

Modelo de Predicción Dinámica de Riesgo Urbano Multicapa Basado en Inteligencia Artificial para Usuarios Vulnerables de la Vía en Bogotá: El Modelo Murim y su Integración con Plataformas de Navegación en Tiempo Real

"AI-Based Multilayer Urban Risk Prediction Model for Vulnerable Road Users in Bogotá: The MURIM Model and Its Integration with Real-Time Navigation Platforms"

Andres Aparicio¹

¹ Especialista en Gerencia Logística. Docente del curso Fundamentos de Negocios Internacionales. Escuela de Ciencias Administrativas, Contables, Económicas y de Negocios (ECACEN), Universidad Nacional Abierta y a Distancia – UNAD.
ORCID: <https://orcid.org/0009-0005-7811-6614>
andres.aparicio@unad.edu.co

Resumen

Este trabajo propone el Modelo de Inteligencia de Riesgo Urbano Multicapa (MURIM), un framework predictivo espacio-temporal que estima niveles dinámicos de riesgo para intersecciones y segmentos viales en Bogotá. A diferencia de los sistemas convencionales de mapas de calor, MURIM introduce el concepto de Traffic-Condition-Dependent Urban Vulnerability Modeling: el riesgo no es solo función de la ubicación geográfica, sino de la interacción entre localización, estado dinámico del tráfico y perfil de exposición del usuario. El modelo integra cinco capas: seguridad criminal, exposición en congestión, vulnerabilidad climática, interrupciones sociales y perfil de usuario, en un Dynamic Urban Risk Score (DURS) con pesos calibrables por aprendizaje automático. Se identifican tres perfiles de usuario con ventanas de exposición diferenciadas: operadores logísticos, conductores de servicio nocturno y mujeres conductoras en horario diurno. Para este último perfil, el hallazgo central es que el riesgo principal no es nocturno sino diurno, concentrado en el tiempo de inmovilización en semáforos y trancones. El paper propone una arquitectura técnica de integración con Google Maps Platform y Waze for Cities, con infraestructura de datos totalmente disponible en Bogotá.

Palabras clave:

Riesgo Urbano Dinámico, Inteligencia Artificial, Seguridad Vial, Congestión Vehicular, Bogotá, Usuarios Vulnerables, Navegación Predictiva.

Clasificación JEL: R41, C45, O33, D81.

Abstrac

This paper proposes the Multi-Layer Urban Risk Intelligence Model (MURIM), a spatio-temporal predictive framework that estimates dynamic risk levels for intersections and road segments in Bogotá. Unlike conventional heat-map systems, MURIM introduces the concept of Traffic-Condition-Dependent Urban Vulnerability Modeling: risk is not solely a function of geographic location, but of the interaction between location, dynamic traffic conditions, and user exposure profile. The model integrates five layers—criminal safety, congestion exposure, climate vulnerability, social disruptions, and user profile into a Dynamic Urban Risk Score (DURS) with weights calibrated through machine learning. Three user profiles are identified with differentiated exposure windows: logistics operators, night-shift service drivers, and women drivers during daytime hours. For this last profile, the central finding is that the primary risk is not nocturnal but diurnal, concentrated in the time spent immobilized at traffic lights and in traffic jams. The paper proposes a technical integration architecture with Google Maps Platform and Waze for Cities, with data infrastructure fully available in Bogotá.

Keywords

Dynamic Urban Risk, Artificial Intelligence, Road Safety, Vehicular Congestion, Bogotá, Vulnerable Users, Predictive Navigation.

JEL Classification: R41, C45, O33, D81.

Introducción

Bogotá concentra algunos de los problemas de movilidad y seguridad urbana más complejos de América Latina. El hurto a personas y vehículos es la modalidad delictiva de mayor prevalencia en la ciudad, con patrones espaciales y temporales correlacionados con los flujos de tráfico (Secretaría de Seguridad, 2023). Sin embargo, esta correlación ha sido escasamente explorada desde una perspectiva analítica integrada que combine datos de movilidad, criminalidad y perfil del usuario en un modelo predictivo unificado.

La literatura dominante en seguridad urbana computacional opera sobre mapas de calor delictivos estáticos (Chainey & Ratcliffe, 2005): el riesgo se trata como propiedad fija del lugar, independiente del estado dinámico del entorno. Esta suposición es particularmente problemática cuando la exposición al riesgo está mediada por las condiciones del tráfico. El caso más ilustrativo es el de las mujeres conductoras en Bogotá: la literatura asocia su riesgo al desplazamiento nocturno, pero la evidencia local muestra que su principal ventana de vulnerabilidad es diurna y está determinada por el tiempo de inmovilización en semáforos congestionados, 467 hurtos en semáforos en 2024, con 104 casos adicionales en el primer trimestre de 2025 (Infobae Colombia, 2025). El 72,5% de los bogotanos encuestados por la Universidad Manuela Beltrán se siente más vulnerable en semáforos y el 69,3% en trancones (Semana, 2025).

Este trabajo responde a esa brecha proponiendo el Modelo MURIM, que incorpora explícitamente la condición del tráfico como variable moduladora del riesgo. La pregunta central es: ¿cómo puede un modelo de IA multicapa predecir dinámicamente el riesgo urbano en Bogotá integrando seguridad, clima, congestión y perfil del usuario, con potencial de incorporación en plataformas de navegación en tiempo real?

Las hipótesis de trabajo son tres. H1: un modelo multicapa con variables dependientes del estado del tráfico mejora significativamente la predicción de seguridad en ruta frente a sistemas de georeferenciación estática. H2: la personalización por perfil de usuario reduce la exposición en intersecciones

de alto riesgo. H3: la integración con plataformas de navegación potencia la toma de decisiones preventiva y reduce pérdidas económicas asociadas al delito y a las interrupciones.

La contribución principal es la introducción del concepto Traffic-Condition-Dependent Urban Vulnerability Modeling como categoría analítica en la literatura de seguridad urbana, con implicaciones directas sobre el diseño de sistemas de alerta y navegación inteligente diferenciados por perfil de usuario.

⁴ Modelo de predicción dinámica de riesgo urbano multicapa basado en inteligencia artificial para usuarios vulnerables de la vía en Bogotá: el modelo MURIM y su integración con plataformas de navegación en tiempo real

Revisión de literatura

Modelos predictivos de crimen urbano y aprendizaje automático

El hotspot mapping, sistematizado por Chainey y Ratcliffe (2005), es el paradigma dominante en el análisis espacial del crimen. Su limitación central es la estaticidad: ignora que un mismo segmento vial puede exhibir niveles de riesgo radicalmente distintos según la hora, las condiciones climáticas, el estado del tráfico o el tipo de usuario. La revisión sistemática de Mandalapu et al. (2023) en IEEE Access identificó que los modelos de Random Forest y redes neuronales son los enfoques de ML más utilizados en predicción criminal, pero señala como brecha crítica la ausencia de datos dinámicos en tiempo real. Jenga, Catal y Kar (2023) confirman que los modelos de clasificación mejoran la asignación de recursos policiales, pero subrayan la necesidad de incorporar dependencia espaciotemporal. En Colombia, Fontalvo-Herrera et al. (2024) demostraron que un modelo de clústeres combinado con red neuronal de doble capa alcanza un 97,7% de capacidad predictiva sobre datos del SIEDCO 2018-2022, validando la viabilidad técnica de aproximaciones similares en Bogotá. Kim et al. (2025) mostraron con XGBoost+SHAP que la población flotante y el volumen de flujo vehicular son predictores consistentes del riesgo criminal, convergiendo con las variables de exposición en congestión del MURIM.

La excepción más relevante en la relación tráfico-crimen es Herrnstadt y Muehlegger (2018), que documenta que la congestión extrema incrementa la incidencia de violencia doméstica, aunque sin examinar la exposición del usuario dentro del vehículo. Esta ausencia en la literatura —la dinámica del tráfico como variable de riesgo para el usuario— es el punto de partida del MURIM.

Género, movilidad y seguridad en América Latina

La literatura documenta consistentemente que mujeres y hombres experimentan el espacio urbano de manera asimétrica, con las mujeres reportando mayor percepción de inseguridad y modificando sus patrones de desplazamiento como respuesta (Ait Bihi Ouali et al., 2020). El Banco Mundial señala que estas preocupaciones limitan el acceso femenino al empleo en América Latina (World Bank, 2025). Del Mar Rodas-Zuleta et al. (2022) documentan en Transportation Research Part A que las mujeres colombianas adoptan el vehículo privado como respuesta adaptativa a la inseguridad en el transporte público —conducta que desplaza el riesgo hacia una modalidad diferente de exposición—. Cardoso et al. (2023) confirman en Sustainability, con 763 encuestados en Brasil, que las mujeres modifican sus patrones de viaje con mayor frecuencia ante eventos de inseguridad. Ceccato et al. (2022) identifican que el análisis diferenciado por condición del entorno es fundamental pero sigue siendo la excepción en la literatura. Soto et al. (2022) aportan evidencia desde Barranquilla de que la densidad peatonal alrededor del vehículo detenido amplifica significativamente el riesgo percibido, coherente con el componente $C(i,t)$ del MURIM.

Sistemas de navegación inteligente: vacío de integración

Google Maps Platform, Waze for Cities e IDECA proveen la infraestructura técnica suficiente para integrar datos de movilidad, seguridad y clima en tiempo real. Sin embargo, ningún sistema de navegación disponible incorpora seguridad criminal personalizada por perfil de usuario en sus algoritmos de optimización de rutas. El Informe ProBogotá 2024 confirma que el hurto en Bogotá sigue concentrándose en corredores de alta densidad vehicular, con aumentos del 36,5%, 27,8% y 7,9% en La Candelaria, Los Mártires y Santafé

respectivamente —localidades que coinciden con zonas de alta congestión—. Esta correlación empírica entre congestión y riesgo criminal es el vacío que el MURIM formaliza.

Infraestructura de datos para bogotá

Una fortaleza del caso bogotano es que la mayoría de las fuentes necesarias para operacionalizar el MURIM son de acceso abierto o disponibles mediante convenio institucional. La Tabla 1 sintetiza las fuentes por componente del modelo.

Tabla 1. Infraestructura de datos disponible por componente del MURIM

Componente	Variable clave	Fuente principal	Acceso
S(i,t) - Seguridad	Historial de hurtos e incidentes georreferenciados	SIEDCO (Policía Nacional) / SISC (Sec. Seguridad) / Datos Abiertos Bogotá	Convenio / público
C(i,t) - Congestión	Tiempos de ciclo semafórico, volúmenes vehiculares, velocidad por segmento	CGCT (Sec. Movilidad) / Google Maps Routes API / Waze for Cities	API / convenio
F(i,t) - Clima	Precipitación horaria, zonas inundables	IDEAM / IDIGER vía IDECA	Público (portal abierto)
B(i,t) - Disrupciones	Manifestaciones, bloqueos, paros	Waze for Cities / Sec. Gobierno / Personería Distrital	Convenio / parcial
V(u,i,t) - Perfil usuario	Tipo de usuario, modo, horario	Input declarado por el usuario en la aplicación	Disponible
Base geoespacial	Geometría vial, intersecciones, UPZ	IDECA - Mapa de Referencia Bogotá D.C.	Público (descarga)

El componente de disrupciones sociales B(i,t) es el de menor cobertura en tiempo real; su extensión futura mediante procesamiento de lenguaje natural (NLP) sobre redes sociales constituye una línea de desarrollo prioritaria del modelo.

El modelo MURIM: formulación matemática, probabilística y algorítmica

Ecuación de riesgo dinámico

Sea $DURS(i,t,u)$ el Dynamic Urban Risk Score para la intersección i , el intervalo temporal t y el perfil de usuario u . El modelo define:

$$DURS(i, t, u) = \alpha \cdot S(i,t) + \beta \cdot C(i,t) + \gamma \cdot F(i,t) + \delta \cdot B(i,t) + \varepsilon \cdot V(u,i,t)$$

donde S , C , F , B y V representan respectivamente las funciones de riesgo de seguridad, exposición en congestión, riesgo climático, interrupciones sociales y ajuste por vulnerabilidad del perfil de usuario. Los coeficientes α , β , γ , δ , ε son pesos dinámicos calibrables por aprendizaje automático. La Tabla 2 presenta los valores de referencia iniciales por perfil.

Tabla 2. Pesos de ponderación iniciales del DURS por perfil de usuario

Perfil de usuario	α Seguridad	β Congestión	γ Clima	δ Disrupción	ε Vulnerabilidad
Logística de carga	0.40	0.15	0.20	0.15	0.10
Taxi / servicio nocturno	0.45	0.10	0.10	0.10	0.25
Mujer conductora (diurno)	0.25	0.35	0.10	0.10	0.20
Usuario general	0.25	0.25	0.20	0.15	0.15

Nota: Los pesos suman 1.0. Valores sujetos a calibración empírica.

Representación probabilística de los componentes

Cada componente se formaliza como probabilidad condicional, lo que permite su estimación mediante modelos estadísticos estándar y actualización bayesiana en tiempo real:

$$\begin{aligned}
S(i,t) &= P(\text{evento_delictivo} \mid \text{ubicación}=i, \text{intervalo}=t, \text{historial}) \\
C(i,t) &= P(\text{tiempo_espera} > \tau \mid \text{densidad_tráfico}(i,t), \text{ciclo_semafórico}(i)) \\
F(i,t) &= P(\text{inundación} \mid \text{intensidad_lluvia}(t), \text{zona_riesgo}(i)) \\
B(i,t) &= P(\text{bloqueo} \mid \text{patrón_histórico}(i,t), \text{alertas_activas}(t))
\end{aligned}$$

El factor $V(u,i,t)$ actúa como multiplicador de sensibilidad. Para la mujer conductora en horario diurno amplifica $C(i,t)$ de manera diferencial:

$$V(\text{mujer_conductora}, i, t) = 1 + \kappa \cdot C(i,t) \quad [\kappa > 1 \text{ si hora_diurna}]$$

Ajuste dinámico de pesos por aprendizaje automático

Los coeficientes se actualizan mediante descenso de gradiente estocástico con regla de aprendizaje $\theta_{-}(t+1) = \theta_{-}t - \eta \cdot (\partial L / \partial \theta)$, donde L es el error cuadrático medio entre el DURS predicho y la ocurrencia efectiva de incidentes: $L = (1/n) \cdot \sum [\text{DURS}(i,t,u) - \text{evento_real}(i,t)]^2$. Esto permite al sistema aprender de nuevos incidentes y recalibrar automáticamente sin intervención manual. En una extensión futura, los pesos podrían actualizarse de forma independiente por UPZ o corredor vial, generando un modelo jerárquico con coeficientes locales.

Agrupamiento espacio-temporal de intersecciones críticas

Para identificar nodos de mayor riesgo acumulado, el MURIM aplica DBSCAN (Ester et al., 1996) sobre incidentes históricos georreferenciados, segmenta los registros en cinco ventanas temporales intra-diarias (madrugada, mañana, mediodía, tarde, noche) y normaliza los resultados en un índice 0–100 superpuesto cartográficamente sobre la malla vial. Como ilustración, la intersección Carrera 7ª × Calle 125 —alta congestión, historial de hurto en semáforo, exposición a lluvia— generaría un DURS elevado para el perfil de mujer conductora en hora pico diurna, activando alertas y rutas alternativas.

Pseudocódigo operacional

ENTRADA: red $G=\{i1..in\}$, intervalo T , perfil u

SALIDA : mapa_riesgo M , alertas A , rutas_alt R

INICIALIZAR pesos (a,b,g,d,e) segun perfil u

PARA CADA i EN G , PARA CADA t EN T :

$S=SIEDCO(i,t)$; $C=GoogleMaps/CGCT(i,t)$

$F=IDEAM(i,t)$; $B=Waze/SecGob(i,t)$

$V=vulnerabilidad(u,i,t)$

$DURS = a*S + b*C + g*F + d*B + e*V$

SI $S>tS$ AND $C>tC$: $DURS += \lambda * (S*C*F)$ // amplificacion no lineal

$M[i][t] = DURS$

SI $DURS > UMBRAL[u]$: $A+=alerta(i,u)$; $R+=ruta_alternativa(i,u)$

PARA CADA peso θ : $\theta = \theta - \eta * grad(L,\theta)$ // aprendizaje

RETORNAR M, A, R

Amplificación no lineal por convergencia de riesgos

El MURIM incorpora un mecanismo de amplificación no lineal cuando múltiples componentes de alto riesgo convergen simultáneamente. La coexistencia de alta incidencia delictiva, tráfico detenido e inundación no produce la suma de riesgos individuales sino un efecto multiplicativo:

$$DURS_{ext} = \sum [\theta_k \cdot R_k(i,t)] + \lambda \cdot (S(i,t) \times C(i,t) \times F(i,t))$$

El término $\lambda \cdot (S \times C \times F)$ se activa solo cuando los tres componentes superan simultáneamente sus umbrales críticos, capturando situaciones de riesgo extremo que los modelos lineales subestiman: un bloqueo por manifestación en una intersección de alta incidencia delictiva durante una tormenta intensa deja al conductor en condición de máxima vulnerabilidad simultánea.

Arquitectura técnica e integración con apis de navegación

Stack de integración

La arquitectura del MURIM se organiza en cuatro capas funcionales. La capa de ingesta de datos consume en tiempo real las APIs de Google Maps Platform (Routes API para tiempos de viaje y congestión, Roads API para velocidad por segmento), los feeds de Waze for Cities (incidentes, cierres, congestión colaborativa), los datos del IDEAM y del CGCT, y los datasets abiertos del SIEDCO/SISC. La capa de procesamiento ejecuta el motor DURS, aplica DBSCAN para clustering espacio-temporal, actualiza los pesos mediante gradiente y genera el mapa de riesgo diferencial por perfil. La capa de alertas evalúa el DURS frente a los umbrales de cada perfil, emite notificaciones geolocalizadas y calcula rutas alternativas optimizadas por seguridad. La capa de presentación incluye tanto la interfaz de usuario final —integrable como overlay sobre Google Maps o Waze— como un Urban Risk Intelligence Dashboard para autoridades distritales.

Flujo de integración con Google Maps y Waze for Cities

La integración con Google Maps Platform permite superponer el DURS como capa de riesgo personalizada sobre rutas calculadas por la API, de manera que el sistema no solo optimiza por tiempo o distancia sino por seguridad ajustada al perfil del usuario. El programa Waze for Cities habilita un canal bidireccional: la Secretaría de Movilidad recibe datos de incidentes en tiempo real y puede retroalimentar el modelo con alertas de cierres planificados y emergencias, cerrando el ciclo de datos entre el sistema institucional y el modelo predictivo.

Gobernanza de datos y privacidad

La arquitectura contempla acuerdos de intercambio de datos con la Policía Nacional (SIEDCO), la Secretaría de Seguridad (SISC), la Secretaría de Movilidad (CGCT), el IDEAM y el IDIGER. El procesamiento de datos de usuarios se realiza bajo principios de privacidad diferencial y anonimización. Los datos personales

del perfil de usuario se declaran voluntariamente y se procesan localmente en el dispositivo; solo el DURS agregado se transmite al servidor central. Esta arquitectura garantiza cumplimiento con la Ley 1581 de 2012 (Protección de Datos Personales de Colombia) y con el Reglamento General de Protección de Datos (RGPD) para potenciales despliegues internacionales.

Discusión e implicaciones para política pública

Implicaciones académicas

El concepto de Traffic-Condition-Dependent Urban Vulnerability Modeling que introduce este trabajo tiene implicaciones metodológicas que van más allá del caso bogotano. Primero, sugiere que los modelos predictivos de crimen que ignoran el estado dinámico del tráfico producen estimaciones sesgadas del riesgo, particularmente en intersecciones de alta congestión. Segundo, la formalización matemática de la asimetría de género en el riesgo de movilidad —a través de un multiplicador de sensibilidad diferencial en el factor $V(u,i,t)$ — abre una línea de investigación sobre la cuantificación de vulnerabilidades socialmente diferenciadas en modelos urbanos computacionales. Tercero, el mecanismo de amplificación no lineal por convergencia de riesgos aporta un instrumento formal para modelar los efectos de cascada que la literatura de riesgo urbano ha documentado cualitativamente pero raramente ha formalizado.

Implicaciones para la política pública en Bogotá

El MURIM tiene tres aplicaciones directas para la política pública distrital. En seguridad ciudadana, el mapa de riesgo diferencial por perfil de usuario puede orientar la asignación de patrullaje preventivo de la Policía Metropolitana hacia intersecciones de alta congestión con historial de hurto en semáforos, optimizandolapresenciapolicialenlosmomentosylugaresdemayorexposición. En movilidad urbana, la identificación de nodos de alta convergencia de riesgo

puede informar decisiones de reprogramación semafórica del CGCT —reducir los tiempos de ciclo en rojo en intersecciones críticas reduce directamente el componente $C(i,t)$ y, con él, el DURS— constituyendo una intervención de bajo costo y alto impacto. En infraestructura y gestión del riesgo, la capa climática del modelo puede alimentar los planes de contingencia del IDIGER ante eventos de lluvia intensa, anticipando los nodos viales donde la convergencia de inundación y congestión generará condiciones de vulnerabilidad extrema.

Replicabilidad y escalabilidad

La arquitectura del MURIM está diseñada para ser replicable en otras ciudades latinoamericanas que cuenten con infraestructura de datos urbanos comparable. Las ciudades con plataformas de datos abiertos maduras —Medellín, Ciudad de México, São Paulo, Lima— son candidatas naturales para una extensión del modelo. La parametrización de los pesos por perfil de usuario puede adaptarse a los patrones criminales y de movilidad de cada contexto, y la integración con Google Maps Platform y Waze for Cities es universal. La replicabilidad del modelo es, en sí misma, un argumento de política pública a favor de su desarrollo: un framework estandarizado de predicción de riesgo urbano personalizado podría convertirse en un bien público regional de alto valor para las ciudades latinoamericanas.

Conclusiones y agenda de investigación futura

Este trabajo ha propuesto el Modelo de Inteligencia de Riesgo Urbano Multicapa (MURIM), un framework conceptual que introduce el estado dinámico del tráfico como variable de riesgo independiente en la predicción de seguridad urbana. La evidencia empírica disponible para Bogotá valida la hipótesis central: el tiempo de exposición estática del vehículo en intersecciones congestionadas es un predictor cuantificable del riesgo criminal, especialmente para el perfil de mujer conductora en horario diurno.

El modelo formaliza esta intuición en una función de riesgo con cinco componentes (DURS), pesos calibrables por aprendizaje automático, representación probabilística de cada capa, agrupamiento espacio-temporal mediante DBSCAN y un mecanismo de amplificación no lineal por convergencia de riesgos. La infraestructura de datos necesaria para su operacionalización existe en Bogotá y es mayoritariamente de acceso abierto. La arquitectura técnica de integración con Google Maps Platform y Waze for Cities es técnicamente viable en el corto plazo.

Las tres hipótesis del trabajo quedan apoyadas conceptualmente: H1, porque el DURS incorpora dimensiones de riesgo que los mapas de calor estáticos no capturan; H2, porque la personalización por perfil produce matrices de ponderación radicalmente diferentes que modifican las rutas de menor exposición; y H3, porque la integración con plataformas de navegación transforma la predicción en acción preventiva en tiempo real.

La agenda de investigación futura se articula en cinco líneas. Primera, la validación empírica del modelo con datos históricos del SIEDCO para estimar la mejora predictiva de DURS frente a hotspot mapping estático. Segunda, la calibración de los pesos iniciales de la Tabla 2 mediante regresión sobre incidentes reales segmentados por perfil. Tercera, la extensión del componente $B(i,t)$ mediante NLP sobre fuentes de redes sociales. Cuarta, el diseño de un experimento piloto de integración con la API de Google Maps en un corredor vial de Bogotá de alta congestión y alta incidencia criminal. Quinta, la evaluación de la replicabilidad del modelo en una ciudad latinoamericana de características comparables, preferiblemente Medellín o Ciudad de México, como prueba de escalabilidad del framework.

Referencias

- Ait Bihi Ouali, L., Graham, D. J., Barron, A., & Trompet, M. (2020). Gender differences in the perception of safety in public transport. *Journal of the Royal Statistical Society Series A*, 183(3), 737-769.
- Alcaldía Mayor de Bogotá. (2024). Portal de Datos Abiertos del Distrito Capital. <https://datos.bogota.gov.co>
- Cámara de Comercio de Bogotá. (2021). Informe de seguridad y convivencia en Bogotá 2021. Bogotá: CCB.
- Cardoso, M., et al. (2023). Exploring the Resilience of Public Transport Trips in the Face of Urban Violence from a Gender Perspective. *Sustainability*, 15(24), 16960. <https://doi.org/10.3390/su152416960>
- Ceccato, V., Gaudalet, N., & Graf, G. (2022). Crime and safety in transit environments: a systematic review, 1970-2020. *Public Transport*, 14(1), 105-153.
- Chainey, S., & Ratcliffe, J. (2005). *GIS and Crime Mapping*. John Wiley & Sons.
- Del Mar Rodas-Zuleta, M., et al. (2022). Gender-based violence and Women's mobility in a medium-sized Colombian city. *Transportation Research Part A*, 129, 209-228. <https://doi.org/10.1016/j.tra.2022.01.003>
- Ester, M., Kriegel, H. P., Sander, J., & Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. *Proceedings KDD-96*, 226-231.
- FONSAT. (2022). Estadísticas de siniestralidad vial en Colombia 2021-2022. Bogotá: Fondo de Prevención Vial.
- Fontalvo-Herrera, T. J., Vega-Hernández, M. A., & Mejía-Zambrano, F. (2024). Spatio-Temporal Crime Predictions by Leveraging AI for Citizens Security in Smart Cities. *Information Fusion*, 101904. <https://doi.org/10.1016/j.inffus.2023.101904>

Google LLC. (2024). Google Maps Platform: Routes API. <https://developers.google.com/maps/documentation/routes>

Herrnstadt, E., & Muehlegger, E. (2018). Traffic and crime. *Journal of Environmental Economics and Management*, 90, 36-56.

IDECA. (2024). Mapa de Referencia Bogotá D.C. <https://www.ideca.gov.co>

IDEAM. (2024). Portal de datos hidrometeorológicos. <http://www.ideam.gov.co>

IDIGER. (2023). Cartografía de amenaza por inundación en Bogotá D.C. <https://www.idiger.gov.co>

Infobae Colombia. (2025, 22 de julio). Objetos y horas de mayor hurto en semáforos de Bogotá. <https://www.infobae.com/colombia>

Jenga, K., Catal, C., & Kar, G. (2023). Machine learning in crime prediction. *Journal of Ambient Intelligence and Humanized Computing*, 14(3), 2887-2913.

Kim, J., et al. (2025). Crime mapping using explainable AI in urban environments: Daegu, Korea. *Cities*. <https://doi.org/10.1016/j.cities.2025.104938>

Mandalapu, V., Elluri, L., Vyas, P., & Roy, N. (2023). Crime prediction using ML and DL: A systematic review. *IEEE Access*, 11, 60153-60170. <https://doi.org/10.1109/ACCESS.2023.3286344>

Policía Nacional de Colombia. (2024). Sistema Estadístico, Delincuencial, Contravencional y Operativo (SIEDCO). Bogotá: DIJIN.

ProBogotá. (2025). Informe Anual de Seguridad en Bogotá 2024. <https://www.probogota.org>

Secretaría de Seguridad, Convivencia y Justicia. (2023). SISC - Boletín anual de criminalidad. Bogotá: Alcaldía Mayor.

Secretaría Distrital de Movilidad. (2024). Centro de Gestión y Control del Tráfico.
Bogotá: Alcaldía Mayor.

Semana. (2025, 7 de abril). La forma más común de robo de carros en Bogotá. <https://www.semana.com>

Soto, J., Orozco-Fontalvo, M., & Useche, S. A. (2022). Public transportation and fear of crime at BRT systems in Barranquilla. *Transportation Research Part A*, 155, 142-160.

Waze for Cities. (2024). Program overview. <https://www.waze.com/wazeforcities>

World Bank. (2025). In Latin America, when violence rises, women's economic opportunities fall. <https://blogs.worldbank.org>