraestructura vial.

Para trabajos futuros, se recomienda realizar investigaciones adicionales que exploren cómo otros tipos de POIs y características urbanas pueden afectar la congestión del tráfico. También se sugiere la aplicación de métodos de análisis espacial en diferentes contextos urbanos y regiones geográficas para validar y generalizar los hallazgos. Además, el desarrollo de modelos predictivos que integren variables dinámicas y el uso de tecnologías emergentes, como el análisis en tiempo real de datos de tráfico y POIs, podrían proporcionar nuevas perspectivas y soluciones más efectivas para la gestión del tráfico.

REFERENCIAS

- [1] M. Paucara Rojas, S. E. Avilés Córdova, and S. Huaquisto Cáceres, "Utilización De La Microsimulación Para El Estudio De Tráfico Vehicular En Vías Urbanas," *Investig. Desarrollo*, vol. 23 no.1, pp. 67–77, 2023, doi: 10.23881/idupbo.023.1-5i.
- [2] J. Lu, B. Li, H. Li, and A. Al-Barakani, "Expansion of city scale, traffic modes, traffic congestion, and air pollution," *Cities*, vol. 108, 2021, doi: 10.1016/j.cities.2020.102974.
- [3] C. Lu, "Mapping urban spatial structure based on POI (Point of interest) data: A case study of the central city of Lanzhou, China," *ISPRS Int. J. Geo-Information*, vol. 9, no.2, 2020, doi: 10.3390/ijgi9020092.
- [4] H. Zhu, K. Zhang, C. Wang, L. Jia, and S. Song, "The Impact of Road Functions on Road Congestions Based on POI Clustering: An Empirical Analysis in Xi'an, China," *J. Adv. Transp.*, 2023, doi: 10.1155/2023/6144048.
- [5] K. Cheruiyot, "Detecting spatial economic clusters using kernel density and global and local Moran's I analysis in Ekurhuleni metropolitan municipality, South Africa," *Reg. Sci. Policy Pract.*, vol. 4, no.2, pp. 307–327, 2022, doi: 10.1111/rsp3.12526.
- [6] P. Zhao and H. Hu, "Geographical patterns of traffic congestion in growing megacities: Big data analytics from Beijing," *Cities*, vol.92, pp. 164–174, 2019, doi: 10.1016/j.cities.2019.03.022.
- [7] Z. Bao, S. T. Ng, G. Yu, X. Zhang, and Y. Ou, "The effect of the built environment on spatial-temporal pattern of traffic congestion in a satellite city in emerging economies," *Dev. Built Environ.*, vol. 14, pp. 100173, 2023, doi: 10.1016/j.dibe.2023.100173.
- [8] M. Kolat, T. Tettamanti, T. Bécsi, and D. Esztergár-Kiss, "On the relationship between the activity at point of interests and road traffic," *Commun. Transp. Res.*, vol. 3, 2023, doi: 10.1016/j.commtr.2023.100102.
- [9] Y. Li, M. Abdel-Aty, J. Yuan, Z. Cheng, and J. Lu, "Analyzing traffic violation behavior at urban intersections: A spatio-temporal kernel density estimation approach using automated enforcement system data," *Accid. Anal. Prev.*, vol. 141, pp.105509, 2020, doi: 10.1016/j.aap.2020.105509.

- [10] H. Xu and Z. Wang, "Integrating Points-of-Interest and Areas-Of-Interest for Commercial Space Pattern Analysis," *J. Phys. Conf. Ser.*, vol. 1852, no. 4, 2021, doi: 10.1088/1742-6596/1852/4/042053.
- [11] H. Ge, L. Dong, M. Huang, W. Zang, and L. Zhou, "Adaptive Kernel Density Estimation for Traffic Accidents Based on Improved Bandwidth Research on Black Spot Identification Model," *Electron.*, vol. 11, no. 21, 2022, doi: 10.3390/electronics11213604.
- [12] L. Srikanth and I. Srikanth, "A Case Study on Kernel Density Estimation and Hotspot Analysis Methods in Traffic Safety Management," *Int. Conf. Commun. Syst. NETWORKS, COMSNETS*, pp. 99–104, 2020, doi: 10.1109/COMSNETS48256.2020.9027448.
- [13] B. Pishue, INRIX Global Traffic Scorecard with Q1 2024 Update, INRIX, 2024.
- [14] C. Luiselli, Los desafíos del México urbano, UNAM, 2019.
- [15] Geoapify, <https://www.geoapify.com/places-api/>, last accessed:2024/02/02.
- [16] T. Traffic, <https://developer.tomtom.com/traffic-api/documentation/traffic-flow/flow-segment-data>, last accessed:2024/02/02.
- [17] H. Maps, https://www.here.com/docs/bundle/traffic-api-developer-guide-v6/page/topics_v6.1/resource-parameters-flow.html, last accessed: 2024/02/02.
- [18] D. Onyekachi, "Cubic Square and Square Root Transformation of a Gamma Distribution: A Comparative Analysis," *International Journal of Applied Science and Mathematical Theory*, vol. 6, no. 3, pp. 26–39, 2020.
- [19] N. Fei, Y. Gao, Z. Lu, and T. Xiang, "Z-Score Normalization , Hubness , and Few-Shot Learning". *IEEE Xplore*, pp.142–151.