



PREDICCIÓN DELICTIVA CON MACHINE LEARNING Y DEEP LEARNING: AVANCES RECIENTES

Israel Hernández Vázquez

Instituto Politécnico Nacional, UPIICSA

ihernandezv1900@alumno.ipn.mx

ORCID: [0009-0002-2029-4475](https://orcid.org/0009-0002-2029-4475)

Claudia Marina Vicario Solórzano

Instituto Politécnico Nacional, UPIICSA

cvicario@ipn.mx

ORCID: [0000-0003-0144-3607](https://orcid.org/0000-0003-0144-3607)

Abstract

La predicción delictiva en entornos urbanos se apoya cada vez más en métodos basados en datos. La literatura reciente converge en dos vertientes: la estimación de riesgo macro-social y la predicción micro-espacial de hotspots. Esta monografía sistematiza avances en aprendizaje automático (ML) y aprendizaje profundo (DL), cubriendo los tipos de delitos más abordados, familias algorítmicas predominantes y el ecosistema tecnológico. Destacan los ensembles (p. ej., XGBoost), las arquitecturas espacio-temporales (ConvLSTM, ST-ResNet con LSTM, acoples GCN-LSTM) y la IA explicable (XAI) (SHAP, LIME). El aprendizaje de representaciones en grafos (GAT y embeddings multigrafo) y los Transformers con atención dispersa robustecen la escalabilidad. Se observa integración con GIS/GeoAI y optimización de patrullajes con aprendizaje por refuerzo profundo. Los hallazgos subrayan la interpretabilidad, la evaluación rigurosa y la gobernanza ética como condiciones para una implementación responsable.

Palabras clave: Predicción delictiva; Aprendizaje automático; Aprendizaje profundo; IA explicable; Hotspots

La predicción de la criminalidad urbana ha madurado hacia enfoques apoyados en datos, integrando aprendizaje automático (ML) y aprendizaje profundo (DL) con información geográfica, movilidad y contexto socioeconómico. Dos líneas se han consolidado: por un lado, la estimación de riesgo macro-social, que busca niveles o tendencias por distrito o región a partir de

indicadores socioeconómicos y ambientales; por otro, la predicción micro-espacial de hotspots, que opera con rejillas finas y ventanas temporales cortas para anticipar concentraciones de incidencia (Albors Zumel et al., 2025; İlğün & Dener, 2025; Kim et al., 2025; Shahmoradi et al., 2025). En paralelo, se ha incrementado la atención a la explicabilidad de la IA (XAI), principalmente con SHAP (valores de Shapley) y LIME (Explicación



Local Agnóstica al Modelo), y al trato justo en el despliegue operativo (Ersöz et al., 2025; Khalifa et al., 2025; Liang et al., 2025)

Este ensayo persigue un objetivo general: ofrecer un panorama actualizado y comprensible de los avances recientes en la predicción delictiva con ML/DL, articulando los tipos de delitos más cubiertos, las familias algorítmicas predominantes, las herramientas tecnológicas y las buenas prácticas de evaluación, explicabilidad y equidad. La propuesta es exponer con lenguaje claro, evitando tecnicismos innecesarios, cómo estos elementos se conectan en la práctica y qué implicaciones tienen para la toma de decisiones.

Tipos de delitos y granularidades

La literatura reciente converge en la cobertura de dos grandes familias delictivas: los delitos contra la propiedad (hurto, allanamiento, robo de vehículo) y los delitos violentos (asalto, homicidio, robo con violencia). Este énfasis responde tanto al impacto social y operativo de estas conductas como a la disponibilidad y calidad de registros. En Beijing, la predicción de robo a largo plazo pone el foco en cómo el tejido urbano, concentración de comercios, oficinas, servicios y otros puntos de interés (POIs), moldea el riesgo. El uso de ML en conjunto con herramientas de explicabilidad como SHAP permitió identificar relaciones no lineales, crecientes, decrecientes y curvilíneas, entre variables ambientales y ocurrencia delictiva (Zhang et al., 2025). En el caso de Chicago, los modelos que combinan redes residuales espacio-temporales (ST-ResNet) con memoria de largo y corto plazo (LSTM) capturan dependencias espaciales y periodicidades diarias y semanales, logrando predicciones más precisas de hotspots de robo cuando se integran señales externas como

clima y proximidad a parques (Shahmoradi et al., 2025).

Para estructuras administrativas como distritos policiales, se ha mostrado que integrar un Transformer eficiente para series largas (Informer) con una red de convolución en grafos espacio-temporal (ST GCN) ayuda a modelar simultáneamente cuatro categorías: asalto, robo, daños criminales y hurto, aprovechando la correlación entre unidades vecinas y patrones de periodicidad (Fan et al., 2025). En Manhattan (NYC), trabajos de representación regional mediante embeddings multigrafo (MGRL4RE) demuestran que combinar vistas semánticas (POIs), espaciales (proximidad) y de movilidad (flujos origen-destino) produce vectores informativos que, al alimentar modelos downstream de predicción de crimen, mejoran el error absoluto medio, el error cuadrático medio y el coeficiente de determinación (Chen et al., 2025a).

Más allá de estas ciudades, se observan aproximaciones con categorías agregadas. En Eswatini, por ejemplo, se reconocen cinco grupos amplios: autoridad, moral pública, persona, estatutarios y propiedad, que facilitan la planificación de recursos en contextos con menor granularidad de datos; allí, XGBoost, Random Forest y MLP alcanzan desempeños útiles para priorización operativa (Tsabedze et al., 2025). En Corea (Daegu y Gwangju), la resolución espacial llega a rejillas de 10–20 m, con buffers para aproximar la relación entre entorno construido, flujo peatonal y llamadas al 112; las explicaciones con SHAP revelan el peso de variables como población visitante, número de negocios y ventas con tarjeta, mientras carreteras muestran asociaciones negativas, ayudando a diseñar la instalación óptima de Circuito Cerrado de Televisión (CCTV) (Choi et al., 2025; Kim et al., 2025).

La elección de granularidad: tamaño de celdas y ventana temporal, tiene implicaciones



directas: rejillas muy finas (por ejemplo, 0.077 millas cuadradas) y ventanas de 12 horas elevan la sensibilidad del modelo a un evento poco frecuente, por lo que se beneficiará de arquitecturas con convoluciones espaciales y memoria temporal (ConvLSTM), además de incorporar variables de movilidad y sociodemografía que enriquecen la señal (Albors Zumel et al., 2025). En este escenario, la precisión tiende a bajar por el desbalance, mientras el recall mejora; ello obliga a evaluar con métricas que reflejen la utilidad operativa sin inducir falsas expectativas. En contraste, particionar por hotspots de densidad múltiple y luego ajustar modelos por tramo temporal puede estabilizar el error en horizontes semanales (Cesario et al., 2024).

Otro aspecto crítico es la definición de población en riesgo. Usar residentes como denominador no siempre captura dinámicas de visita o tránsito; incorporar población flotante puede alterar sustancialmente métricas como precisión, recall y F1, cambiando la evaluación de qué zonas son verdaderamente riesgosas (Khalifa & Hardyns, 2025). Finalmente, evitar la rigidez de intervalos fijos mediante marcos de tiempo continuo: como FlexiCrime, reduce la sensibilidad del modelo a cambios en la duración o inicio de las ventanas, manteniendo desempeño más estable cuando se prueban intervalos flexibles (Jin et al., 2024).

Algoritmos predominantes en la predicción delictiva

Dentro del aprendizaje automático (ML) clásico, los ensembles: XGBoost, Random Forest, LightGBM y CatBoost, persisten como opciones de referencia gracias a su buen rendimiento y a la posibilidad de integrar explicabilidad con SHAP y LIME. Su robustez ante variables heterogéneas y la facilidad para incorporar ingeniería de atributos temporales y espaciales explican su presencia en estudios

con múltiples ciudades y fuentes de datos (Ersöz et al., 2025; Khalifa et al., 2025; Kim et al., 2025). En contextos donde el objetivo es comparar partición administrativa versus partición basada en aprendizaje no supervisado, los algoritmos de clustering de densidad: DBSCAN y HDBSCAN y propuestas de densidad múltiple: CHD, muestran que definir hotspots más homogéneos puede mejorar el pronóstico con modelos SARIMA, reduciendo el MAPE y el MAE frente a particiones por distrito (Cesario et al., 2024, 2025).

En series de tiempo, los modelos estadísticos ARIMA/SARIMA: bien especificados por hotspot o región, siguen siendo competitivos frente a redes neuronales recurrentes cuando la estacionalidad es pronunciada y el horizonte es de semanas. La ventaja radica en su parsimonia y capacidad para capturar periodicidades anuales/semanales con inferencia transparente, mientras que LSTM puede requerir mayor volumen de datos y cuidado con el sobreajuste (Cesario et al., 2025, 2025; İlgün & Dener, 2025). No obstante, cuando la dinámica presenta múltiples escalas temporales y patrones complejos, el DL: por ejemplo, N-HITS o ConvLSTM, ofrece mejoras, especialmente al integrar variables externas de movilidad y contexto (Albors Zumel et al., 2025; Elseidi, 2025).

El aprendizaje profundo (DL) espacio-temporal agrupa aportes centrales. Las combinaciones ST-ResNet + LSTM equilibran representación espacial y memoria temporal; su eficacia se evidencia en Chicago con hotspots de robo cuando se agregan señales ambientales (Shahmoradi et al., 2025). ConvLSTM, por su parte, opera de manera natural sobre rejillas y secuencias cortas, capturando patrones locales con convoluciones y dependencias temporales con LSTM; su desempeño en recall frente a LR y



RF apunta a que, en contextos de alto desbalance, reconocer el evento poco frecuente es más valioso que maximizar la precisión (Albors Zumel et al., 2025).

Las redes en grafos han ganado protagonismo. Modelos como GCN-LSTM amplían la capacidad de aprendizaje al incorporar relaciones topológicas entre zonas, con mecanismos que robustecen frente a ruido y datos incompletos (Shan et al., 2025). En la frontera de eficiencia, los Transformers con atención dispersa (ProbSparse) y convolución gráfica adaptativa (ACSAformer) reducen la complejidad de $O(L^2)$ a $O(L \cdot \log L)$ y aprenden matrices de adyacencia dinámicas, mostrando mejoras en MSE/MAE y estabilidad ante ruido gaussiano (Qin et al., 2025).

Otra línea de trabajo consiste en aprender representaciones de regiones urbanas. MTGC: embedding temporal multiescala con contraste y MGRL4RE: multi-grafo con atención (GAT) y fusión multi-vista, no predicen directamente el crimen, sino que construyen vectores que, cuando se usan como entrada en tareas downstream (p. ej., regresión Lasso o clasificación), mejoran el rendimiento y, sobre todo, la transferibilidad entre zonas con perfiles distintos (Chen et al., 2025; Li et al., 2026).

En ámbitos específicos, se exploran metaheurísticas y búsqueda automática de arquitecturas. El diseño RICCNN con optimización Jarrett-Butterfly y Parrot para selección de características y transformaciones cuánticas aleatorias (RQCT) ilustra cómo se puede adaptar una red convolucional para invariancia rotacional y preprocesamiento ruidoso, manteniendo implementaciones en PyTorch sobre hardware modesto (Li et al., 2026). En paralelo, la búsqueda de arquitecturas neuronales (NAS), combinada con ajuste de hiperparámetros, se usa para

seleccionar modelos competitivos frente a enfoques clásicos (Alshahrani & Khanzada, 2025).

Finalmente, dos líneas complementarias aportan valor operativo. Primero, los modelos multimodales que integran texto, imágenes y video de redes sociales: SMDCnet, muestran que enriquecer con señales sociales puede elevar precisión de clasificación y reducir error en pronóstico, siempre que se cuiden sesgos de la fuente y representatividad («Text and Visual Information Enriched Multimodal Deep Learning Model for Crime Prediction Using Social Media Information», 2025). Segundo, la optimización con aprendizaje por refuerzo profundo (DRL) y navegación en grafos con sensores sintetizados permite planificar patrullajes sensibles al riesgo, evaluar recompensas acumuladas y discutir explícitamente desigualdades en distribución de visitas (DDQN vs. PPO) (Liang et al., 2025; Majumdar et al., 2025).

Herramientas tecnológicas y aplicativos

El ecosistema tecnológico predominante es Python, con bibliotecas de aprendizaje automático y profundo (scikit-learn, XGBoost, TensorFlow/Keras, PyTorch) y entornos de experimentación (Jupyter/Colab). La integración con Sistemas de Información Geográfica (GIS): QGIS, ArcGIS, OSMnx, permite geocodificación, extracción de redes viales y cálculo de métricas espaciales (distancias, buffers, densidades), esenciales para construir variables que capten la estructura urbana. En proyectos de evaluación y reproducibilidad, marcos como STEval definen escenarios controlados (granularidad temporal/espacial, resiliencia, volumen, ventanas) y exponen métricas (HR, MSE, RMSE, PAI, ALS) de forma estandarizada, habilitando comparaciones entre modelos bajo condiciones equivalentes (Amarante et al., 2025). Por su parte, repos públicos para



algoritmos de clustering de densidad múltiple (CHD) y datasets en Zenodo/figshare fomentan transparencia y reutilización (Albors Zumel et al., 2025; Cesario et al., 2025; Qin et al., 2025).

El pipeline típico incluye: (i) ingestión y limpieza de datos: detección de duplicados, imputación de faltantes, normalización de variables; (ii) geocodificación y enriquecimiento: POIs, clima, movilidad, datos censales; (iii) ingeniería de atributos: fechas (año, mes, día, fin de semana), transformaciones espaciales (coordenadas polares, rotaciones), agregaciones multiescala; (iv) particionado temporal cuidadoso para evitar fuga (validación temporal o holdout final); (v) entrenamiento/ajuste con técnicas como búsqueda de hiperparámetros (random/grid), y eventualmente NAS; (vi) evaluación con métricas acordes al objetivo: error para conteos, PAI/HR para hotspots, AUC/F1 para clasificación; (vii) explicabilidad con SHAP/LIME y visualización de mapas de riesgo; y (viii) documentación de decisiones para permitir auditoría (Alshahrani & Khanzada, 2025; Devi et al., 2025; İlğün & Dener, 2025; Kim et al., 2025).

Tabla 1 Inventario tecnológico y lenguaje de programación

Artículo	Herramientas / Frameworks	Lenguaje
Li (2026)	MTGC, PyTorch, Adam, NVIDIA 4090	Python
Mythily Devi (2025)	RICCNN-CP-JBOA, PyTorch 1.11, CUDA 11.6, Grid Search	Python
Amarante (2025)	STEval, YAML, HR/MSE/RMSE/PAI/ALS	No se menciona
Khalfa et al. (2025)	XGBoost, SHAP, LIME, ALE, Permutation FI, ArcGIS Geocoder API	Python (3.11)

Alshahrani & Khanzada (2025)	NAS, AutoKeras, KerasTuner, RRA	No se menciona
Khalfa & Hardyns (2025)	LogReg, RF, XGBoost; Precision/Recall/F1, AIC	No se menciona
Liang et al. (2025)	XGBoost, DRL (PyTorch), OSMnx, GA, Gurobi	Python
Shahmoradi et al. (2025)	ST-ResNet, LSTM, atención, Keras	Python
Elseidi (2025)	AutoARIMA, AutoLightGBM, N-HiTS, TimeGPT	No se menciona
Majumdar et al. (2025)	ST GCN, DQN/DDQN/PPO, simulación, KDE	No se menciona
Iacobescu & Susnea (2025)	ARIMA-ANN, SHAP, TensorFlow/Keras, pandas, NumPy, scikit-learn	Python (3.10)
Fan et al. (2025)	Informer, ST GCN (GCN + ST-ResNet), NAdam, cosine annealing	No se menciona
Ilğün & Dener (2025)	XGBoost, CatBoost, RF, LSTM/BiLSTM, SARIMA, Prophet, HWES	No se menciona
Zhang et al. (2023)	GBDT, XGBoost, RF, SHAP, KMeans, Baidu APIs	No se menciona
Shan et al. (2025)	Ada-GCNLSTM (GCN + LSTM + RMU + MMD)	No se menciona
Chen et al. (2025)	MGRL4RE (GAT + fusión multi-vista), Lasso	No se menciona
Silva et al. (2025)	k-means, chi-cuadrado, ranking bayesiano, OSMnx, NetworkX, CityHub, Google Places	No se menciona
Taha (2025)	Python 3.6, TensorFlow 2.10, Adam, Keras	Python



Cesario et al. (2025)	scikit-learn (DBSCAN/HDBSCAN), pmdarima (SARIMA), CHD (repo)	Python
Ersöz et al. (2025)	Weka, Python, R, SHAP, LIME; GeoAI/GIS	Python, R
Albors Zumel et al. (2025)	ConvLSTM; dataset Zenodo (multicanal)	No se menciona
Li et al. (2024)	CNN-LSTM; data binning	No se menciona
Tsabedze et al. (2025)	Jupyter/Colab, pandas, scikit-learn, MLP, XGBoost, RF, KNN	Python
Palanisa my & Arunachalam (2025)	Python 3.11, Word2Vec, LDA, Mask R-CNN, ConvBiLSTM, Adam	Python
Kim et al. (2025)	XGBoost, SHAP, zonal statistics, balanceo de clases	No se menciona
Qin et al. (2025)	PyTorch, Adaptive GCN (MixHop), ProbSparse attention	Python
Choi et al. (2025)	Python (ML, MCLP), Keras (FNN), QGIS, RStudio	Python, R
Jin et al. (2024)	Atención temporal continua, Neural ODE, Type-Aware CNF, GRU	No se menciona
Dass et al. (2024)	Python (Twitter API), SVM/NB/RF/DT/LR; RNN/LSTM/GRU	Python
Cesario et al. (2024)	CHD, SARIMA, LSTM (comparación)	No se menciona

Evaluación, explicabilidad y equidad

Evaluar una predicción delictiva útil exige alinear métricas con objetivos operativos. Para conteos por celda o distrito, el Error Absoluto Medio (MAE), el Error Cuadrático Medio (MSE) y su raíz (RMSE) permiten comparar magnitud y estabilidad del error; cuando el objetivo es identificar hotspots, el Índice de

Precisión Predictiva (PAI) y el Hit Rate (HR) informan sobre la proporción de eventos correctamente anticipados dentro de las áreas marcadas. En Chicago, el uso de ST-ResNet + LSTM con señales externas eleva el HR y reduce el RMSE frente a baselines como CNN-LSTM o ConvLSTM, especialmente en rejillas de 500 m y 1,000 m; además, se observa mejora en el PAI al concentrar la predicción en el top de celdas de riesgo (Shahmoradi et al., 2025). En el estudio que integra Informer y ST GCN, los autores reportan superioridad estadística (t test pareado) frente a ARIMA, XGBoost y variantes recurrentes (LSTM, GRU), con reducciones visibles de MAE y RMSE para asalto, robo, daños criminales y hurto (Fan et al., 2025).

En contextos de clasificación, el conjunto de métricas: accuracy, precision, recall, F1 y AUC, requiere interpretación prudente según el desbalance. En Daegu, XGBoost alcanza una accuracy cercana a 0.90 con recall y precision balanceados, y los valores SHAP identifican el aporte de variables como población visitante y actividad comercial; estos resultados se sostienen en rejillas de 10 m y buffers óptimos de 20 m (Kim et al., 2025 [25]). En Eswatini, XGBoost supera a RF, MLP y KNN con una accuracy en torno a 71%, demostrando que con ingeniería de atributos temporal/espacial se puede extraer valor predictivo incluso en datos administrativos heterogéneos (Tsabedze et al., 2025).

La explicabilidad (XAI) ocupa un lugar central: técnicas pos-hoc como SHAP y LIME aclaran el peso relativo de cada variable, revelan relaciones no lineales y ayudan a detectar donde el modelo podría estar sobreajustando. En predicción de robo residencial a micro-lugares, la comparación de XAI permite elegir explicaciones más estables y útiles para la toma de decisiones (Khalifa et al., 2025); en Beijing, SHAP muestra curvas



de dependencia que explican cómo la densidad de POIs y la movilidad influyen en el riesgo de robo (Zhang et al., 2025); y en la revisión amplia sobre IA y explicabilidad, se advierte que su adopción práctica aún es limitada y debe fortalecerse (Ersöz et al., 2025).

En el plano de equidad y gobernanza, comienzan a integrarse indicadores como el coeficiente de Gini, el índice de justicia distributiva (JFI) y el Gini Policing Index (GPI) para medir desigualdad entre visitas policiales y distribución del crimen. En el diseño de zonas con DRL, se observan trade-offs entre cobertura y equidad; por ejemplo, estrategias basadas en PPO pueden repartir visitas de modo más equilibrado que DDQN, aunque la eficiencia en recompensa acumulada varíe según el entorno (Majumdar et al., 2025). En el caso de Los Ángeles, combinar XGBoost para riesgo con DRL para optimización espacial permite ajustar criterios de cobertura y variación (CV), con análisis explícito del Gini y el Jain's Fairness Index (JFI), lo que evidencia el valor de introducir fairness desde el diseño de la política (Liang et al., 2025).

Retos y oportunidades

La calidad de datos es un reto transversal: registros incompletos, errores de geocodificación, cambios en definiciones de delitos y desbalance extremo pueden deteriorar el rendimiento. Preprocesos como limpieza, imputación, normalización y selección de características: por información mutua o rankings robustos, ayudan a estabilizar el aprendizaje (Alshahrani & Khanzada, 2025; İlgün & Dener, 2025). En granularidades finas, el desbalance obliga a ajustar umbrales y adoptar estrategias de muestreo: como oversampling aleatorio, para evitar que el modelo ignore casos minoritarios (Choi et al., 2025).

La transferencia entre ciudades se mantiene limitada: modelos calibrados en Chicago o Los Ángeles pueden perder desempeño en entornos con estructura urbana distinta. En respuesta, se exploran embeddings de región: MTGC y MGRL4RE, que capturan propiedades semánticas, espaciales y de movilidad, con mejoras en tareas downstream de predicción y potencial para generalización; asimismo, arquitecturas con atención dispersa y convolución gráfica adaptativa (ACSAformer) muestran mayor robustez ante ruido y cambios de horizonte (Chen et al., 2025; Li et al., 2026; Qin et al., 2025).

Los criterios operativos y éticos son otro frente. La presión por maximizar aciertos puede, si no se controlan sesgos, intensificar vigilancia en áreas ya históricamente sobrepolicadas. Incorporar fairness como restricción, auditar resultados con indicadores de desigualdad y documentar supuestos, por ejemplo, cómo se define población en riesgo, son pasos clave para legitimidad y sostenibilidad (Ersöz et al., 2025; Khalfa et al., 2025; Liang et al., 2025). En paralelo, el uso de datos de movilidad y redes sociales eleva el potencial predictivo, pero también exige marcos de privacidad: minimización de datos, agregación, anonimización y transparencia en los fines del uso (Albors Zumel et al., 2025; Silva et al., 2025; «Text and Visual Information Enriched Multimodal Deep Learning Model for Crime Prediction Using Social Media Information», 2025)

Finalmente, la escalabilidad computacional impulsa diseños eficientes: Informer y ACSAformer reducen la complejidad de atención y optimizan el procesamiento de secuencias largas; el acople con grafos (ST GCN) permite explotar relaciones espaciales de manera dinámica. Reportar parámetros (optimizadores como Adam/NAdam, tasas de aprendizaje, tamaños de batch) y repetir experimentos ayuda a asegurar estabilidad y



reproducibilidad (Fan et al., 2025; Qin et al., 2025).

Conclusiones

El campo de predicción delictiva avanza hacia arquitecturas y marcos que equilibran tres objetivos: desempeño, explicabilidad y equidad. Los ensembles siguen siendo base confiable por su rendimiento y capacidad de interpretación; los modelos estadísticos ARIMA/SARIMA mantienen vigencia en horizontes semanales con estacionalidad; y el DL espacio-temporal: ConvLSTM, ST-ResNet+LSTM, ST GCN, Transformers con atención dispersa, aporta ventajas claras en granularidades finas y escenarios complejos. La integración de datos de movilidad, POIs y clima eleva sensibilidad contextual, mientras que XAI: SHAP/LIME y fairness: Gini, JFI, GPI, forjan condiciones de legitimidad para implementación.

De cara a la adopción responsable, se recomiendan prácticas coherentes con la evidencia: (i) fijar la resolución espacial y temporal según el objetivo operativo, evitando intervalos rígidos cuando afecten estabilidad; (ii) documentar decisiones de preprocesamiento, variables externas y supuestos (población en riesgo); (iii) evaluar con métricas alineadas: PAI/HR para hotspots, MAE/RMSE para conteos, AUC/F1 para clasificación; (iv) incluir XAI desde el diseño y auditar desigualdades con indicadores de fairness; (v) promover reproducibilidad con marcos de evaluación y repos públicos; y (vi) explorar representaciones de región y arquitecturas eficientes para escalar y transferir. Estas pautas aumentan la utilidad práctica y ayudan a que la predicción delictiva aporte valor real en la gestión urbana, sin sacrificar transparencia ni justicia (Ersöz et al., 2025; İlgün & Dener, 2025; Qin et al., 2025; Shahmoradi et al., 2025)

Referencias

- Albors Zumel, A., Tizzoni, M., & Campedelli, G. M. (2025). Deep Learning for Crime Forecasting: The Role of Mobility at Fine-grained Spatiotemporal Scales. *Journal of Quantitative Criminology*. <https://doi.org/10.1007/s10940-025-09629-3>
- Alshahrani, R. A., & Khanzada, T. J. S. (2025). Improved Crime Prediction Using Hybrid Neural Architecture Search Together with Hyperparameter Tuning. *International Journal of Computational Intelligence Systems*, 18(1), 195. <https://doi.org/10.1007/s44196-025-00888-3>
- Amarante, G., Pimenta, M., Andrade, Y., Senna, M., Menezes, R., Faria, A. H., Vilas-Boas, M., de Paula Neto, F. M., da Silva, J. P., de Sousa, E. R., da Silva, J., Jr., W. M., Teodoro, G., Rocha, L., & Ferreira, R. (2025). STEval: A framework for evaluating spatio-temporal crime prediction models. *Engineering Applications of Artificial Intelligence*, 162, 112123. <https://doi.org/10.1016/j.engappai.2025.112123>
- Cesario, E., Lindia, P., & Vinci, A. (2024). Multi-density crime predictor: An approach to forecast criminal activities in multi-density crime hotspots. *Journal of Big Data*, 11(1), 75. <https://doi.org/10.1186/s40537-024-00935-4>
- Cesario, E., Lindia, P., & Vinci, A. (2025). Comparing Machine Learning-Based Crime Hotspots Versus Police Districts: What's the Best Approach for Crime Forecasting? *IEEE Access*, 13, 133053-133077. <https://doi.org/10.1109/ACCESS.2025.3592668>
- Chen, M., Li, Z., Jia, H., Shao, X., Zhao, J., Gao, Q., Yang, M., & Yin, Y. (2025a). MGRL4RE: A Multi-Graph Representation Learning Approach for Urban Region Embedding. *ACM Transactions on Intelligent Systems and*



- Technology*, 16(2), 1-23.
<https://doi.org/10.1145/3712698>
- Chen, M., Li, Z., Jia, H., Shao, X., Zhao, J., Gao, Q., Yang, M., & Yin, Y. (2025b). MGRL4RE: A Multi-Graph Representation Learning Approach for Urban Region Embedding. *ACM Transactions on Intelligent Systems and Technology*, 16(2), 1-23.
<https://doi.org/10.1145/3712698>
- Choi, B.-G., Lee, S.-W., & Lim, H.-J. (2025). Determining Optimal Surveillance Camera Installation Locations for Crime Prevention. *IEEE Access*, 13, 212565-212576.
<https://doi.org/10.1109/ACCESS.2025.3641443>
- Devi, B. M., Reddy, B. B., Chandra, I. S., Lakshmi, N. V. K. M., & Laxmi, C. (2025). A rotation invariant Co-ordinate convolutional neural network based crime prediction utilizing Jarrett-Butterfly optimization algorithm. *Expert Systems with Applications*, 294, 128539.
<https://doi.org/10.1016/j.eswa.2025.128539>
- Elsaidi, M. (2025). From classical models to artificial intelligence models: Prospects for crime prediction in the era of big data. *International Journal of Data and Network Science*, 9(4), 803-812.
<https://doi.org/10.5267/j.ijdns.2025.8.004>
- Ersöz, F., Ersöz, T., Marcelloni, F., & Ruffini, F. (2025). Artificial Intelligence in Crime Prediction: A Survey With a Focus on Explainability. *IEEE Access*, 13, 59646-59674.
<https://doi.org/10.1109/ACCESS.2025.3553934>
- Fan, Y., Hu, X., & Hu, J. (2025). Research on a Crime Spatiotemporal Prediction Method Integrating Informer and ST-GCN: A Case Study of Four Crime Types in Chicago. *Big Data and Cognitive Computing*, 9(7), 179.
<https://doi.org/10.3390/bdcc9070179>
- İlgün, E. G., & Dener, M. (2025). Exploratory data analysis, time series analysis, crime type prediction, and trend forecasting in crime data using machine learning, deep learning, and statistical methods. *Neural Computing and Applications*, 37(18), 11773-11798.
<https://doi.org/10.1007/s00521-025-11094-9>
- Jin, J., Hong, Y., Xu, G., Zhang, J., Tang, J., & Wang, H. (2024). *An Event-centric Framework for Predicting Crime Hotspots with Flexible Time Intervals* (Versión 1). arXiv.
<https://doi.org/10.48550/ARXIV.2411.01134>
- Khalifa, R., & Hardyns, W. (2025). On how population-at-risk estimates influence crime rates and predictions: Comparing residential and ambient-like estimates. *Applied Geography*, 185, 103780.
<https://doi.org/10.1016/j.apgeog.2025.103780>
- Khalifa, R., Theinert, N., & Hardyns, W. (2025). Comparing XAI techniques for interpreting short-term burglary predictions at micro-places. *Computational Urban Science*, 5(1), 27.
<https://doi.org/10.1007/s43762-025-00185-x>
- Kim, G., Cho, Y., Lee, J.-H., & Lee, G. (2025). Correlation analysis between urban environment features and crime occurrence based on explainable artificial intelligence techniques. *Journal of Asian Architecture and Building Engineering*, 24(6), 5751-5770.
<https://doi.org/10.1080/13467581.2024.2421260>
- Li, Y., Niu, X., Zhu, J., Wen, S., & Min, F. (2026a). Multi-Scale Temporal Graph Contrastive Embedding for urban region representation. *Information Fusion*, 125, 103464.
<https://doi.org/10.1016/j.inffus.2025.103464>
- Li, Y., Niu, X., Zhu, J., Wen, S., & Min, F. (2026b). Multi-Scale Temporal Graph Contrastive Embedding for urban region representation. *Information Fusion*, 125, 103464.
<https://doi.org/10.1016/j.inffus.2025.103464>
- Liang, X., Zhou, L., Wang, S., Zhao, X., Xue, J., Ding, Q., & Pan, Y. (2025). Spatiotemporal crime prediction and



- fairness-constrained spatial optimization with deep reinforcement learning for patrol region design. *International Journal of Applied Earth Observation and Geoinformation*, 145, 104973. <https://doi.org/10.1016/j.jag.2025.104973>
- Majumdar, S., Awasthi, A., & Szolga, L. A. (2025). Spatiotemporal Risk-Aware Patrol Planning Using Value-Based Policy Optimization and Sensor-Integrated Graph Navigation in Urban Environments. *Applied Sciences*, 15(15), 8565. <https://doi.org/10.3390/app15158565>
- Qin, Z., Wei, B., Gao, C., Zhu, F., Qin, W., & Zhang, Q. (2025). ACSAformer: A crime forecasting model based on sparse attention and adaptive graph convolution. *Frontiers in Physics*, 13, 1596987. <https://doi.org/10.3389/fphy.2025.1596987>
- Shahmoradi, N., Alesheikh, A. A., Jafari, A., & Lotfata, A. (2025). Hybrid ST-ResNet and LSTM approach for precise crime hotspot prediction. *Scientific Reports*, 15(1), 40754. <https://doi.org/10.1038/s41598-025-24559-7>
- Shan, M., Ye, C., Chen, P., & Peng, S. (2025). Ada-GCNLSTM: An adaptive urban crime spatiotemporal prediction model. *Journal of Safety Science and Resilience*, 6(2), 226-236. <https://doi.org/10.1016/j.jnlssr.2024.11.003>
- Silva, D. B. L., Vieira, T., De Barros Costa, E., Paiva, A., & Nonato, L. G. (2025). A street corner-level methodology to analyze the influence of points of interest on urban crime. *Socio-Economic Planning Sciences*, 102, 102297. <https://doi.org/10.1016/j.seps.2025.102297>
- Text and Visual Information Enriched Multimodal Deep Learning Model for Crime Prediction Using Social Media Information. (2025a). *International Journal of Intelligent Engineering and Systems*, 18(2), 145-159. <https://doi.org/10.22266/ijies2025.0331.12>
- Text and Visual Information Enriched Multimodal Deep Learning Model for Crime Prediction Using Social Media Information. (2025b). *International Journal of Intelligent Engineering and Systems*, 18(2), 145-159. <https://doi.org/10.22266/ijies2025.0331.12>
- Tsabedze, L. T., Akinnuwesi, B. A., Dlamini, B., Mbunge, E., Fashoto, S. G., Olabanjo, O., Mashwama, P., Metfula, A. S., Nxumalo, M., Badeji-Ajisafe, B., & Egenti, G. (2025). Enhancing Public Safety in Eswatini: A Machine Learning-Driven Predictive Policing Model. *Human Behavior and Emerging Technologies*, 2025(1), 9939274. <https://doi.org/10.1155/hbe2/9939274>
- Zhang, Y., Cai, L., Song, G., & Zhu, C. (2025). The Long-Term Theft Prediction in Beijing Using Machine Learning Algorithms: Comparison and Interpretation. *Crime & Delinquency*, 71(6-7), 2061-2091. <https://doi.org/10.1177/00111287231180102>

Notas de los autores

Los autores del presente artículo Israel Hernández Vázquez <https://orcid.org/0009-0002-2029-4475> y Claudia Marina Vicario Solórzano <https://orcid.org/0000-0003-0144-3607>, agradecen y dan crédito al Instituto Politécnico Nacional (IPN) por el apoyo brindado a través de la Maestría de Informática de la UPIICSA para la realización de la contribución y a la Secretaría de Investigación y Posgrado (SIP) del IPN el apoyo financiero recibido a través del proyecto 20254760.



Humanidades, Tecnología y Ciencia,
del Instituto Politécnico Nacional



Certificado de Reserva de Derechos al Uso Exclusivo del Título: 04-2010-0326124-14000-203 ISSN: 2007-1957