

An aerial night view of a city, likely Bogotá, Colombia, showing a complex highway interchange and surrounding urban areas. A glowing blue network of lines and nodes is overlaid on the city, representing data or connectivity. A full moon is visible in the dark sky at the top center.

PANORAMA DE LA CIENCIA

INTELIGENCIA URBANA PARA LA SEGURIDAD PÚBLICA: DEL ANÁLISIS ESPACIAL A LA ACCIÓN

*Germain García Zanabria
Juanpablo Heredia
Felipe Moreno
Jorge Poco*

INTRODUCCIÓN:

EL ECOSISTEMA CIENTÍFICO CONTRA EL CRIMEN

La seguridad pública constituye uno de los desafíos más complejos de las sociedades contemporáneas. En las ciudades, la violencia y la criminalidad no responden a una única causa ni pueden explicarse únicamente por la reacción policial frente a los delitos. Son el resultado de la interacción entre factores sociales, características del espacio urbano, debilidades institucionales y oportunidades que favorecen la comisión de actos delictivos. Por ello, diversos organismos internacionales sostienen que la seguridad urbana requiere enfoques integrales, capaces de abordar simultáneamente los múltiples factores que generan violencia, delito e inseguridad, especialmente en ciudades densamente pobladas y marcadas por profundas desigualdades (UNODC, s. f.).

En el Perú, este desafío adquiere una relevancia particular. La percepción de inseguridad se ha mantenido elevada durante los últimos años. Según el Instituto Nacional de Estadística e

Informática (INEI, 2025), entre enero y junio de 2025, el 85,1 % de la población urbana de 15 años o más consideró probable ser víctima de un delito durante los siguientes doce meses; en Lima Metropolitana y el Callao, esta cifra alcanzó el 86,3 %. Estos datos reflejan no solo la magnitud del problema, sino también la necesidad de fortalecer las capacidades analíticas del Estado para comprender patrones delictivos cada vez más complejos, dinámicos y diferenciados según el territorio. Para ello no basta con incorporar nuevas herramientas tecnológicas: también es necesario mejorar la calidad de los datos, integrarlos y facilitar su intercambio entre las distintas instituciones responsables de la seguridad ciudadana.


Comprender estos desafíos exige una mirada multidisciplinaria. Hoy, el estudio del crimen reúne aportes provenientes de disciplinas tan diversas como la neurociencia, la informática, la estadística, la geografía, la psicología y el urbanismo. Por ejemplo, la neurociencia investiga cómo determinados procesos cerebrales influyen en los comportamientos antisociales y en la interacción entre el individuo y su entorno (Kahhale, 2022). Al mismo tiempo, el análisis computacional permite estudiar cómo



PASO 1: ANÁLISIS ESPACIAL



PASO 2: INTEGRACIÓN DE DATOS (EL CEREBRO DE LA IA)



PASO 3: ACCIÓN - DESPLIEGUE OPERATIVO



Ilustración: IA — Copilot, prompt y edición Kelly Vásquez Chaparro

la configuración física de una ciudad influye tanto en la ocurrencia de delitos como en la percepción de seguridad de sus habitantes (Jacobs, 1961). Gracias a estas herramientas ha sido posible visualizar patrones delictivos en distintas escalas urbanas (García-Zanabria et al., 2020), identificar regularidades espaciales en grandes ciudades (García-Zanabria et al., 2021) y analizar cómo las personas perciben la seguridad de una calle a partir de sus características visuales (Moreno-Vera et al., 2021a).

En este contexto, el análisis de datos y la inteligencia artificial desempeñan un papel cada vez más importante. La posibilidad de procesar grandes volúmenes de información, identificar patrones espaciales y temporales y

optimizar la asignación de recursos está permitiendo que la gestión de la seguridad evolucione desde estrategias predominantemente reactivas hacia enfoques preventivos. Así, la ciencia del crimen deja de ser únicamente una herramienta para describir lo que ocurre y se convierte en un soporte para comprender los fenómenos delictivos, anticipar escenarios y diseñar políticas públicas sustentadas en evidencia.

Según el INEI, entre enero y junio de 2025, el 85,1 % de la población urbana de 15 años o más consideró probable ser víctima de un delito.

TENDENCIAS GLOBALES: ALGORITMOS, TECNOLOGÍA DE VIGILANCIA Y CIBERSEGURIDAD


Durante las últimas décadas, la gestión de la seguridad pública ha experimentado una profunda transformación. La protección de las ciudades ya no depende exclusivamente de la presencia policial, sino también del uso de tecnologías capaces de recopilar, monitorear y procesar información de manera continua. En el contexto de las llamadas ciudades inteligentes (*smart cities*), la seguridad se apoya cada vez más en cámaras de vigilancia, sensores urbanos, plataformas de monitoreo y protocolos de ciberseguridad destinados tanto a proteger a la población como a garantizar el funcionamiento de servicios esenciales, como el transporte, la salud o las comunicaciones (Shaffer, 2024).

Este cambio tecnológico también ha transformado la manera de comprender la seguridad urbana. Los datos se han convertido en un recurso estratégico y su utilidad depende de factores como la calidad de la información, su

actualización permanente, la integración entre instituciones y la posibilidad de rastrear su origen y uso. En otras palabras, cuanto mejor sea la gestión de los datos, mayor será la capacidad del Estado para tomar decisiones fundamentadas y transparentes.


Como consecuencia de esta transformación, los métodos computacionales y matemáticos ocupan hoy un lugar central en la planificación de la seguridad pública. Entre ellos destacan las técnicas de machine learning o aprendizaje automático, es decir, algoritmos capaces de aprender a partir de grandes cantidades de datos para identificar patrones, clasificar información o realizar predicciones. Estas herramientas permiten detectar hotspots o zonas con alta concentración delictiva, reconocer patrones espaciales y temporales y estimar dónde existe una mayor probabilidad de que ocurran determinados delitos a partir del análisis de registros policiales y datos geoespaciales (García-Zanabria et al., 2021).

A ello se suma el *deep learning* o aprendizaje profundo, una rama del aprendizaje automático basada en redes neuronales artificiales que permite analizar información mucho




CRIME PATTERN MAPPING - LIMA METROPOLITANA

ANÁLISIS TEMPORAL: OCURRENCIA POR HORA




PROBABILIDAD DELICTIVA PREDICHA



REGISTROS POLICIALES INTEGRADOS



ESTIMACIÓN DE PROBABILIDAD




más compleja, como imágenes urbanas. Gracias a estas técnicas es posible clasificar automáticamente distintos entornos según el nivel de seguridad que perciben los ciudadanos, aportando nuevas herramientas para comprender la relación entre las características físicas del espacio, la percepción de inseguridad y el riesgo delictivo (Moreno-Vera et al., 2021a).

En conjunto, estas aproximaciones permiten superar muchas de las limitaciones de los análisis estadísticos

tradicionales y optimizar la asignación de recursos públicos. Como muestra la Figura 1, distintas fuentes de información urbana —registros policiales, cámaras de videovigilancia, sensores, datos de movilidad, imágenes de calles o información socioeconómica— pueden integrarse mediante herramientas analíticas para generar diagnósticos, predicciones y escenarios que apoyen la toma de decisiones, siempre bajo criterios de gobernanza, transparencia, privacidad y ciberseguridad.

FIGURA N.º 1



De las fuentes de datos a la inteligencia urbana para la seguridad pública. El esquema resume cómo distintos tipos de datos urbanos alimentan métodos analíticos que producen diagnósticos, predicciones y explicaciones útiles para la toma de decisiones, todo ello bajo las exigencias de gobernanza, privacidad, transparencia y ciberseguridad.

Un ejemplo ampliamente conocido es PredPol,¹ desarrollado en Estados Unidos para estimar las zonas con mayor probabilidad de ocurrencia de delitos a partir de patrones espaciales y temporales. En el Reino Unido, la Policía Metropolitana de Londres ha incorporado sistemas de reconocimiento facial en tiempo real, una tecnología que ha impulsado un intenso debate sobre privacidad, vigilancia y derechos civiles. En América Latina, aunque la incorporación de inteligencia artificial ha sido más gradual, ya existen experiencias relevantes de videovigilancia, análisis en tiempo real y visualización de patrones criminales (García-Zanabria et al., 2020). Entre ellas destaca SITIA,² en Chile, que integra la información obtenida por cámaras de vigilancia con bases de datos policiales para fortalecer las capacidades de análisis.

Más allá de la infraestructura tecnológica, uno de los principales aportes proviene de la criminología ambiental. Esta disciplina sostiene que el delito tiende a concentrarse en microespacios urbanos específicos, como determinadas esquinas o segmentos de calle, frecuentemente asociados con lugares que atraen o facilitan la actividad delictiva (García-Zanabria et al., 2021).



Asimismo, investigaciones recientes muestran que el estado físico del entorno —por ejemplo, la presencia de basura, infraestructura deteriorada o espacios abandonados— influye en la percepción de seguridad de las personas y puede incorporarse a modelos que ayudan a simular distintos escenarios de intervención urbana para evaluar cuáles podrían resultar más eficaces (Lavi et al., 2022; Moreno-Vera et al., 2025; Raimundo et al., 2025).

ANÁLISIS CRIMINALÍSTICO Y EVOLUCIÓN DE LOS MAPAS DE CALOR

A lo largo de las últimas décadas, los Sistemas de Información Geográfica (GIS, por sus siglas en inglés) han desempeñado un papel decisivo en el análisis del crimen. Mediante la elaboración de mapas delictivos (*crime mapping*), estas herramientas han permitido visualizar cómo se distribuyen los delitos en el territorio, analizar su comportamiento a lo largo del tiempo e incorporar variables urbanas, sociales y ambientales asociadas a la generación de oportunidades delictivas. Gracias a ello, el estudio del crimen ha evolucionado desde un enfoque

principalmente descriptivo hacia una perspectiva interdisciplinaria que integra la estadística, el aprendizaje automático, la visualización de datos y las ciencias sociales (Garcia-Zanabria et al., 2021).

Uno de los métodos más utilizados en este ámbito es el análisis de hotspots o zonas de alta concentración delictiva. Su objetivo consiste en identificar aquellos lugares donde los delitos ocurren con mayor frecuencia para orientar mejor las acciones de prevención y la asignación de recursos (Chainey et al., 2008). Sin embargo, los mapas de calor tradicionales presentan una limitación importante: privilegian la cantidad de delitos registrados y tienden a invisibilizar lugares donde determinados delitos, aunque menos numerosos, ocurren de manera persistente y reiterada (Garcia-Zanabria et al., 2020, 2021).

Esta dificultad se relaciona con la forma en que tradicionalmente se representa el espacio urbano. Con frecuencia, las ciudades se dividen en cuadrículas regulares o unidades territoriales amplias que simplifican la realidad, pero también ocultan diferencias relevantes entre calles, esquinas o pequeños sectores urbanos.

Como se observa en la Figura 2, este tipo de representación puede diluir la concentración delictiva al promediar eventos que, en realidad, se concentran en puntos muy específicos, como intersecciones o determinados tramos de una vía (Bernasco & Block, 2011; Clarke & Eck, 2007; Weisburd, 2015).

Los mapas de calor tradicionales presentan una limitación importante: privilegian la cantidad de delitos registrados y tienden a invisibilizar lugares donde determinados delitos, aunque menos numerosos, ocurren de manera persistente y reiterada.

FIGURA N.º 2




Figura 2. Comparación entre la discretización espacial mediante cuadrículas y la representación basada en una red de calles. A la izquierda, la agregación en celdas regulares puede ocultar variaciones en microlugares. A la derecha, la discretización por intersecciones y segmentos viales permite identificar con mayor precisión la concentración delictiva en esquinas y en tramos. Adaptado de García-Zanabria et al. (2020, 2021).

Frente a estas limitaciones surgieron nuevas formas de analizar el espacio urbano a una escala mucho más detallada. Entre ellas destacan herramientas como Mirante y CrimAnalyzer, que marcaron un cambio importante en la manera de estudiar la distribución del delito. Mientras Mirante propuso una representación basada en la red real de calles, CrimAnalyzer incorporó técnicas matemáticas para identificar hotspots considerando no solo la cantidad de delitos, sino también la intensidad, la frecuencia y la recurrencia de los patrones delictivos (Garcia-Zanabria et al., 2020, 2021).

Este desarrollo metodológico dio un paso adicional con CriPAV (véase la Figura 3), una plataforma que integra el análisis a nivel de calle con modelos probabilísticos para estimar la probabilidad de ocurrencia del delito. Además de identificar patrones espaciales, el sistema incorpora imágenes de Street View para relacionar la dinámica delictiva con las características físicas del entorno urbano y agrupa segmentos de calles que presentan comportamientos similares (Garcia-Zanabria et al., 2022). De este modo, el análisis deja de centrarse únicamente en la ubicación de los delitos y comienza a incorporar información sobre el contexto donde estos ocurren.

FIGURA N.º 3




Figura 3. SS. Adaptado de Garcia-Zanabria et al. (2022).

Mientras Mirante propuso una representación basada en la red real de calles, CrimAnalyzer incorporó técnicas matemáticas para identificar hotspots considerando no solo la cantidad de delitos, sino también la intensidad, la frecuencia y la recurrencia de los patrones delictivos (García-Zanabria et al., 2020, 2021).

Esta evolución refleja un cambio más amplio en la investigación sobre seguridad urbana. Mientras los primeros mapas delictivos respondían principalmente a la pregunta "¿dónde ocurre el delito?", las herramientas actuales buscan responder también "¿por qué ocurre precisamente allí?" y "¿qué características del entorno ayudan a explicarlo?". Ese cambio de perspectiva resulta fundamental para diseñar estrategias preventivas más precisas y eficaces.

EL ENTORNO URBANO Y LA PERCEPCIÓN DE SEGURIDAD

La relación entre el entorno físico y el comportamiento humano constituye uno de los temas centrales de la psicología social, la criminología y los estudios urbanos (Keuschnigg & Wolbring, 2015). Una de las teorías más influyentes en este campo es la teoría de las ventanas rotas, que sostiene que los signos visibles de deterioro —como grafitis, acumulación de basura, infraestructura dañada o un exceso de cableado aéreo— transmiten la sensación de que un espacio carece de control y supervisión, lo que puede incrementar la percepción de inseguridad (Wilson & Kelling, 1982).

Desde esta perspectiva, la seguridad urbana no depende únicamente del número de delitos registrados. También está relacionada con la manera en que las personas perciben y experimentan los espacios públicos. Esa percepción influye en decisiones cotidianas tan diversas como caminar por una calle, permanecer en una plaza o utilizar determinados servicios urbanos, y termina afectando la calidad de vida de quienes habitan la ciudad (Moreno-Vera et al., 2021b).

Durante los últimos años, el desarrollo de técnicas de visión por computadora ha permitido estudiar este fenómeno de una manera inédita. Mediante imágenes obtenidas a nivel de calle —por ejemplo, a través de Street View— y bases de datos construidas a partir de las opiniones de los ciudadanos, diversas investigaciones han demostrado que es posible estimar la percepción de seguridad asociada a un entorno urbano analizando sus características visuales.

En una primera etapa, los modelos de inteligencia artificial utilizaron técnicas de segmentación semántica y redes neuronales convolucionales para identificar los elementos presentes en una escena urbana y relacionarlos con la percepción de seguridad expresada

por las personas (Moreno-Vera et al., 2021a, 2021b). De este modo, un juicio que tradicionalmente se consideraba subjetivo pudo transformarse en un fenómeno susceptible de ser analizado y cuantificado.

La Figura 4 resume este proceso. En primer lugar, los participantes observan pares de imágenes urbanas y responden una pregunta sencilla: ¿Cuál de estas dos calles le parece más segura? A partir de miles de respuestas de este tipo, los modelos de aprendizaje profundo identifican patrones visuales recurrentes y estiman un puntaje de seguridad percibida para nuevas imágenes. Así, el sistema aprende qué características del entorno suelen asociarse con una mayor o menor sensación de seguridad.

FIGURA N.º 4




Figura 4. Proceso de cuantificación de la percepción urbana. A la izquierda, tenemos el método de recolección de preferencias mediante una encuesta en línea que compara dos imágenes urbanas. A la derecha se muestra el flujo para cuantificar la percepción urbana aplicando modelos de aprendizaje profundo; es posible extraer características y elementos visuales para estimar la percepción de seguridad urbana a partir de la composición de la escena. Adaptado de Moreno-Vera et al. (2021a).

Más recientemente, el desarrollo de modelos multimodales —capaces de combinar distintos tipos de información, como imágenes y texto— y de enfoques contrafactuales ha permitido avanzar un paso más. Ya no se trata únicamente de predecir cómo será percibido un lugar, sino también de explicar por qué genera esa percepción.

Las investigaciones más recientes, como UrbanVLM y UrbanPhysicalDisorder-4K, muestran que determinados elementos del entorno tienen un impacto especialmente importante. La presencia de infraestructura deteriorada, basura, grafitis o exceso de cableado aéreo suele asociarse con una menor percepción de

seguridad, mientras que la vegetación, el mantenimiento de los espacios públicos y un entorno ordenado contribuyen a mejorarla (Lavi et al., 2022; Moreno-Vera et al., 2025; Moreno-Vera & Poco, 2025).

La Figura 5 ilustra este enfoque mediante un ejemplo contrafactual. En lugar de limitarse a indicar que una calle parece insegura, el modelo modifica virtualmente algunos elementos de la escena —por ejemplo, elimina grafitis o incorpora árboles— y estima cómo cambiaría la percepción de seguridad. Este tipo de simulaciones permite explorar el posible impacto de distintas intervenciones urbanas antes de ejecutarlas.

FIGURA N.º 5




Figura 5. Análisis contrafactual del desorden físico urbano. La figura ilustra el proceso para analizar y modificar la distribución de los objetos presentes. A la izquierda mostramos una imagen inicial percibida como insegura (puntaje de 4.31), una imagen contrafactual generada (puntaje de 6.75) y la relación entre los atributos árbol y grafiti que determinan la percepción. En la derecha mostramos el análisis y los atributos a añadir y remover, mejorando la estimación de seguridad urbana. Este proceso demuestra el impacto causal de estos componentes en la percepción de seguridad. Adaptado de Moreno-Vera et al. (2025).

En conjunto, estas herramientas representan un cambio importante en la forma de comprender la seguridad urbana. Más allá de identificar dónde ocurren los delitos, permiten analizar cómo las características físicas del entorno influyen en la experiencia cotidiana de las personas y ofrecen información valiosa para orientar intervenciones urbanas que contribuyan a generar espacios más seguros.

ANÁLISIS DE DATOS APLICADOS A LA VIGILANCIA PREDICTIVA DE LA DELINCUENCIA

El análisis del crimen ha dejado de limitarse a describir patrones o identificar zonas de riesgo. En la actualidad, también busca comprender las causas de los fenómenos delictivos y explorar posibles escenarios de intervención que faciliten la toma de decisiones. En este contexto, la vigilancia predictiva ya no responde únicamente a la pregunta «¿dónde podría ocurrir un delito?», sino también a otras igualmente relevantes: «¿qué cambios podrían reducir ese riesgo?» y «¿por qué ocurrió un hecho inesperado?».

Este cambio refleja una evolución importante en el uso de la inteligencia artificial aplicada a la seguridad. Los avances recientes en métodos

de explicabilidad y en explicaciones contrafactuales permiten comprender mejor cómo llegan los modelos a determinadas conclusiones y explorar qué condiciones deberían modificarse para obtener resultados distintos (Ribeiro et al., 2016; Wachter et al., 2018). En otras palabras, la inteligencia artificial ya no solo predice: también comienza a explicar.

El desarrollo de modelos multimodales —capaces de combinar distintos tipos de información, como imágenes y texto— y de enfoques contrafactuales ha permitido avanzar un paso más.

Una de las herramientas desarrolladas con este propósito es CounterCrime, un sistema que incorpora explicaciones contrafactuales al análisis del crimen. En lugar de limitarse a señalar qué regiones presentan mayores niveles de riesgo, la plataforma analiza qué variables urbanas y socioeconómicas deberían modificarse para que una zona cambie de una condición de mayor riesgo a otra más favorable (Raimundo et al., 2025).

Como muestra la Figura 6, el sistema permite simular distintos escenarios considerando cambios en variables como la densidad de establecimientos comerciales, las paradas de transporte público, el nivel de ingresos o la población residente. Su principal aporte consiste en que estas propuestas no son arbitrarias

sino que se basan en configuraciones observadas en otras áreas de la ciudad con características similares. De este modo, el análisis deja de ser exclusivamente predictivo y adquiere una dimensión propositiva, capaz de orientar intervenciones urbanas plausibles.

FIGURA N.º 6




Figura 6. Exploración de escenarios con CounterCrime. A la izquierda, se muestran las regiones y sus características originales, destacando una región "insegura". En el centro, se ilustra su transformación mediante contrafactuales (CF1–CF4) hacia una región "segura", junto con los cambios en variables urbanas y socioeconómicas. A la derecha, se muestra el impacto espacial de estas modificaciones, en la reclasificación de regiones bajo distintos escenarios. Adaptado de Raimundo et al. (2025).

Una segunda aproximación corresponde a AnomalyExplain, una plataforma diseñada para explicar por qué se producen determinados cambios inesperados en los patrones delictivos. Mientras CounterCrime explora qué modificaciones podrían reducir el riesgo, AnomalyExplain intenta responder a la pregunta inversa: ¿qué factores explican una anomalía que ya ocurrió?

Para ello, el sistema integra información espacial, series temporales, modelos de lenguaje e información procedente de fuentes externas (Heredia et al., 2025). Esta combinación permite contextualizar las anomalías y transformarlas en explicaciones comprensibles para quienes toman decisiones.

La Figura 7 resume este funcionamiento. En lugar de generar únicamente una alerta estadística, la plataforma relaciona la anomalía con información espacial, temporal y contextual para construir una explicación fundamentada. En estudios realizados sobre robos de teléfonos móviles en São Paulo, por ejemplo, el sistema logró

asociar determinados incrementos delictivos con eventos masivos, como el Carnaval o festividades religiosas, evidenciando cómo las modificaciones en la movilidad y en la concentración de personas alteran también las oportunidades para la comisión de delitos (Heredia et al., 2025).

FIGURA N.º 7



Figura 7. Descripción general de AnomalyExplain. La plataforma integra datos espaciales, series temporales y contexto externo (1) en un flujo que combina análisis (2), visualización interactiva (3) y un módulo LLM (4) para generar explicaciones sobre posibles causas de anomalías criminales, apoyadas en evidencia espacial y temporal, así como en fuentes externas. Adaptado de Heredia et al. (2025).

En conjunto, ambas herramientas ilustran la dirección que está tomando la investigación en inteligencia urbana. El objetivo ya no consiste únicamente en anticipar dónde podría ocurrir un delito, sino también en comprender por qué sucede, explicar los factores que intervienen y evaluar posibles alternativas de intervención antes de implementarlas. Este cambio representa un paso importante hacia una gestión de la seguridad pública más transparente, fundamentada y orientada al aprendizaje continuo.

CONCLUSIONES: HACIA UN MODELO APLICABLE PARA EL PERÚ

La persistente percepción de inseguridad en el Perú —donde más del 85 % de la población urbana considera posible ser víctima de un delito— evidencia la necesidad de fortalecer las capacidades del Estado mediante un enfoque científico para la gestión de la seguridad pública. Este desafío exige superar una lógica centrada exclusivamente en la

reacción frente al delito y avanzar hacia estrategias preventivas sustentadas en el análisis criminal a microescala, el estudio de patrones espaciales, la explicabilidad de los modelos de inteligencia artificial y la evaluación sistemática de distintos escenarios de intervención.

La evidencia presentada a lo largo de este artículo muestra que la seguridad urbana no depende únicamente de la cantidad de delitos registrados. También está profundamente relacionada con la manera en que las personas experimentan y perciben los espacios que habitan. Por ello, comprender el papel del entorno físico, de las dinámicas sociales y de los factores que generan desorden urbano resulta indispensable para

identificar riesgos y diseñar estrategias de prevención más eficaces.

Las herramientas descritas en este trabajo demuestran que la inteligencia artificial, el análisis espacial y la ciencia de datos pueden contribuir significativamente a mejorar la gestión de la seguridad pública. Sin embargo, su verdadero potencial no reside únicamente en la capacidad de producir predicciones cada vez más precisas. Su principal aporte consiste en ofrecer explicaciones, simular escenarios y proporcionar evidencia que permita tomar decisiones mejor fundamentadas.

En conjunto, estas aproximaciones ofrecen una base científica para



Ilustración: IA — Copilot, prompt y edición Kelly Vásquez Chaparro

La evidencia presentada a lo largo de este artículo muestra que la seguridad urbana no depende únicamente de la cantidad de delitos registrados. También está profundamente relacionada con la manera en que las personas experimentan y perciben los espacios que habitan.

diseñar políticas públicas más precisas, transparentes y viables. Desde esta perspectiva, la aplicación de métodos científicos al estudio del crimen configura una oportunidad relevante para el Perú, donde la tecnología no sustituye la acción del Estado, sino que la fortalece mediante mejores capacidades de análisis, prevención y planificación.

No obstante, para que este modelo pueda implementarse de manera efectiva, no basta con disponer de herramientas tecnológicas avanzadas. También es indispensable contar con datos confiables, sistemas interoperables, instituciones capaces de analizar la información y mecanismos de gobernanza que garanticen la transparencia, la protección de los derechos ciudadanos y el uso responsable de la inteligencia artificial.

En definitiva, la inteligencia urbana representa mucho más que un conjunto de tecnologías aplicadas a la seguridad. Constituye una nueva forma de comprender el territorio, anticipar riesgos y construir políticas públicas sustentadas en evidencia. Su mayor contribución no radica únicamente en hacer más eficiente la respuesta frente al delito, sino en fortalecer la capacidad del Estado para prevenirlo y mejorar la calidad de vida de la ciudadanía.

Referencias bibliográficas

- Bernasco, W., & Block, R. (2011). Robberies in Chicago: A block-level analysis of the influence of crime generators, crime attractors, and offender anchor points. *Journal of Research in Crime and Delinquency*, 48(1), 33–57. <https://doi.org/10.1177/0022427810384135>
- Chainey, S., Tompson, L., & Uhlig, S. (2008). The utility of hotspot mapping for predicting spatial patterns of crime. *Security Journal*, 21(1–2), 4–28. <https://doi.org/10.1057/palgrave.sj.8350066>
- Clarke, R. V., & Eck, J. E. (2007). Understanding risky facilities (Problem-Oriented Guides for Police, Problem-Specific Guide Series No. 6). Office of Community Oriented Policing Services, U.S. Department of Justice. <https://portal.cops.usdoj.gov/resourcecenter/content.ashx/cops-p118-pub.pdf>
- Garcia-Zanabria, G., Gomez-Nieto, E., Silveira, J., Poco, J., Nery, M., Adorno, S., & Nonato, L. G. (2020). Mirante: A visualization tool for analyzing urban crimes. En 2020 33rd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI) (pp. 148–155). IEEE. <https://doi.org/10.1109/SIBGRAPI51738.2020.00028>
- Garcia-Zanabria, G., Raimundo, M. M., Poco, J., Nery, M. B., Silva, C. T., Adorno, S., & Nonato, L. G. (2022). CriPAV: Street-level crime patterns analysis and visualization. *IEEE Transactions on Visualization and Computer Graphics*, 28(12), 4000–4015. <https://doi.org/10.1109/TVCG.2021.3111146>
- Garcia-Zanabria, G., Silveira, J., Poco, J., Paiva, A., Nery, M. B., Silva, C. T., Adorno, S., & Nonato, L. G. (2021). CrimAnalyzer: Understanding crime patterns in São Paulo. *IEEE Transactions on Visualization and Computer Graphics*, 27(4), 2313–2328. <https://doi.org/10.1109/TVCG.2019.2947515>
- Heredia, J., Estrada-Rayme, L., Matos-Cangalaya, J., & Poco, J. (2025). Interactive exploration and explanation of spatio-temporal anomalies with Graph-LLM integration. En 2025 38th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI) (pp. 1–6). IEEE. <https://doi.org/10.1109/SIBGRAPI67909.2025.11223398>

Instituto Nacional de Estadística e Informática. (2025). Estadísticas de seguridad ciudadana: Informe técnico (N.º 05). <https://www1.inei.gob.pe/media/MenuRecursivo/boletines/informe-tecnico-estadisticas-de-seguridad-ciudadana.pdf>

Jacobs, J. (1961). *The death and life of great American cities*. Random House.

Kahhale, I. (2022). Neural basis of antisocial behaviour. *Nature Reviews Psychology*, 1(3), 129. <https://doi.org/10.1038/s44159-022-00027-1>

Keuschnigg, M., & Wolbring, T. (2015). Disorder, social capital, and norm violation: Three field experiments on the broken windows thesis. *Rationality and Society*, 27(1), 96–126. <https://doi.org/10.1177/1043463114561749>

Lavi, B., Tokuda, E., Moreno-Vera, F., Nonato, L., Silva, C., & Poco, J. (2022). 17K-Graffiti: Spatial and crime data assessments in São Paulo city. En *Proceedings of the 17th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications* (pp. 968–975). <https://doi.org/10.5220/0010883300003124>

Moreno-Vera, F., De-la-Puente, A., & Poco, J. (2025). UrbanPhysicalDisorder-4K: Understanding urban perception via counterfactuals and Street View signs of physical disorder. En 2025 IEEE International Conference on Big Data (BigData) (pp. 5194–5200). IEEE. <https://doi.org/10.1109/BigData66926.2025.11401786>

Moreno-Vera, F., Lavi, B., & Poco, J. (2021a). Quantifying urban safety perception on Street View images. En IEEE/WIC/ACM International Conference on Web Intelligence (pp. 611–616). <https://doi.org/10.1145/3486622.3493975>

Moreno-Vera, F., Lavi, B., & Poco, J. (2021b). Urban perception: Can we understand why a street is safe? En I. Batyrshin, A. Gelbukh, & G. Sidorov (Eds.), *Advances in Computational Intelligence* (Vol. 13067, pp. 277–288). Springer. https://doi.org/10.1007/978-3-030-89817-5_21

Moreno-Vera, F., & Poco, J. (2025). Assessing urban environments with vision-language models: A comparative analysis of AI-generated ratings and human volunteer evaluations. En 2025 *International Joint Conference on Neural Networks (IJCNN)* (pp. 1–8). IEEE. <https://doi.org/10.1109/IJCNN64981.2025.11229058>

- Raimundo, M. M., Garcia-Zanabria, G., Nonato, L. G., & Poco, J. (2025). CounterCrime: Using counterfactual explanations to explore crime reduction scenarios. *IEEE Transactions on Visualization and Computer Graphics*, 31(10), 9008–9023. <https://doi.org/10.1109/TVCG.2025.3586202>
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "Why should I trust you?": Explaining the predictions of any classifier. En *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1135–1144). <https://doi.org/10.1145/2939672.2939778>
- Shaffer, B. (2024). The data-driven city: Analytics for smart urbanism. <https://www.amazon.com.br/Data-Driven-City-Analytics-Urbanism-English-ebook/dp/B0D1NZ6XYH>
- United Nations Office on Drugs and Crime. (s. f.). Crime prevention. <http://www.unodc.org/unodc/en/urban-safety/crime-prevention.html>
- Wachter, S., Mittelstadt, B., & Russell, C. (2018). Counterfactual explanations without opening the black box: Automated decisions and the GDPR. *Harvard Journal of Law & Technology*, 31(2), 841–887. <https://doi.org/10.2139/ssrn.3063289>
- Weisburd, D. (2015). The law of crime concentration and the criminology of place. *Criminology*, 53(2), 133–157. <https://doi.org/10.1111/1745-9125.12070>
- Wilson, J. Q., & Kelling, G. L. (1982). Broken windows. *The Atlantic Monthly*, 249(3), 29–38.

INTELIGENCIA URBANA PARA LA SEGURIDAD PÚBLICA: DEL ANÁLISIS ESPACIAL A LA ACCIÓN



El 85.1% de la población urbana en Perú **considera posible ser víctima de un delito.**



El desorden físico visible como grafitis y basura deteriora la percepción de seguridad urbana.



Los mapas de calor tradicionales ocultan la **concentración delictiva real ocurrida en microlugares.**



Sistemas como CounterCrime usan contrafactuales para simular escenarios de reducción del delito.



AnomalyExplain integra modelos de lenguaje para traducir anomalías delictivas en narrativas.