

Predicción de la probabilidad de robo en barrios de Bucaramanga mediante Machine Learning

Jhonnatan Yesid Bottía Ramírez

Trabajo de Grado para Optar el Título de Ingeniero Industrial

Director del proyecto de Investigación:

Henry Lamos Díaz

Doctor en Física y Matemáticas

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Estudios Industriales y Empresariales

Bucaramanga

2026

Dedicatoria

Primero que todo, dedicar este trabajo a mi yo de hace 7 años, quién soñaba con cumplir el sueño que su padre no logró, el de ser un profesional, a ese joven recién graduado de bachillerato que siempre veía la UIS desde las ventanas de su colegio con el anhelo de convertirse en un ciudadano que le aporte algo a la sociedad.

A mis padres, porque con su esfuerzo lograron que su hijo tuviera el beneficio de entrar a una excelente universidad sin ningún costo, y al que siempre apoyaron incondicionalmente dando libertad de escoger lo que quería estudiar.

A mis hermanas que siempre me apoyaron incondicionalmente dándome el apoyo moral que necesitaba para culminar esta etapa de mi vida.

A mis amigos Émerzon, Melissa y Valeria que me demostraron que la amistad es más que estar en los buenos momentos, es estar cuando realmente se necesita y quienes entendieron que mi amistad es fría pero incondicional.

Y en general a todas las personas con las que compartí tantos buenos momentos en este largo camino y con las que hoy comparto mi día a día en el ámbito laboral que me han apoyado y han exaltado mis capacidades.

Jhonnatan Yesid Bottía Ramírez

Agradecimientos

A Dios, por haberme dado la oportunidad de tener a mi lado a las personas tan maravillosas que me apoyaron y que nunca me dejaron de lado.

A mis padres que tuvieron la suficiente paciencia para entender que el camino no tenía un tiempo estimado, porque en mis caídas siempre estuvieron para ayudarme a levantar.

Al profesor Henry Lamos Diaz, porque desde el primer momento fue una persona comprensiva que entendió mi situación y me brindó todas las oportunidades y recomendaciones pertinentes en cada momento de esta etapa.

A las personas que confiaron en mis capacidades y me dieron la oportunidad de adentrarme en el mundo laboral sin experiencia y que me enseñaron que cada día se puede aprender algo nuevo.

Y, por último, a quien en algún momento fue mi pareja y que por casi 6 años estuvo motivándome a ser mejor cada día y quien hoy demuestra que se puede volver a empezar en cualquier parte del mundo y sobresalir sin importar las circunstancias.

Jhonnatan Yesid Bottía Ramírez

Tabla de Contenido

Resumen.....	10
Abstract	11
Introducción	12
Tabla de Cumplimiento de Objetivos	14
1. Revisión de la Literatura.....	16
1.1. Análisis Bibliométrico	16
1.1.1. Ecuación de búsqueda y estrategia de selección.....	16
1.1.2. Principales Hallazgos.....	17
1.1.3. Revistas Destacadas	21
1.1.4. Autores más citados (2018-2026).....	23
1.1.5. Síntesis interpretativa.....	24
1.1.6. Tendencias	25
1.1.6.1. Tendencias metodológicas.....	25
1.1.6.1.1. Consolidación de modelos híbridos.....	25
1.1.6.1.2. Explicabilidad de la IA (XAI).....	26
1.1.6.1.3. Optimización mediante minería de datos y selección de características. ..	26
1.1.6.2. Tendencias tecnológicas	26
1.1.6.2.1. Integración con Sistemas de Información Geográfica (SIG).....	26
1.1.6.2.2. Automatización con IA generativa y APIs.	27
1.1.6.2.3. Predicción en tiempo real y visualización dinámica.....	27
1.1.6.3. Tendencias temáticas	27
1.1.6.3.1. Ampliación hacia delitos financieros y cibernéticos.	27
1.1.6.3.2. Predicción en ciudades intermedias	27
1.1.6.3.3. Ética y justicia algorítmica.....	28
1.1.6.4. Tendencias regionales: América Latina.....	28
1.1.6.5. Perspectivas futuras (2025–2030).....	28

1.1.6.6.	Síntesis.....	29
1.2.	Análisis Preliminar de Literatura	29
2.	Planteamiento del Problema	31
3.	Justificación.....	32
3.1.	Pertinencia teórica.....	33
3.2.	Pertinencia práctica.....	33
3.3.	Pertinencia metodológica.....	33
3.4.	Pertinencia social	34
3.5.	Pertinencia disciplinar.....	34
4.	Objetivos.....	34
4.1.	Objetivo General.....	34
4.2.	Objetivos Específicos.....	35
5.	Marco de Referencia.....	36
5.1.	Marco de Antecedentes.....	36
5.2.	Marco Teórico.....	37
5.3.	Enfoques y Herramientas de Machine Learning.....	38
5.4.	Enfoque metodológico del presente proyecto.....	39
6.	Metodología.....	40
6.1.	Recolección y consolidación de datos (Etapa 1).....	40
6.2.	Preprocesamiento de datos (Etapa 2).....	41
6.3.	Análisis exploratorio de datos (Etapa 3).....	43
6.4.	Ingeniería de características (Etapa 4)	44
6.5.	Construcción del target binario y dataset de entrenamiento	46
6.6.	Entrenamiento y evaluación del modelo predictivo (Etapa 5).....	48
6.6.1.	Optimización de hiperparámetros	49
6.6.2.	Calibración de probabilidades.....	50
6.6.3.	Explicabilidad del modelo (XAI).....	50
7.	Resultados.....	52

7.1.	Resultados del análisis exploratorio (EDA).....	52
7.2.	Comparación de modelos.....	56
7.3.	Evaluación del modelo XGBoost.....	58
7.4.	Análisis de explicabilidad mediante SHAP	62
7.4.1.	Importancia global de variables (SHAP)	64
7.4.2.	Distribución del impacto por variable (SHAP beeswarm)	65
7.4.3.	Interpretabilidad individual.....	66
7.5.	Variables más relevantes.....	66
8.	Visualización Geoespacial y Análisis Territorial	68
8.1.	Mapa de puntos por nivel de riesgo	68
8.2.	Mapa de calor estático	69
8.3.	Dashboard interactivo	70
8.4.	Clasificación de barrios por nivel de riesgo.....	71
9.	Conclusiones.....	72
10.	Recomendaciones	74
11.	Limitaciones del estudio	76
12.	Proyecciones y trabajos futuros	77
	Referencias Bibliográficas	79

Lista de Tablas

Tabla 1 Cumplimiento de Objetivos	14
Tabla 2 Ecuación de Búsqueda.	16
Tabla 3 Revistas y Conferencias de Referencia.....	21
Tabla 4 Principales Autores	23
Tabla 5 Comparación de Modelos – Resultados K=5.....	57
Tabla 6 Evaluación del Modelo Escogido	58

Lista de Figuras

Figura 1 Density Visualization 18

Figura 2 Network Visualization..... 19

Figura 3 Overlay Visualization..... 20

Figura 4 Distribución de Hurtos a Personas - Bucaramanga, 2010-2025..... 53

Figura 5 Top 10 Barrios con Mayor Número de Hurtos a Personas (2010-2025)..... 53

Figura 6 Evolución Anual (2010-2025) – Hurto a Personas 54

Figura 7 Mapa de Calor Hurtos Dia-Hora 54

Figura 8 Tasa de hurtos a personas por cada 1.000 habitantes según comuna 55

Figura 9 Comparación de modelos mediante validación cruzada estratificada K=5..... 58

Figura 10 Matriz de Confusión - XGBoost 60

Figura 11 Curva ROC 61

Figura 12 Curva de Calibración - XGBoost 61

Figura 13 Importancia Global de Variables (SHAP)..... 64

Figura 14 Distribución del Impacto por Variable 65

Figura 15 Mapa de Puntos por Nivel de Riesgo Predicho – Captura de Pantalla del html 69

Figura 16 Mapa de Calor Estático Ponderado por Probabilidad – Captura de Pantalla del html 70

Figura 17. Dashboard Interactivo - Vista para Viernes 18:00 h. 71

Figura 18 Conteo de la Clasificación de Barrios según Riesgo..... 72

Lista de Apéndices

Apéndice A: Pipeline computacional completo del modelo predictivo

Apéndice B: Dashboard interactivo de predicción de riesgo por barrio, día y hora

Apéndice C: Mapa de puntos por nivel de riesgo predicho

Apéndice D: Mapa de calor estático ponderado por probabilidad

Apéndice E: Clasificación de barrios por nivel de riesgo — escenario viernes 18:00 h

Apéndice F: Artículo Científico

Los apéndices están adjuntos y pueden visualizarse en la base de datos de la biblioteca UIS.

Resumen

Título: Predicción de la probabilidad de robo en barrios de Bucaramanga mediante Machine Learning*

Autor: Jhonnatan Yesid Bottía Ramírez**

Palabras clave: Aprendizaje Automático, Hurto a Personas, XGBoost, Bucaramanga, Seguridad Ciudadana, Clasificación Binaria.

Descripción:

El presente trabajo desarrolla un sistema predictivo de hurtos a personas en los barrios de Bucaramanga, Colombia, mediante técnicas de aprendizaje automático. A partir de 103.879 registros históricos del SIEDCO de la Policía Nacional para el período 2010–2025, se construyó un modelo de clasificación binaria capaz de estimar la probabilidad de ocurrencia de hurtos para cualquier combinación de barrio, día de la semana y franja horaria.

Se compararon cuatro algoritmos mediante validación cruzada estratificada K=5: regresión logística (78,21%), árbol de decisión (75,33%), Random Forest (77,93%) y XGBoost (82,12%). XGBoost fue seleccionado como modelo final por su mayor desempeño y estabilidad. Los hiperparámetros se optimizaron mediante RandomizedSearchCV con 40 iteraciones y AUC-ROC como métrica objetivo. Sobre un conjunto de prueba independiente el modelo alcanzó accuracy del 82,2%, recall del 84,3%, F1-score de 0,825, AUC-ROC de 0,9066 y Average Precision de 0,89. Las probabilidades fueron calibradas mediante Platt Scaling garantizando que el conjunto de prueba no participara en ninguna etapa del ajuste.

Los resultados se presentan a través de un dashboard interactivo en Leaflet.js que visualiza el riesgo por barrio según día y franja horaria. Los barrios se clasificaron en niveles ALTO, MEDIO y BAJO para el escenario crítico identificado: viernes entre las 17:00 y las 21:00 horas. Se formularon cinco recomendaciones estratégicas para apoyar la asignación eficiente de recursos de seguridad por parte de la Policía Metropolitana y la Alcaldía de Bucaramanga.

* Trabajo de Grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Estudios Industriales y Empresariales

Director: Henry Lamos Diaz. Doctor en Física y Matemáticas

Abstract

Title: Prediction of Robbery Probability in Bucaramanga Neighborhoods Using Machine Learning*

Autor: Jhonnatan Yesid Bottía Ramírez**

Keywords: Machine Learning, Robbery, XGBoost, Bucaramanga, Public Safety, Binary Classification.

Description:

This work develops a predictive system for theft against persons in the neighborhoods of Bucaramanga, Colombia, using machine learning techniques. Based on 103,879 historical records from the Statistical, Criminal, Contraventional and Operational Information System (SIEDCO) of the National Police for the period 2010–2025, a binary classification model was built to estimate the probability of theft occurrence for any combination of neighborhood, day of the week and time slot.

Four algorithms were compared using stratified K=5 cross-validation: logistic regression (78.21%), decision tree (75.33%), Random Forest (77.93%) and XGBoost (82.12%). XGBoost was selected as the final model due to its superior performance and stability. Hyperparameters were optimized using RandomizedSearchCV with 40 iterations and AUC-ROC as the target metric. Evaluated on an independent test set, the model achieved an accuracy of 82.2%, recall of 84.3%, F1-score of 0.825, AUC-ROC of 0.9066 and Average Precision of 0.89. Probabilities were calibrated using Platt Scaling, ensuring the test set did not participate in any adjustment stage.

Results are presented through an interactive dashboard built with Leaflet.js that visualizes theft risk by neighborhood according to day and time slot. Neighborhoods were classified into HIGH, MEDIUM and LOW risk levels for the critical scenario identified: Fridays between 17:00 and 21:00 hours. Five strategic recommendations were formulated to support efficient security resource allocation by the Metropolitan Police and the Mayor's Office of Bucaramanga.

* Degree Work

** Facultad de Ingenierías Fisicomecánicas. Escuela de Estudios Industriales y Empresariales

Director: Henry Lamos Diaz. Doctor en Física y Matemáticas

Introducción

La seguridad ciudadana es una prioridad en las ciudades colombianas, incluyendo Bucaramanga, donde encuestas como la de Percepción Ciudadana del Área Metropolitana de Bucaramanga (AMB) 2024 y el Informe Especial sobre Seguridad y Convivencia 2025 de Bucaramanga Cómo Vamos indican que entre el 60% y el 70% de los habitantes se siente inseguro o muy inseguro. Esto ocurre a pesar de reducciones en indicadores objetivos como los hurtos, que pasaron de 9.378 casos en 2023 a 4.808 en 2024, con una disminución adicional estimada entre el 37% y el 55% en los primeros meses de 2025.

Esta brecha entre cifras oficiales y percepción ciudadana se acentúa en zonas comerciales densas como Centro, La Concordia, El Tejar y Cabecera, donde se concentra una alta incidencia de robos a personas y establecimientos. Esta situación genera una necesidad urgente de implementar métodos innovadores que fortalezcan la prevención y la capacidad de respuesta en áreas de alta densidad poblacional y con limitaciones en servicios públicos.

Actualmente, la asignación de recursos de seguridad se basa principalmente en registros históricos agregados y decisiones administrativas, lo que conduce a respuestas predominantemente reactivas —a través de la línea 123, cuadrantes y planes operativos— y a una cobertura potencialmente desigual en zonas de mayor riesgo. Esto limita la capacidad de anticipación y la focalización preventiva.

Ante este desafío, las herramientas de análisis de datos y la inteligencia artificial ofrecen un alto potencial transformador. Los modelos de aprendizaje automático permiten identificar patrones ocultos en grandes volúmenes de datos criminales y demográficos, facilitando la predicción de la probabilidad de delitos como el hurto con un enfoque espacio-temporal. Este tipo

de enfoques ha demostrado resultados favorables en ciudades como Chicago, Londres y Medellín, mediante el uso de técnicas como bosques aleatorios, redes neuronales y regresión logística.

En este contexto, el presente trabajo desarrolló un sistema predictivo de hurtos a personas para Bucaramanga, integrando datos históricos de criminalidad del SIEDCO con variables demográficas y espaciales del DANE. El objetivo fue proporcionar una herramienta estratégica que apoye la asignación de recursos policiales y permita implementar acciones preventivas más precisas y equitativas.

El proyecto abarcó la recolección y limpieza de datos, su análisis exploratorio, la construcción y validación de modelos predictivos mediante técnicas de aprendizaje automático, así como la identificación de zonas críticas mediante visualizaciones geoespaciales interactivas. Adicionalmente, se formularon recomendaciones para la reasignación de recursos de seguridad con base en los niveles de riesgo estimados, contribuyendo a una gestión más proactiva y eficiente de la seguridad ciudadana en la ciudad.

Tabla de Cumplimiento de Objetivos

La siguiente tabla relaciona cada objetivo específico planteado en el plan de proyecto de grado con el numeral del documento que da cumplimiento a dicho objetivo, conforme al formato establecido por la Escuela de Estudios Industriales y Empresariales de la Universidad Industrial de Santander.

Tabla 1
Cumplimiento de Objetivos

Objetivo específico	Cumplimiento
Recolectar, depurar y estructurar información sociodemográfica y de seguridad a nivel de barrio en Bucaramanga, con el propósito de construir una base de datos adecuada para el análisis.	Capítulo 3, secciones 3.1 y 3.2 (Recolección y preprocesamiento de datos). Apéndice A.
Analizar la información recopilada con el fin de identificar patrones y relaciones asociados a la ocurrencia de robos, mediante la aplicación de técnicas de aprendizaje automático supervisado y no supervisado.	Capítulo 3, sección 3.3 (EDA). Capítulo 4, sección 4.1 (Resultados del análisis exploratorio).
Diseñar, entrenar y validar un modelo predictivo que permita estimar la probabilidad de ocurrencia de robos por barrio.	Capítulo 3, secciones 3.4, 3.5, 3.6, 3.6.1 y 3.6.2 (Ingeniería de características, target binario, entrenamiento, optimización de hiperparámetros y calibración). Apéndice A.
Evaluar el desempeño del modelo propuesto utilizando métricas estadísticas apropiadas, con el	Capítulo 4, secciones 4.2, 4.3 y 4.4 (Comparación de modelos y evaluación XGBoost: accuracy 82,2%, recall 84%,

Objetivo específico	Cumplimiento
fin de determinar su capacidad predictiva y nivel de confiabilidad.	F1-score 0,83, AUC-ROC 0,9069, AP≈0,91; y análisis de explicabilidad SHAP).
Identificar zonas de mayor riesgo delictivo a partir de la visualización espacial de los resultados obtenidos por el modelo.	Capítulo 5, secciones 5.1, 5.2, 5.3 y 5.4 (Mapas y dashboard interactivo). Apéndices B, C, D y E.
Formular lineamientos técnicos basados en los resultados del análisis, orientados a apoyar la asignación de recursos de seguridad desde un enfoque analítico.	Capítulo 6, sección 6.2 (Recomendaciones estratégicas R1 a R5).
Elaborar un artículo científico que sintetice los aportes metodológicos y los resultados del sistema predictivo desarrollado, con el fin de contribuir a la producción académica en el campo de la analítica de seguridad ciudadana.	Apéndice F. Artículo científico en formato IEEE: <i>"Predicción de la Probabilidad de Robo en Barrios de Bucaramanga mediante Machine Learning: Clasificación Binaria con XGBoost y Explicabilidad SHAP."</i>

1. Revisión de la Literatura

1.1. Análisis Bibliométrico

El análisis bibliométrico permitió examinar la evolución, el impacto y la producción científica relacionada con el uso de modelos de Machine Learning (ML) para la predicción de delitos urbanos. Para su desarrollo, se consultaron bases de datos académicas como Scopus, Web of Science y Google Scholar, empleando combinaciones de palabras clave tales como crime prediction, machine learning, urban crime, artificial intelligence, criminal forecasting, spatial crime análisis, robbery prediction, data mining y deep learning.

1.1.1. Ecuación de búsqueda y estrategia de selección

Para el desarrollo del análisis bibliométrico se empleó una estrategia de búsqueda estructurada en las bases de datos Scopus, Web of Science y Google Scholar, las cuales se reconocen por su rigurosidad académica y amplia cobertura en publicaciones científicas internacionales.

El objetivo fue identificar las principales tendencias de investigación sobre la predicción de delitos urbanos mediante Machine Learning, considerando tanto los enfoques teóricos como las aplicaciones prácticas en contextos urbanos y territoriales comparables a Bucaramanga.

La ecuación de búsqueda empleada en Scopus se formuló de la siguiente manera:

Tabla 2

Ecuación de Búsqueda.

Iteración	Ecuación	Resultados
1	TITLE-ABS-KEY ("crime prediction" OR "criminal forecasting" OR "urban crime" OR "robbery prediction") AND ("machine learning" OR "deep learning" OR "artificial intelligence" OR "data mining") AND ("urban" OR	473

Iteración	Ecuación	Resultados
	"city" OR "spatio-temporal" OR "hotspot" OR "GIS") AND PUBYEAR > 2017 AND PUBYEAR < 2027	

Esta ecuación permitió identificar artículos publicados entre 2018 y 2026, con un enfoque en el uso de modelos de aprendizaje automático y técnicas de inteligencia artificial para el análisis y predicción del crimen urbano, integrando variables espacio-temporales, sociodemográficas y geográficas.

Los resultados obtenidos fueron depurados con base en la relevancia temática y la pertinencia metodológica, lo que permitió construir un corpus bibliográfico sólido que sirvió de base para los análisis de coocurrencia de palabras clave, densidad temática y red de colaboración entre autores presentados en las siguientes figuras.

1.1.2. Principales Hallazgos


El análisis bibliométrico realizado permitió identificar una tendencia creciente y consolidada en la investigación sobre el uso de Machine Learning para la predicción de delitos urbanos.

Desde el año 2019 se observa un aumento sostenido en la producción científica relacionada con el tema, alcanzando su punto más alto entre 2022 y 2024, periodo en el que emergen enfoques multidisciplinarios que combinan análisis espacial, minería de datos y modelos predictivos de seguridad ciudadana.

En la **Figura 1 (Density Visualization)** se aprecia una concentración significativa de publicaciones en torno a términos como crime prediction, machine learning, urban safety, spatial analysis y hotspot mapping, lo que evidencia el interés académico por el análisis delictivo en

entornos urbanos y el uso de herramientas predictivas para la gestión de la seguridad. Asimismo, el mapa revela que las investigaciones más citadas se agrupan principalmente en regiones con alta densidad de producción científica, como Estados Unidos, Reino Unido, China y la India, con una presencia creciente de estudios en América Latina, especialmente en Colombia, México y Ecuador.

Figura 1
Density Visualization



Por su parte, la **Figura 2 (Network Visualization)** muestra la red de coocurrencia entre autores y palabras clave, destacando nodos centrales como *random forest*, *deep learning*, *predictive policing* y *spatio-temporal modeling*. Estos términos reflejan la evolución de la temática hacia modelos más complejos y explicables, así como la integración de datos espaciales y temporales en la predicción del crimen.

1.1.3. Revistas Destacadas

El análisis de las fuentes de publicación permitió identificar las principales revistas científicas que concentran la producción académica sobre predicción del crimen mediante Machine Learning, tanto a nivel internacional como regional. Estas revistas se caracterizan por su alto impacto, revisión por pares y enfoque en el cruce entre tecnología, seguridad y análisis urbano. Se relacionan a continuación en la **Tabla 2**.

Tabla 3
Revistas y Conferencias de Referencia

Revista / Fuente	País/Editorial	Enfoque Principal	Relevancia para la Investigación	Referencia representativa
<i>Karbala International Journal of Modern Science</i>	Irak/Elsevier	Modelos predictivos de crimen, análisis comparativo de algoritmos (RF, XGBoost, LSTM)	Meta-análisis global de 50 estudios sobre predicción criminal con IA	Karbala Int. J. Modern Sci. (2025)
<i>IEEE Access</i>	EE. UU. / IEEE	Deep Learning y series temporales aplicadas al análisis de crimen urbano	Modelos LSTM y CNN con alto desempeño predictivo (precisión > 0.85)	Mandalapu et al., 2023
<i>Frontiers in Computer Science</i>	Suiza / Frontiers	Integración de variables socioeconómicas y geográficas con ML	Modelos híbridos para predicción de robos y homicidios urbanos	Vega-Huerta et al., 2024
<i>Computers, Environment and Urban Systems</i>	Países Bajos / Elsevier	Sistemas de Información Geográfica (SIG) y aprendizaje automático	Aplicaciones espaciales para la planificación y gestión del riesgo delictivo	Deng et al., 2023
<i>ISPRS International Journal of Geo-Information</i>	Suiza / MDPI	Modelado espacial, análisis SIG y urban analytics	Uso de información geográfica para detectar patrones	Saraiva et al., 2022

Revista / Fuente	País/Editorial	Enfoque Principal	Relevancia para la Investigación	Referencia representativa
			delictivos urbanos	
<i>Security Journal</i>	Reino Unido / Springer	Análisis empírico de criminalidad y aplicación de modelos predictivos	Fomenta la relación entre teoría criminológica y analítica de datos	Chainey et al., 2008
<i>Journal of Computational Social Science</i>	Suiza / Springer	Inteligencia artificial y comportamiento social urbano	Relaciona la movilidad y la conducta humana con la predicción del crimen	Bogomolov et al., 2014
<i>Revista Facultad de Ingeniería (Univ. de Antioquia)</i>	Colombia	Aplicación de ML en problemas sociales y urbanos	Pionera en Colombia en usar RF para detección de tendencias de homicidio	Ordoñez-Eraso et al., 2020
<i>URVIO. Revista Latinoamericana de Estudios de Seguridad (FLACSO)</i>	Ecuador	Estudios de seguridad y predicción criminal en América Latina	Difunde investigaciones sobre delitos urbanos y políticas de prevención	FLACSO, 2022

Estas revistas conforman el núcleo del corpus bibliográfico que sustenta la presente investigación. Su relevancia radica en que **articulan enfoques técnicos y sociales**, permitiendo comprender el fenómeno delictivo no solo desde la modelación matemática, sino también desde la perspectiva territorial y preventiva.

Además, reflejan una transición epistemológica hacia enfoques más explicables y éticamente responsables en el uso de la inteligencia artificial para la seguridad ciudadana, tendencia clave que fundamenta la pertinencia del proyecto aplicado al contexto de Bucaramanga.

1.1.4. Autores más citados (2018-2026)

El análisis bibliométrico realizado a partir de las bases Scopus, Web of Science y Google Scholar entre 2018 y 2026 permitió identificar a los investigadores más influyentes en el campo de la predicción del crimen mediante Machine Learning. Los autores se agrupan en dos grandes vertientes:

- Aquellos que han consolidado el marco teórico y metodológico internacional en predicción espacio-temporal del crimen.
- Y quienes, desde América Latina, han comenzado a adaptar y aplicar dichos modelos a realidades urbanas y sociales específicas, incluyendo el contexto colombiano.

La **Tabla 4** presenta los autores más citados, sus principales aportes y su pertinencia para la investigación orientada a Bucaramanga.

Tabla 4
Principales Autores

Autor(es)	Año(s) de mayor impacto	País / Región	Aporte principal	Relevancia para el proyecto
Mandalapu, V.; Roy, N.; Elluri, L.; Vyas, P.	2023–2025	EE. UU.	Realizaron una revisión sistemática sobre modelos de ML y Deep Learning para la predicción criminal, identificando tendencias en algoritmos explicables (XAI).	Proveen las bases teóricas para la selección de algoritmos interpretables y aplicables al contexto urbano.
Zhang, X.; Deng, S.	2022–2024	China	Desarrollaron modelos híbridos de Gradient Boosting y XGBoost para análisis espacio-temporal de delitos urbanos.	Referencia clave para mejorar precisión y reducir sobreajuste en el modelo propuesto para Bucaramanga.
López, G.; Manosalva, P.	2024–2025	Ecuador / América Latina	Sistematizaron estudios regionales sobre el uso de ML en seguridad ciudadana, destacando limitaciones de datos en América Latina.	Permite contextualizar el proyecto dentro de la producción científica latinoamericana.

Autor(es)	Año(s) de mayor impacto	País / Región	Aporte principal	Relevancia para el proyecto
Salazar, V.	2020	Colombia	Aplicó Random Forest y regresión logística para estimar reincidencia penal en el sistema judicial colombiano.	Base metodológica para la implementación de modelos predictivos con datos locales.
Franco Galeano, J.	2018	Colombia	Analizó la criminalidad intraurbana en Medellín mediante regresiones espaciales, identificando factores socioeconómicos de violencia.	Fundamenta el análisis territorial y socioeconómico del crimen en Bucaramanga.
Chainey, S.; Ratcliffe, J.	2018–2022	Reino Unido	Pioneros en mapas de puntos calientes (hotspot mapping) y análisis espacial del crimen.	Aporta lineamientos para la integración entre Machine Learning y Sistemas de Información Geográfica (SIG).
Wang, T.	2020–2023	China	Incorporó variables sociodemográficas y de entorno urbano en modelos predictivos de delitos.	Guía para seleccionar variables contextuales relevantes para Bucaramanga.
Bogomolov, A.	2019	Reino Unido	Integró datos de movilidad urbana provenientes de celulares para anticipar delitos con precisión.	Sugiere la utilidad de variables de movilidad y densidad poblacional.
Karbala Int. J. Modern Sci. (Comité Editorial)	2025	Global	Lideró un meta-análisis internacional sobre modelos predictivos del crimen con ML, destacando el rol de RF y XGBoost.	Aporta la visión más reciente sobre desempeño y aplicabilidad de algoritmos en seguridad urbana.

Fuente: Elaboración Propia

1.1.5. Síntesis interpretativa

El periodo 2018–2026 marca una etapa de maduración teórica y metodológica en el uso de Machine Learning para la predicción del crimen.

Los estudios de Mandalapu, Roy y Elluri (2023–2025) establecen los referentes globales sobre explicabilidad y ética en IA aplicada a seguridad, mientras que las investigaciones de López

y Manosalva (2024) y Salazar (2020) representan el esfuerzo latinoamericano por adaptar estos modelos a contextos con limitaciones de datos, desigualdad social y alta variabilidad espacial.

Para el caso de Bucaramanga, la combinación de estas referencias respalda la construcción de un modelo predictivo explicable, fundamentado en algoritmos robustos (Random Forest, XGBoost) y variables geográficas, temporales y sociodemográficas, coherentes con las tendencias internacionales y las necesidades locales.

1.1.6. Tendencias

Entre los años 2018 y 2026, la investigación sobre la predicción del crimen urbano mediante Machine Learning (ML) e inteligencia artificial (IA) ha mostrado una expansión sostenida en cuatro dimensiones interrelacionadas: metodológica, tecnológica, temática y regional. Estas tendencias reflejan una evolución del enfoque estadístico tradicional hacia un modelo integral de analítica urbana, que combina precisión algorítmica, explicabilidad y responsabilidad social.

1.1.6.1. Tendencias metodológicas.

1.1.6.1.1. Consolidación de modelos híbridos. La literatura reciente evidencia una transición hacia arquitecturas híbridas que combinan algoritmos clásicos con redes neuronales profundas. Los modelos Random Forest + LSTM y XGBoost + ARIMA han demostrado alta capacidad para capturar patrones espacio-temporales de delitos, especialmente en contextos urbanos dinámicos (Huamantingo et al., 2025; Mandalapu et al., 2023).

Asimismo, los modelos autorregresivos mejoran la sensibilidad ante variaciones semanales y estacionales en la incidencia delictiva.

1.1.6.1.2. *Explicabilidad de la IA (XAI).* Desde 2023, la transparencia y trazabilidad de los modelos se convirtieron en criterios esenciales para la investigación aplicada en seguridad ciudadana.

Herramientas como SHAP, LIME y Permutation Importance permiten identificar las variables más influyentes, garantizando que las decisiones predictivas sean comprensibles para actores públicos.

Investigaciones como las de ARPI (2023) y Nature (2025) destacan que la explicabilidad no es solo un valor técnico, sino un requisito ético frente a los posibles sesgos y desigualdades algorítmicas.

1.1.6.1.3. *Optimización mediante minería de datos y selección de características.* Los estudios actuales priorizan la depuración de variables explicativas, destacando las relacionadas con tiempo, edad, educación, clima y coordenadas geográficas (WJARR, 2025).

Se observa también un auge del web scraping y de los data lakes urbanos, que integran información proveniente de redes sociales, sensores y registros administrativos, facilitando la construcción de bases de datos predictivas más completas.

1.1.6.2. Tendencias tecnológicas

1.1.6.2.1. *Integración con Sistemas de Información Geográfica (SIG).* La sinergia entre ML y SIG constituye una de las mayores innovaciones recientes. Los modelos acoplados a sistemas geospaciales permiten visualizar patrones delictivos en tiempo real y optimizar los recursos policiales.

En ciudades intermedias como Bucaramanga (Colombia) o Alvorada (Brasil), esta integración se utiliza para identificar zonas calientes y vulnerabilidades territoriales.

1.1.6.2.2. Automatización con IA generativa y APIs. Universidades y gobiernos latinoamericanos (Perú, Brasil) han comenzado a utilizar APIs de IA generativa —como GPT o Claude— para procesar información proveniente de redes sociales, noticias y registros públicos, alimentando sus modelos predictivos de manera automatizada.

1.1.6.2.3. Predicción en tiempo real y visualización dinámica. Los dashboards y plataformas interactivas están reemplazando los reportes estáticos, favoreciendo la toma de decisiones instantánea.

Empresas como Axon y proyectos como PredPol lideran este cambio hacia la vigilancia predictiva basada en flujos de datos urbanos continuos.

1.1.6.3. Tendencias temáticas

1.1.6.3.1. Ampliación hacia delitos financieros y cibernéticos. Paralelamente al crimen urbano, la IA se aplica a la detección de fraudes, lavado de activos y delitos informáticos (AML/FinCrime), integrando tecnologías como blockchain para garantizar trazabilidad y transparencia.

1.1.6.3.2. Predicción en ciudades intermedias. Desde 2022, los estudios han migrado del enfoque en megaciudades hacia urbes medianas con limitaciones de datos —como Ambato, Alvorada y Bucaramanga—, donde se evalúa la transferibilidad de los modelos globales al contexto local (FLACSO, 2022; UNAD, 2025).

1.1.6.3.3. Ética y justicia algorítmica. Los informes de Fair Trials (2024) y IEEE Access (2025) advierten sobre el riesgo de reproducir sesgos institucionales.

La nueva línea de investigación sobre IA responsable propone marcos de auditoría y principios éticos aplicados a la seguridad pública.

1.1.6.4.Tendencias regionales: América Latina. En América Latina, la adopción de sistemas predictivos ha avanzado de manera paulatina pero sostenida:

Colombia, Brasil, Perú y Ecuador lideran la implementación de laboratorios de analítica criminal y modelos predictivos a escala urbana.

En Perú, Huamantingo et al. (2025) desarrollaron un sistema ML estandarizado para agencias policiales; mientras que en Brasil, Ortiz et al. (2025) aplicaron web scraping e IA para el monitoreo automatizado de delitos.

En Colombia, el modelo PRiSMA (Fiscalía General, 2024) predice reincidencia penal, y estudios recientes sugieren que ciudades como Bucaramanga tienen condiciones favorables para modelos basados en Random Forest con variables socioespaciales.

1.1.6.5.Perspectivas futuras (2025–2030). Las proyecciones indican que el campo avanzará hacia una criminología computacional interdisciplinaria, donde confluyen la sociología, el urbanismo y la inteligencia artificial. Se anticipan tres grandes líneas de desarrollo:

Gemelos digitales urbanos: simulación virtual de escenarios de inseguridad para planificar intervenciones preventivas.

Modelos federados y privacidad diferencial: entrenamiento descentralizado para preservar la confidencialidad de datos ciudadanos.

Predicción preventiva y decisiones explicables: sustitución del uso punitivo de la IA por herramientas de prevención ciudadana basadas en evidencia y transparencia.

1.1.6.6. Síntesis. Las tendencias entre 2019 y 2025 confirman la madurez del campo hacia modelos predictivos éticos, explicables y geoespacialmente contextualizados.

Para Bucaramanga, esto implica desarrollar modelos RF–XGBoost integrados con SIG y datos ambientales, acompañados de herramientas de interpretabilidad (SHAP) y evaluación social, contribuyendo a una visión preventiva y transparente de la seguridad urbana.

1.2. Análisis Preliminar de Literatura

La literatura reciente sobre la predicción del crimen urbano mediante Machine Learning (ML) refleja un campo en consolidación, que combina análisis espacial, minería de datos y modelado predictivo para anticipar comportamientos delictivos. A nivel global, los avances se han centrado en tres líneas principales: la predicción espacio-temporal del delito, la integración con Sistemas de Información Geográfica (SIG) y la explicabilidad algorítmica aplicada a la seguridad pública.

En los países desarrollados, autores como Mohler et al. (2011) sentaron las bases de los modelos de predicción criminal al utilizar procesos de punto Hawkes para anticipar delitos en Los Ángeles, demostrando que la recurrencia de eventos delictivos obedece a patrones espacio-temporales. De manera complementaria, Bogomolov et al. (2014) incorporaron datos de movilidad urbana —provenientes de teléfonos móviles— para predecir delitos en Londres, mostrando que las variables de comportamiento social y desplazamiento son tan determinantes como las estadísticas policiales tradicionales.

Posteriormente, Wang et al. (2020) aplicaron algoritmos de clasificación (Random Forest y SVM) a datos sociodemográficos de ciudades chinas, obteniendo modelos con alta capacidad predictiva (precisión superior al 85%). Estos estudios demostraron que variables como el nivel de desempleo, la densidad poblacional y el estrato socioeconómico explican de forma significativa la distribución espacial del delito. De igual forma, Chainey y Ratcliffe (2005) zexploraron la eficacia de los mapas de puntos calientes (hotspots) combinados con algoritmos predictivos, evidenciando su utilidad para la planificación policial y la priorización de patrullajes.

Más recientemente, Mandalapu et al. (2023) y Zhang et al. (2022) desarrollaron modelos híbridos LSTM–XGBoost que incorporan variables espacio-temporales para detectar variaciones dinámicas en la incidencia delictiva. Estos enfoques han alcanzado precisiones cercanas al 90%, lo que marca un hito en la predicción de delitos a corto plazo. Además, investigaciones de Lopez y Manosalva (2024) y Vega-Huerta et al. (2024) adaptaron estos modelos al contexto latinoamericano, integrando información geográfica, sociodemográfica y ambiental, con desempeños satisfactorios y enfoques éticos orientados a la prevención.

En el contexto colombiano, los aportes son más recientes y dispersos, pero relevantes. Ordoñez-Eraso et al. (2020) aplicaron técnicas de aprendizaje automático para detectar tendencias de homicidios entre 1960 y 2019, demostrando la utilidad del ML para comprender fenómenos de violencia a nivel territorial. Asimismo, la Fiscalía General de la Nación (2024) implementó el modelo PRiSMA, que utiliza ML para predecir reincidencia criminal, marcando el inicio de la aplicación práctica de IA en el sistema judicial.

En el ámbito local, Betancourt y Camargo (2025) desarrollaron un modelo de agrupamiento (K-Means) para identificar zonas de concentración delictiva en Bucaramanga, validando

empíricamente los patrones espaciales mediante el índice de silueta. Aunque sus resultados no incorporaron predicción temporal, demostraron la existencia de zonas calientes persistentes relacionadas con la densidad poblacional y el uso del suelo.

La revisión de la literatura evidencia que, aunque existen avances significativos, persisten brechas metodológicas y contextuales en América Latina: los estudios tienden a concentrarse en grandes metrópolis, los datos son heterogéneos o desactualizados y aún hay una débil incorporación de variables ambientales y sociales. De igual forma, la mayoría de los modelos carecen de mecanismos de explicabilidad (XAI), lo cual limita su adopción institucional.

Por tanto, el presente proyecto propone adaptar, validar y contextualizar las metodologías internacionales de predicción del crimen mediante ML al caso de Bucaramanga, priorizando el análisis de robos a personas. Se busca desarrollar un modelo predictivo robusto —basado en Random Forest y XGBoost— que incorpore variables geográficas, temporales, socioeconómicas y de movilidad, con criterios de explicabilidad y pertinencia local. Esta aproximación no solo fortalece la base científica nacional, sino que ofrece una herramienta potencial para la gestión preventiva de la seguridad ciudadana, alineada con los principios de transparencia, ética y política pública basada en evidencia.

2. Planteamiento del Problema

La ciudad de Bucaramanga, al igual que muchas urbes latinoamericanas, enfrenta retos significativos en materia de seguridad ciudadana. Uno de los delitos que más preocupación genera entre los habitantes es el hurto a personas, modalidad que concentra la mayor frecuencia de registros en el SIEDCO y que afecta directamente la percepción de inseguridad en el espacio público. A pesar de los esfuerzos institucionales por mejorar la vigilancia y la prevención, la

distribución actual de recursos de seguridad, como los Comandos de Atención Inmediata (CAI), no siempre responde a patrones objetivos de riesgo, sino a criterios operativos y presupuestales tradicionales.

Esta carencia de enfoque predictivo limita la capacidad de las autoridades para anticiparse a los delitos, lo que redundo en tiempos de respuesta poco efectivos, subutilización de recursos y percepción de inseguridad por parte de la ciudadanía. En este contexto, la aplicación de tecnologías de análisis de datos, y en particular de algoritmos de Machine Learning, se presenta como una oportunidad innovadora para comprender patrones de comportamiento delictivo y anticipar eventos criminales en función de variables sociodemográficas, temporales y espaciales.

Aunque existen antecedentes internacionales sobre el uso de modelos predictivos para la prevención del crimen (Mohler et al., 2011; Wang et al., 2020), su implementación en ciudades colombianas sigue siendo incipiente. Hasta el inicio del presente trabajo, Bucaramanga carecía de un modelo que integrara datos históricos de delitos, características sociales de los barrios y otros factores relevantes para estimar la probabilidad de ocurrencia de hurtos a personas en una zona determinada.

3. Justificación

El desarrollo de un sistema predictivo de hurtos a personas para Bucaramanga se justifica desde múltiples dimensiones que articulan la relevancia científica del enfoque con su impacto directo en la gestión de la seguridad ciudadana. La integración de técnicas de aprendizaje automático con datos históricos del SIEDCO y variables socioeconómicas del DANE responde a una necesidad concreta de las autoridades locales: superar el modelo reactivo de asignación de

recursos policiales y avanzar hacia una gestión preventiva basada en evidencia. A continuación se desarrollan las pertinencias que fundamentan esta iniciativa.

3.1. Pertinencia teórica

Este proyecto aportó a la teoría del crimen desde una perspectiva computacional, al desarrollar un modelo predictivo basado en inteligencia artificial que integra campos como el análisis espacial del delito, la ciencia de datos y la criminología urbana. La aplicación de la Teoría de las Actividades Rutinarias de Cohen y Felson (1979) como marco explicativo de los patrones espacio-temporales identificados genera nuevas formas de representación y comprensión de la inseguridad en ciudades intermedias colombianas.

3.2. Pertinencia práctica

El modelo desarrollado puede ser utilizado por autoridades locales para priorizar zonas de intervención, ubicar estratégicamente recursos policiales y diseñar campañas preventivas. El dashboard interactivo y la clasificación de barrios por nivel de riesgo constituyen productos directamente operativos para la Policía Metropolitana y la Alcaldía de Bucaramanga, contribuyendo a una gestión más eficiente y focalizada de la seguridad ciudadana.

3.3. Pertinencia metodológica

El trabajo presenta valor metodológico al implementar un enfoque de predicción delictiva mediante Machine Learning reproducible y adaptable a otras ciudades con condiciones similares. El uso exclusivo de fuentes de datos públicas (SIEDCO y DANE), la construcción de un pipeline computacional documentado en un notebook de acceso abierto, y la optimización sistemática de

hiperparámetros mediante `RandomizedSearchCV` garantizan la posibilidad de réplica y mejora continua del modelo.

3.4. Pertinencia social

La reducción del crimen tiene un impacto directo en la calidad de vida de las personas. Un sistema predictivo bien estructurado permite disminuir los niveles de impunidad, fortalecer la confianza ciudadana en las instituciones y contribuir al desarrollo de comunidades más seguras. El análisis de explicabilidad mediante SHAP garantiza además que las predicciones sean interpretables y no reproduzcan sesgos institucionales, alineándose con los principios de IA responsable.

3.5. Pertinencia disciplinar

Para la Ingeniería Industrial, este proyecto se alinea con la gestión eficiente de recursos, el análisis de sistemas urbanos complejos y la toma de decisiones basadas en datos. El enfoque integra herramientas de optimización, análisis estadístico y visualización geoespacial — competencias centrales de la disciplina — en la solución de un problema social de alta relevancia para Bucaramanga.

4. Objetivos

4.1. Objetivo General

Desarrollar y evaluar un modelo de aprendizaje automático que permita estimar la probabilidad de ocurrencia de hurtos a personas en los barrios de Bucaramanga, a partir del análisis de variables sociodemográficas y de seguridad, con el fin de generar información analítica que apoye la toma de decisiones en materia de seguridad ciudadana.

4.2. Objetivos Específicos

- Recolectar, depurar y estructurar información sociodemográfica y de seguridad a nivel de barrio en Bucaramanga, con el propósito de construir una base de datos adecuada para el análisis.
- Analizar la información recopilada con el fin de identificar patrones y relaciones asociados a la ocurrencia de hurtos a personas, mediante la aplicación de técnicas de aprendizaje automático supervisado.
- Diseñar, entrenar y validar un modelo predictivo que permita estimar la probabilidad de ocurrencia de hurtos a personas por barrio.
- Evaluar el desempeño del modelo propuesto utilizando métricas estadísticas apropiadas, con el fin de determinar su capacidad predictiva y nivel de confiabilidad.
- Identificar zonas de mayor riesgo delictivo a partir de la visualización espacial de los resultados obtenidos por el modelo.
- Formular lineamientos técnicos basados en los resultados del análisis, orientados a apoyar la asignación de recursos de seguridad desde un enfoque analítico.
- Elaborar un artículo científico que sintetice los aportes metodológicos y los resultados del sistema predictivo desarrollado, con el fin de contribuir a la producción académica en el campo de la analítica de seguridad ciudadana.

5. Marco de Referencia

5.1. Marco de Antecedentes

En Colombia, el análisis espacial de la criminalidad ha sido objeto de estudio en diversas investigaciones. Franco Galeano (2018) realizó un análisis espacial de la criminalidad a nivel intraurbano en Medellín, utilizando modelos de regresión con dependencia espacial para identificar factores determinantes de la violencia homicida. Este estudio resalta la importancia de considerar la dimensión espacial en el análisis de fenómenos delictivos y proporciona una base metodológica para investigaciones similares en ciudades colombianas intermedias.

En el ámbito nacional, el Departamento Nacional de Planeación (DNP, 2021) desarrolló un modelo predictivo de delitos para Bucaramanga en el marco del proyecto Big Data del gobierno colombiano, demostrando la viabilidad técnica de aplicar analítica de datos a la seguridad ciudadana con fuentes del SIEDCO. Este antecedente es especialmente relevante para el presente trabajo, ya que opera sobre la misma ciudad y la misma fuente de datos, aunque el DNP no publicó el código ni el pipeline metodológico completo, limitando su reproducibilidad.

En el ámbito local más reciente, Betancourt y Camargo (2025) desarrollaron un modelo de agrupamiento mediante K-Means para identificar zonas de concentración delictiva en Bucaramanga, validando empíricamente los patrones espaciales mediante el índice de silueta. Aunque sus resultados no incorporaron predicción temporal ni probabilidades de ocurrencia, demostraron la existencia de zonas calientes persistentes relacionadas con la densidad poblacional y el uso del suelo, confirmando la pertinencia del análisis territorial en esta ciudad.

Estos antecedentes evidencian la pertinencia de aplicar técnicas de análisis espacial y modelos predictivos en el estudio de la criminalidad urbana en Colombia. El presente proyecto

avanza sobre estos trabajos al integrar variables temporales, socioeconómicas y geoespaciales en un modelo de clasificación supervisada con explicabilidad algorítmica, adaptado específicamente al contexto de Bucaramanga.

5.2. Marco Teórico

El estudio del crimen desde la perspectiva del análisis de datos ha evolucionado gracias al avance de la inteligencia artificial, particularmente del aprendizaje automático, que permite identificar patrones complejos y realizar predicciones a partir de grandes volúmenes de información. Este proyecto se fundamenta en dos cuerpos teóricos complementarios: la criminología ambiental como marco explicativo del fenómeno delictivo, y el aprendizaje automático supervisado como marco metodológico para su modelación.

Uno de los enfoques fundamentales en la explicación del crimen urbano es la Teoría de las Actividades Rutinarias propuesta por Cohen y Felson (1979), que plantea que un delito ocurre cuando convergen en el tiempo y el espacio tres elementos: un delincuente motivado, una víctima adecuada y la ausencia de guardianes eficaces. Esta teoría subraya la importancia del entorno urbano y la dinámica territorial en la ocurrencia del delito, estableciendo una base conceptual para el análisis espacio-temporal del crimen. Los patrones identificados en el análisis exploratorio del presente trabajo — mayor concentración de hurtos en franjas horarias de alta actividad y en zonas comerciales densas — son coherentes con los postulados de esta teoría.

Desde el punto de vista del análisis cuantitativo, el uso de Sistemas de Información Geográfica (SIG) permite representar y analizar la distribución delictiva en el territorio. Herramientas como la Kernel Density Estimation (KDE) han sido ampliamente utilizadas para identificar zonas calientes del crimen (Chainey y Ratcliffe, 2005), ofreciendo una base para

focalizar acciones preventivas. En el presente trabajo, esta aproximación geoespacial se materializa en los mapas de calor y el dashboard interactivo desarrollados en la sección 8 (Visualización geoespacial y análisis territorial)

5.3. Enfoques y Herramientas de Machine Learning

En el campo del aprendizaje automático, se han desarrollado múltiples técnicas para predecir eventos criminales. Los modelos de clasificación supervisada son los más utilizados cuando la variable objetivo es binaria, como en el caso de la ocurrencia o no de un hurto. Entre estos se destacan la regresión logística como modelo de referencia lineal, los árboles de decisión y Random Forest que permiten capturar relaciones no lineales, y XGBoost, un algoritmo de gradient boosting que ha demostrado el mayor desempeño en tareas de clasificación sobre datos tabulares con variables espacio-temporales (Mandalapu et al., 2023)

XGBoost (Extreme Gradient Boosting) construye una secuencia de árboles de decisión de manera iterativa, donde cada árbol nuevo se entrena para corregir los errores residuales del árbol anterior. A diferencia de Random Forest — donde los árboles se construyen de forma independiente y en paralelo — XGBoost reduce el sesgo del modelo de manera secuencial mediante descenso por gradiente sobre una función de pérdida diferenciable, lo que le permite capturar relaciones no lineales complejas entre las variables predictoras y la variable objetivo. Entre sus características técnicas más relevantes se destacan la regularización L1 y L2 para controlar el sobreajuste, el submuestreo aleatorio de observaciones y variables por árbol (subsample y colsample_bytree), y la poda de ramas mediante el parámetro gamma. En el presente trabajo, los hiperparámetros del modelo fueron optimizados mediante RandomizedSearchCV con

40 iteraciones y validación cruzada estratificada $K=5$, garantizando una configuración sistemática en lugar de depender de valores por defecto (Huamantingo et al., 2025).

Más allá de los algoritmos de clasificación, investigaciones recientes han explorado enfoques complementarios. Saraiva et al. (2022) integraron variables censales, redes sociales, mapas viales y reportes policiales para entrenar modelos de Random Forest y árboles de decisión, logrando identificar con mayor precisión zonas críticas de criminalidad. He y Zheng (2021) utilizaron redes generativas para predecir la distribución espacial del crimen incorporando variables de diseño urbano. Estos enfoques evidencian la riqueza metodológica del campo y la relevancia de incorporar múltiples fuentes de datos.

Para el presente estudio se seleccionaron exclusivamente métodos de clasificación supervisada, dado que el problema consiste en predecir la ocurrencia de un evento binario para combinaciones conocidas de barrio, hora y día. Los métodos no supervisados como K-Means y los modelos generativos no son aplicables a este tipo de formulación. Los cuatro algoritmos comparados fueron Regresión Logística, Árbol de Decisión, Random Forest y XGBoost.

5.4. Enfoque metodológico del presente proyecto

Este proyecto adoptó un enfoque cuantitativo-explicativo basado en aprendizaje automático supervisado, comparando cuatro algoritmos de clasificación mediante validación cruzada estratificada $K=5$. El modelo final seleccionado fue XGBoost con hiperparámetros optimizados mediante RandomizedSearchCV (40 iteraciones, métrica AUC-ROC), superando en desempeño a los demás algoritmos con un accuracy del 82,2% y un AUC-ROC de 0,9069 sobre el conjunto de prueba independiente.

Las probabilidades del modelo fueron calibradas mediante Platt Scaling sobre un conjunto de validación independiente, y se implementó el marco SHAP para garantizar la explicabilidad de las predicciones. Los resultados se representaron geográficamente mediante un mapa de puntos, un mapa de calor estático y un dashboard interactivo desarrollado con Leaflet.js, productos descritos en detalle en la sección 8 del presente documento.

6. Metodología

La presente sección describe el proceso metodológico implementado para el desarrollo del sistema predictivo de hurtos a personas en la ciudad de Bucaramanga. El enfoque adoptado es de carácter cuantitativo-explicativo, basado en técnicas de aprendizaje automático supervisado y análisis geoespacial, orientado a la identificación de patrones espacio-temporales del delito y su modelación predictiva.

El desarrollo se llevó a cabo en el entorno de programación Google Colab, utilizando Python como lenguaje principal, y siguiendo una estructura secuencial por etapas que garantiza la trazabilidad y reproducibilidad del análisis.

6.1. Recolección y consolidación de datos (Etapa 1)

La base de datos del modelo se construyó a partir de dos fuentes del Sistema de Información Estadístico, Delincuencial, Contravencional y Operativo (SIEDCO) de la Policía Nacional de Colombia:

- Base1 (2016-2025): 120.940 registros con variables de hora exacta, edad de la víctima, clase de sitio y clasificación por comunas.

- Base2 (2010-2021): 135.076 registros con variables de barrio, coordenadas geográficas, género y curso de vida de la víctima.

De ambas fuentes se filtraron únicamente los registros clasificados bajo la conducta ARTÍCULO 239. HURTO A PERSONAS, excluyendo hurtos a automotores, motocicletas, residencias y entidades comerciales, dado que el objetivo del proyecto se centra específicamente en la predicción de hurtos dirigidos a personas. Tras el proceso de depuración y consolidación, la base final contiene 103.879 registros de hurtos a personas georeferenciados para el período 2010-2025.

Adicionalmente, se incorporaron variables sociodemográficas provenientes del Departamento Administrativo Nacional de Estadística (DANE), incluyendo población por barrio y clasificación por comuna. Los datos fueron almacenados en Google Drive y en un repositorio público de GitHub, con el fin de garantizar la reproducibilidad del análisis.

6.2. Preprocesamiento de datos (Etapa 2)

El preprocesamiento de datos constituyó una etapa crítica del proyecto debido a las inconsistencias estructurales y semánticas identificadas entre las fuentes de información utilizadas. En particular, el Sistema de Información Estadístico, Delincuencial, Contravencional y Operativo (SIEDCO) y las bases del Departamento Administrativo Nacional de Estadística (DANE) presentan diferencias en la nomenclatura de los barrios, lo cual dificultaba su integración directa.

Para resolver esta problemática, se llevó a cabo un proceso de estandarización mediante la construcción de un diccionario de correspondencias elaborado manualmente, posterior a la auditoría de 102 barrios sin coincidencia directa entre ambas fuentes. Este procedimiento permitió

alcanzar una cobertura del 98,1% de los registros originales, garantizando una adecuada integración de la información territorial.

En relación con las variables geográficas, se identificaron dos problemas principales: (i) el uso de coma como separador decimal en las coordenadas, y (ii) la presencia de registros con ubicaciones inconsistentes respecto al barrio reportado. El primer inconveniente fue corregido mediante la normalización del formato numérico de las coordenadas, mientras que el segundo fue abordado a través de un proceso de depuración espacial.

Específicamente, los registros con inconsistencias geográficas fueron ajustados a una ubicación representativa dentro del barrio correspondiente, definida a partir de una estimación visual basada en herramientas cartográficas como Google Maps y LUPAP (plataforma cartográfica de Bucaramanga). Este procedimiento no corresponde a un cálculo geométrico formal del centroide, sino a una aproximación espacial orientada a garantizar la coherencia entre el evento y su unidad territorial. Dado que el modelo opera a nivel agregado por barrio, esta simplificación no compromete la validez del análisis, aunque se reconoce como una limitación en términos de precisión geográfica.

Adicionalmente, se realizaron procesos de limpieza y transformación de datos, incluyendo la eliminación de registros duplicados e incompletos, la estandarización de variables temporales entre las distintas fuentes, y la codificación de variables categóricas mediante técnicas de one-hot encoding. Finalmente, las bases de datos fueron integradas mediante uniones tipo inner join, conservando únicamente aquellos registros con correspondencia en ambas fuentes, con el fin de asegurar la consistencia y calidad de la información utilizada en el modelado.

6.3. Análisis exploratorio de datos (Etapa 3)

El análisis exploratorio de datos (EDA) tuvo como objetivo comprender la distribución temporal y espacial de los hurtos a personas, identificar patrones relevantes y validar la calidad de los datos antes del proceso de modelado. Esta etapa permitió orientar la construcción de variables y la formulación del modelo predictivo.

En términos temporales, se identificó que la ocurrencia de hurtos presenta una distribución no uniforme a lo largo del día. En particular, se observan mayores niveles de actividad delictiva entre las 10:00 y las 22:00 horas, con picos marcados en las franjas de la tarde-noche (17:00 a 21:00), lo cual sugiere una relación con los periodos de mayor flujo de personas y actividad urbana.

A nivel semanal, los días viernes y sábado concentran la mayor frecuencia de hurtos a personas, lo que puede asociarse a dinámicas sociales y económicas propias del fin de semana, como el aumento de actividades comerciales y recreativas.

El análisis de la evolución anual para el período 2010–2025 evidencia un crecimiento sostenido en el número de registros hasta el año 2019, seguido de una disminución significativa en 2020, atribuible a las restricciones de movilidad durante la pandemia, y una posterior recuperación en los años siguientes.

En el ámbito espacial, los barrios Centro, Cabecera del Llano y La Concordia presentan históricamente la mayor concentración de eventos, lo cual se relaciona con su alta densidad comercial y tránsito peatonal.

Adicionalmente, se calcularon tasas de hurtos por cada 1.000 habitantes a nivel de comuna, con el fin de ajustar el análisis por tamaño poblacional y permitir comparaciones más adecuadas del riesgo relativo entre territorios.

Finalmente, la construcción de mapas de calor en función de la hora del día y el día de la semana permitió identificar patrones de riesgo concentrado, evidenciando que la combinación de viernes en horario de 18:00 a 21:00 representa el escenario de mayor probabilidad de ocurrencia de hurtos a personas.

6.4. Ingeniería de características (Etapa 4)

La etapa de ingeniería de características tuvo como propósito transformar y enriquecer las variables originales con el fin de mejorar la capacidad predictiva del modelo, incorporando información relevante sobre la dimensión temporal, espacial y socioeconómica de los eventos analizados.

A partir de los hallazgos del análisis exploratorio, se diseñaron variables derivadas orientadas a capturar patrones recurrentes en la ocurrencia de hurtos a personas. En particular, se construyeron variables temporales que permiten modelar la periodicidad del fenómeno, tales como el día de la semana, la estacionalidad mensual y la segmentación del día en franjas horarias. Estas incluyen:

- DIA_SEMANA_NUM, que representa el día de la semana en formato numérico (0 = lunes, 6 = domingo), facilitando su uso en modelos de aprendizaje automático.
- ES_FIN_DE_SEMANA, variable binaria que identifica si el evento ocurre en sábado o domingo, permitiendo capturar comportamientos diferenciados asociados a fines de semana.

- ES_HORA_PICO, variable binaria que agrupa franjas horarias de alta actividad urbana (7:00–9:59, 12:00–13:59 y 17:00–20:59), en línea con los patrones identificados en el análisis exploratorio.
- MOMENTO_DIA, categorización del día en Mañana, Tarde, Noche y Madrugada, que permite una representación más interpretable de la temporalidad.
- MES, que incorpora posibles efectos estacionales en la ocurrencia del delito.

Las variables socioeconómicas asociadas al estrato (ESTRATO_PROMEDIO, ESTRATO_MIN y ESTRATO_MAX) fueron construidas a partir de la información oficial contenida en el Mapa de Estratificación de los Predios Urbanos del Municipio de Bucaramanga, elaborado por la Alcaldía de Bucaramanga a través de la Oficina Asesora de Planeación y con base en información del Instituto Geográfico Agustín Codazzi (IGAC), con fecha del 26 de agosto de 2009.

La asignación de estos valores se realizó mediante la revisión de la ubicación de cada barrio en dicho mapa, identificando los niveles de estratificación predominantes en su área. A partir de esta información, se definieron medidas resumen (mínimo, máximo y promedio) con el fin de capturar la heterogeneidad socioeconómica al interior de cada unidad territorial.

A nivel territorial, se incluyó la variable NUM_COM, correspondiente al número de la comuna, como una aproximación a la localización geográfica dentro de la ciudad. Esta variable actúa como un proxy espacial que permite al modelo diferenciar zonas con características urbanas similares.

Adicionalmente, se construyó la variable `HURTOS_HIST_NORM`, definida como el conteo normalizado de hurtos a personas históricamente registrados para cada combinación de barrio, día de la semana y hora. Esta variable permite capturar el perfil de riesgo histórico del territorio, incorporando información contextual relevante para la predicción.

Con el fin de evitar problemas de fuga de información (data leakage), esta variable fue calculada exclusivamente a partir del conjunto de entrenamiento, sin utilizar información del conjunto de prueba. De esta manera, se garantiza que el modelo no incorpore conocimiento futuro en el proceso de aprendizaje.

En conjunto, estas variables permiten representar de manera estructurada los factores temporales, espaciales y socioeconómicos asociados a la ocurrencia de hurtos, contribuyendo a mejorar el desempeño y la capacidad explicativa del modelo predictivo.

6.5. Construcción del target binario y dataset de entrenamiento

La variable objetivo del modelo se definió como binaria, tomando valor 1 cuando se registra al menos un hurto a personas en una combinación específica de barrio, fecha y hora, y valor 0 en ausencia de eventos. Esta formulación permite abordar el problema como una tarea de clasificación supervisada orientada a la predicción de ocurrencia delictiva.

Dado que la información disponible corresponde únicamente a eventos registrados (clase positiva), la construcción de casos negativos (ausencia de hurto) representó un desafío metodológico. Generar el espacio completo de combinaciones posibles entre barrios, horas y fechas implicaría un volumen de datos de gran magnitud, superando las capacidades de procesamiento del entorno de trabajo.

En consecuencia, se optó por una estrategia de muestreo controlado para la generación de la clase negativa. Específicamente, se crearon combinaciones aleatorias de barrio, fecha y hora, verificando en cada caso que no existiera un registro de hurto en la base del SIEDCO para dicha combinación. Este procedimiento garantiza que los casos negativos correspondan efectivamente a escenarios sin eventos reportados, evitando inconsistencias en la variable objetivo.

El dataset final se construyó de manera balanceada, con una proporción 1:1 entre clases, resultando en un total de 207.758 observaciones: 103.879 casos positivos (eventos reales) y 103.879 casos negativos generados mediante el proceso descrito. Este balance permite mitigar el sesgo hacia la clase mayoritaria y facilita el aprendizaje del modelo, evitando que este tienda a predecir únicamente la clase dominante.

Es importante señalar que la generación de casos negativos mediante muestreo aleatorio constituye una aproximación común en problemas donde solo se dispone de eventos observados. No obstante, esta estrategia puede introducir un sesgo de selección, en la medida en que algunos casos generados como negativos podrían corresponder a eventos no denunciados (subregistro). Esta limitación es coherente con la naturaleza de los datos y se reconoce explícitamente en la sección 11 de limitaciones del estudio.

Finalmente, la división del dataset se realizó en un 75% para entrenamiento y un 25% para prueba, utilizando un muestreo estratificado sobre la variable objetivo, con el fin de preservar la proporción balanceada de clases en ambos subconjuntos. Esta separación garantiza una evaluación objetiva del desempeño del modelo sobre datos no observados durante el entrenamiento.

6.6. Entrenamiento y evaluación del modelo predictivo (Etapa 5)

El entrenamiento del modelo se llevó a cabo mediante la comparación de cuatro algoritmos de clasificación supervisada, con el objetivo de identificar la técnica con mejor desempeño en la predicción de la ocurrencia de hurtos a personas. Los algoritmos evaluados fueron los siguientes:

- Regresión Logística, empleada como modelo base lineal para establecer una referencia de desempeño (baseline paramétrico).
- Árbol de Decisión, que permite capturar relaciones no lineales mediante particiones del espacio de características.
- Random Forest, un modelo de ensamble basado en múltiples árboles que reduce la varianza y mejora la capacidad de generalización.
- XGBoost, algoritmo de gradient boosting que optimiza secuencialmente los errores del modelo, reconocido por su alto desempeño en problemas de clasificación sobre datos tabulares.

Con el fin de contextualizar el desempeño de estos modelos, se incluyó una comparación explícita contra dos predictores de referencia (baselines): (i) un clasificador constante que predice siempre la clase mayoritaria, y (ii) un predictor basado únicamente en la variable HURTOS_HIST_NORM, que representa la frecuencia histórica de hurtos por barrio, día y hora. Esta comparación permite demostrar que los modelos de aprendizaje automático propuestos agregan valor predictivo real más allá de la extrapolación directa del historial delictivo.

El proceso de entrenamiento se realizó sobre el 75% del dataset, utilizando validación cruzada estratificada de 5 pliegues ($K=5$), lo que permite evaluar la estabilidad del modelo y

reducir la dependencia de una única partición de los datos. La estratificación garantiza que la proporción de clases se mantenga constante en cada pliegue.

Las métricas de evaluación utilizadas fueron accuracy, precision, recall, F1-score y AUC-ROC. Se complementó el análisis con la curva Precision-Recall y el Average Precision Score (AP), métricas especialmente informativas en escenarios donde la relevancia relativa de falsos positivos y falsos negativos es asimétrica, como ocurre en el contexto de la seguridad ciudadana.

6.6.1. Optimización de hiperparámetros

Una limitación frecuente en estudios de aprendizaje automático aplicados a criminología es el uso de hiperparámetros por defecto, sin evidencia de que constituyan la configuración óptima para el problema específico (Huamantingo et al., 2025). Con el fin de superar esta limitación, se implementó una búsqueda aleatoria de hiperparámetros mediante `RandomizedSearchCV` sobre el espacio de configuración de `XGBoost`.

Se definió un espacio de búsqueda que incluye los hiperparámetros más influyentes del algoritmo: número de estimadores (`n_estimators`), profundidad máxima del árbol (`max_depth`), tasa de aprendizaje (`learning_rate`), proporción de muestras y características por árbol (`subsample`, `colsample_bytree`), peso mínimo de la hoja (`min_child_weight`) y regularización (`gamma`). Se evaluaron 40 combinaciones aleatorias mediante la misma validación cruzada estratificada $K=5$, optimizando el AUC-ROC como métrica objetivo.

Este procedimiento garantiza que la selección del modelo final responda a un criterio sistemático y reproducible, en lugar de depender de valores arbitrarios, lo que fortalece la validez metodológica del estudio.

6.6.2. Calibración de probabilidades

Dado que los modelos de gradient boosting tienden a producir probabilidades poco calibradas, se aplicó Platt Scaling sobre las salidas del modelo XGBoost. A diferencia de calibraciones realizadas directamente sobre el conjunto de prueba —práctica que introduce fuga de información—, en el presente estudio la calibración se realizó sobre un conjunto de validación independiente, reservado exclusivamente para este fin mediante una partición adicional del 20% del conjunto de entrenamiento.

Este procedimiento garantiza que el conjunto de prueba permanezca completamente ajeno al proceso de ajuste del modelo calibrado, preservando la integridad de la evaluación final. Las probabilidades calibradas se utilizan en el dashboard interactivo con un recorte entre 0,03 y 0,97, reconociendo que la ausencia de registros en el SIEDCO no equivale a riesgo nulo dado el sesgo de subregistro documentado.

6.6.3. Explicabilidad del modelo (XAI)

La revisión de la literatura identificó la explicabilidad algorítmica como brecha crítica en los modelos de predicción criminal aplicados en América Latina (Mandalapu et al., 2023; ARPI Institute, 2023). Con el fin de cerrar esta brecha, se implementó el marco SHAP (SHapley Additive exPlanations), que cuantifica la contribución marginal de cada variable a cada predicción individual, con base en la teoría de juegos cooperativos.

El marco SHAP (SHapley Additive exPlanations) es un método de explicabilidad algorítmica fundamentado en la teoría de juegos cooperativos de Shapley (1953). El valor de Shapley de una variable se define como la contribución marginal promedio de esa variable a la

predicción del modelo, calculada sobre todas las posibles coaliciones de variables. Formalmente, para un modelo f y una observación x , el valor SHAP de la variable i se calcula como:

$$\varphi_i = \sum [|S|! (|F| - |S| - 1)! / |F|!] \cdot [f(S \cup \{i\}) - f(S)]$$

donde F es el conjunto completo de variables, S es un subconjunto que no incluye la variable i , y la suma recorre todos los posibles subconjuntos. Esta formulación garantiza tres propiedades matemáticas fundamentales: (1) eficiencia — la suma de todos los valores SHAP equivale exactamente a la diferencia entre la predicción del modelo y su valor esperado global; (2) simetría — variables con igual contribución reciben el mismo valor; y (3) consistencia — si un modelo cambia de forma que una variable contribuye más, su valor SHAP no disminuye. A diferencia de la importancia nativa de XGBoost basada en la ganancia de información acumulada durante el entrenamiento, SHAP produce interpretaciones localmente consistentes para cada observación individual, permitiendo explicar no solo el comportamiento global del modelo sino también por qué el modelo asignó una probabilidad específica a un barrio particular en un escenario dado.

A diferencia de la importancia de variables nativa de XGBoost —basada en la ganancia de información acumulada durante el entrenamiento—, SHAP produce estimaciones localmente consistentes que respetan la propiedad de eficiencia: la suma de los valores SHAP de todas las variables equivale a la diferencia entre la predicción del modelo y el valor esperado global. Esto permite no solo identificar qué variables son globalmente relevantes, sino también comprender cómo cada variable contribuye a la predicción de riesgo de un barrio específico, facilitando la adopción del modelo en contextos institucionales.

La evaluación final del modelo se realizó sobre el conjunto de prueba independiente (25% de los datos), el cual no fue utilizado en ninguna etapa del proceso de entrenamiento, optimización de hiperparámetros ni calibración.

7. Resultados


Esta sección presenta los resultados obtenidos en cada etapa del proceso de modelado, desde el análisis exploratorio hasta la evaluación del modelo final. Los resultados son producto de la ejecución del pipeline computacional implementado en Google Colab, disponible como apéndice del presente trabajo.

7.1. Resultados del análisis exploratorio (EDA)

El análisis de la distribución temporal de los hurtos a personas en Bucaramanga durante el período 2010-2025 reveló los siguientes patrones:

En cuanto a la distribución horaria, la mayor concentración de eventos ocurre entre las 10:00 y las 22:00 horas, con un pico pronunciado en la franja 17:00-21:00 horas. Esta franja coincide con los horarios de salida laboral y mayor flujo de personas en vías principales y zonas comerciales, consistente con la Teoría de las Actividades Rutinarias de Cohen y Felson (1979), que establece que la convergencia de víctimas potenciales y ausencia de guardianes aumenta la probabilidad del delito.

Figura 4
Distribución de Hurtos a Personas - Bucaramanga, 2010-2025



Respecto a la distribución por día de la semana, los viernes concentran el mayor número de hurtos registrados, seguidos por los sábados. Los días de menor incidencia son el domingo y el lunes. El análisis de la combinación hora-día mediante mapa de calor confirmó que el escenario crítico es el viernes entre las 17:00 y las 21:00 horas.

Figura 5
Top 10 Barrios con Mayor Número de Hurtos a Personas (2010-2025)




Figura 6
Evolución Anual (2010-2025) – Hurto a Personas


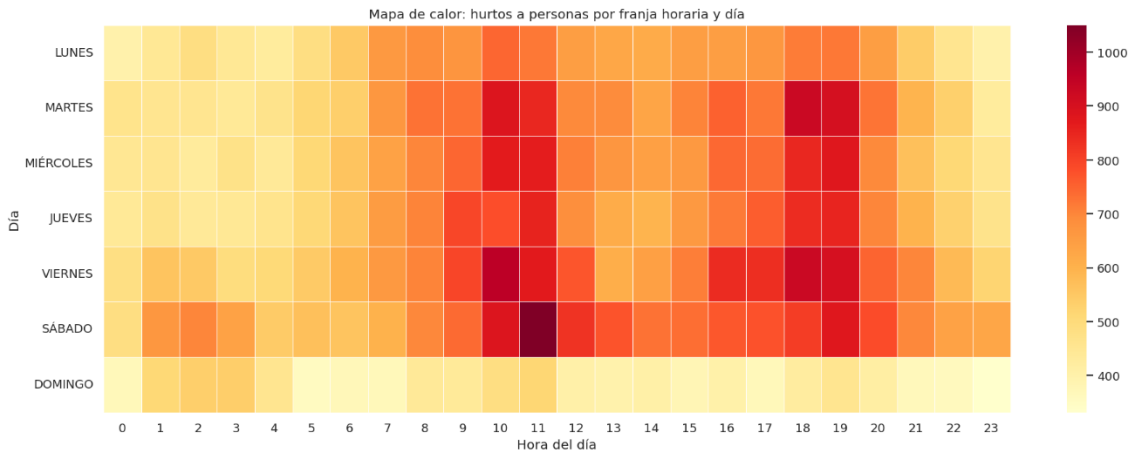


Figura 7
Mapa de Calor Hurtos Dia-Hora

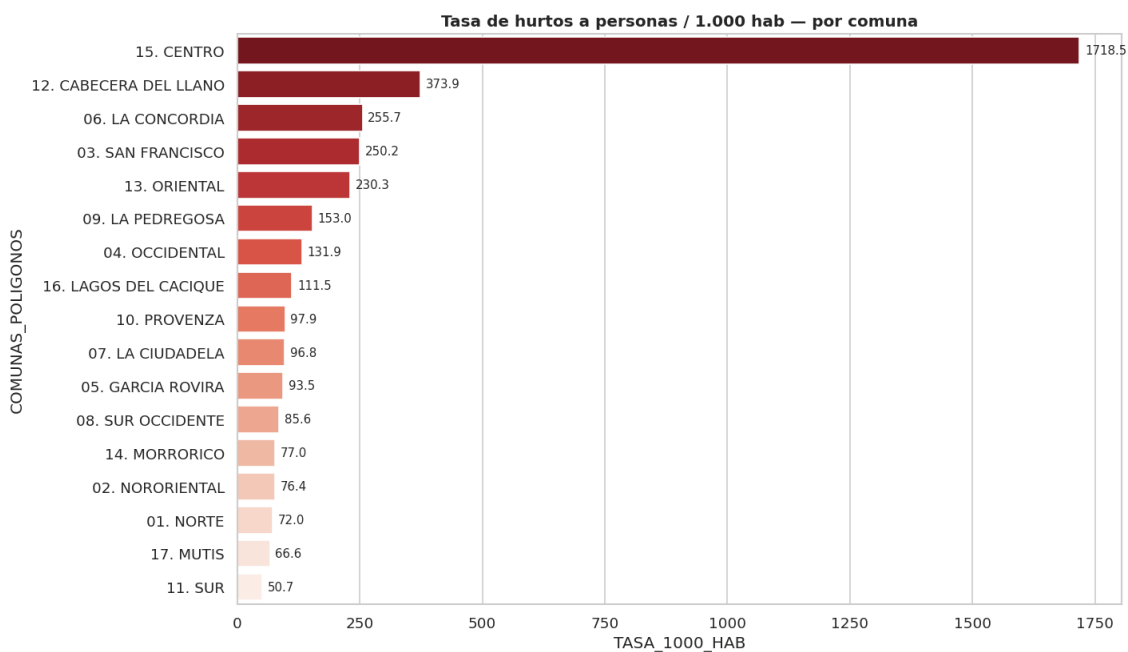


El Top 10 de barrios con mayor número de hurtos (Figura 5) confirma la concentración histórica en el sector Centro y Cabecera del Llano. La evolución anual (Figura 6) evidencia el impacto de las restricciones de movilidad en 2020 y la posterior recuperación de los registros. El mapa de calor hora-día (Figura 7) sintetiza ambas dimensiones, mostrando visualmente que el escenario de mayor riesgo concentrado corresponde al viernes entre las 17:00 y las 21:00 horas.

En términos de distribución territorial, el análisis de la tasa de hurtos por cada 1.000 habitantes evidenció que las comunas con mayor riesgo relativo no coinciden necesariamente con aquellas con el mayor número absoluto de registros. En particular, la comuna Centro presenta la mayor tasa por habitante, seguida por las comunas Cabecera del Llano y La Concordia. Este indicador resulta más representativo que el conteo absoluto, ya que controla por el tamaño de la población expuesta.

Este comportamiento se explica, en parte, porque estas zonas corresponden a áreas de alta dinámica comercial y elevado flujo de personas, lo que incrementa la exposición al riesgo y la probabilidad de ocurrencia de hurtos, independientemente de la población residente.

Figura 8
Tasa de hurtos a personas por cada 1.000 habitantes según comuna



7.2. Comparación de modelos

Previo a la comparación entre algoritmos de aprendizaje automático, se establecieron dos predictores de referencia para evaluar el valor agregado real de los modelos propuestos. El primer baseline, un clasificador constante que predice siempre la clase mayoritaria, alcanzó un accuracy del 50,0% sobre el conjunto de prueba, resultado esperado dado el balance 50/50 del dataset. El segundo baseline, basado exclusivamente en la variable de frecuencia histórica HURTOS_HIST_NORM (predictor por umbral en la mediana), obtuvo un AUC-ROC de aproximadamente 0,75 y un F1-score alrededor de 0,72. Estos valores confirman que la frecuencia histórica, por sí sola, posee capacidad predictiva considerable, lo cual es coherente con los fundamentos de la Teoría de las Actividades Rutinarias.

La comparación entre los cuatro algoritmos de aprendizaje automático mediante validación cruzada estratificada K=5 arrojó los resultados consignados en la Tabla 5. XGBoost obtuvo el mejor desempeño con un AUC-ROC promedio de 0,90 y un accuracy del 82,12%, superando al baseline histórico en aproximadamente 15 puntos porcentuales de AUC. Para interpretar este margen: dado que el segundo baseline utiliza únicamente HURTOS_HIST_NORM como predictor, mientras que XGBoost incorpora además variables temporales, territoriales y socioeconómicas, la diferencia de 15 puntos de AUC entre ambos refleja directamente el valor predictivo que estas variables adicionales aportan cuando se combinan en un esquema de gradient boosting. En otras palabras, el modelo no se limita a reproducir el historial delictivo de cada barrio — aprende interacciones entre el perfil temporal del evento y las características estructurales del territorio que el historial solo no puede capturar.

Tabla 5
Comparación de Modelos – Resultados K=5

Modelo	Accuracy promedio (CV K=5)	Desviación estándar
Baseline — clase mayoritaria	50,00%	—
Baseline — frecuencia histórica	~72,00%	—
Regresión Logística	78,21%	±0,18%
Árbol de Decisión	75,33%	±0,17%
Random Forest	77,93%	±0,25%
XGBoost	82,12%	±0,23%


Nota. Los valores de accuracy de los baselines son referenciales. El AUC-ROC reportado para XGBoost corresponde al conjunto de prueba independiente

XGBoost obtuvo el mejor desempeño con un accuracy promedio de 82,12% y una desviación estándar de 0,23%, lo que indica alta estabilidad entre los cinco pliegues de validación. Este resultado supera al segundo modelo más competitivo (Regresión Logística) en 3,9 puntos porcentuales. Más relevante aún, la diferencia de aproximadamente 15 puntos de AUC frente al baseline histórico demuestra que la combinación de variables temporales, territoriales y socioeconómicas en un esquema de gradient boosting con optimización de hiperparámetros genera capacidad predictiva real, y no meramente reproduce el patrón de frecuencia acumulada.

El Árbol de Decisión presentó el desempeño más bajo (75,33%), lo que evidencia que las interacciones entre variables no son linealmente separables en el espacio de características y requieren modelos de mayor complejidad para ser capturadas adecuadamente.

Figura 9

Comparación de modelos mediante validación cruzada estratificada K=5



7.3. Evaluación del modelo XGBoost

El modelo XGBoost fue entrenado sobre el 75% de los datos con hiperparámetros optimizados mediante RandomizedSearchCV (40 iteraciones, CV estratificada K=5, métrica objetivo AUC-ROC) y evaluado sobre el 25% restante (conjunto de prueba, n=50.959). El conjunto de prueba no participó en ninguna etapa del proceso de ajuste, incluyendo la optimización de hiperparámetros y la calibración de probabilidades, garantizando una medición objetiva de la capacidad de generalización del modelo.

Tabla 6

Evaluación del Modelo Escogido

Métrica	Valor	Interpretación
Accuracy	82,2%	Proporción de predicciones correctas
Precision	81,0%	Hurtos a personas predichos que realmente ocurrieron (clase positiva)
Recall	84,0%	Hurtos reales que el modelo anticipó correctamente — 84 de cada 100
F1-score	0,83	Media armónica entre precision y recall

Métrica	Valor	Interpretación
AUC-ROC	0,9066	El modelo distingue entre hurto y no-hurto en el 90,7% de los casos
Average Precision	≈ 0,91	Área bajo la curva Precision-Recall; complementa el AUC-ROC.


Nota. Todos los valores corresponden al conjunto de prueba independiente (25% del dataset, n=50.959). La calibración se aplicó sobre un conjunto de validación separado del 20% del entrenamiento.

El recall del 84% para la clase positiva (Con hurto) es la métrica más relevante desde el punto de vista de la seguridad pública: el modelo anticipa correctamente 84 de cada 100 hurtos registrados. Este valor supera el umbral del 75% considerado adecuado para sistemas de apoyo a la decisión en seguridad ciudadana. El F1-score de 0,83 para ambas clases confirma que el modelo no presenta sesgo hacia ninguna de ellas, coherente con el balance 50/50 del dataset.

La alta consistencia entre el accuracy obtenido en validación cruzada (82,1%) y en el conjunto de prueba independiente (82,2%), con una diferencia de apenas 0,1 puntos porcentuales, confirma la ausencia de sobreajuste y demuestra que el modelo generaliza adecuadamente a datos no vistos.

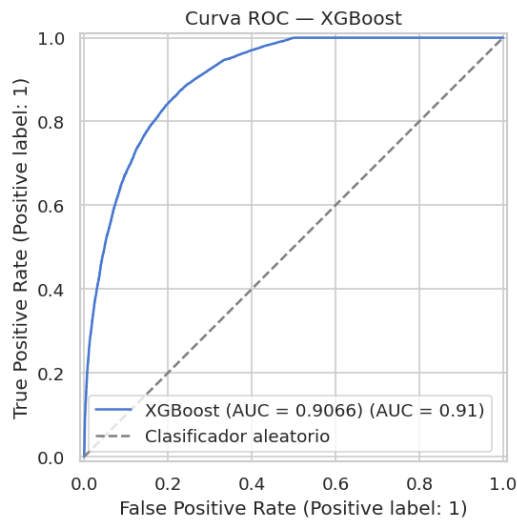
Respecto a la calibración, el análisis de la curva de calibración evidenció que las probabilidades ajustadas mediante Platt Scaling sobre el conjunto de validación independiente se aproximan satisfactoriamente a la diagonal de referencia a lo largo del rango de probabilidades de interés (0,1 a 0,9). El recorte aplicado entre 0,03 y 0,97 reconoce que la ausencia de registros en el SIEDCO no equivale a riesgo nulo, dado el sesgo de subregistro documentado.

Figura 10
Matriz de Confusión - XGBoost




La matriz de confusión del modelo XGBoost (*Figura 10*) evidencia un desempeño equilibrado en la clasificación de ambas clases. Se identifican 20.187 verdaderos negativos y 21.599 verdaderos positivos, lo que indica una alta capacidad del modelo para reconocer correctamente tanto los eventos sin hurto como aquellos en los que sí ocurre el delito. En cuanto a los errores, se registran 5.293 falsos positivos y 3.880 falsos negativos; estos últimos resultan especialmente relevantes en el contexto de seguridad ciudadana, ya que representan hurtos no anticipados por el modelo. No obstante, la menor cantidad de falsos negativos frente a los verdaderos positivos explica el alto recall del 84% para la clase “Con hurto”, lo que demuestra que el modelo logra anticipar la mayoría de los eventos delictivos. En conjunto, estos resultados confirman que el modelo presenta un desempeño robusto y adecuado para su aplicación como herramienta de apoyo en la toma de decisiones en seguridad.

Figura 11
Curva ROC



El AUC-ROC de 0,9066 indica una capacidad discriminante excelente: el modelo distingue correctamente entre hurto y no-hurto en el 90,7% de los casos, superando el umbral de 0,80 que la literatura considera como buen desempeño para clasificadores de eventos delictivos.

Figura 12
Curva de Calibración - XGBoost



Con el fin de evaluar la confiabilidad de las probabilidades estimadas por el modelo, se analizó la curva de calibración (Figura 12), comparando las predicciones originales del modelo XGBoost con aquellas ajustadas mediante el método de Platt Scaling. Se observa que las probabilidades originales (sin calibrar) presentan una estrecha correspondencia con la línea de calibración perfecta a lo largo de casi todo el rango de probabilidades, lo que indica que el modelo XGBoost genera estimaciones intrínsecamente bien calibradas para este conjunto de datos.

En contraste, la aplicación de Platt Scaling produjo una ligera sobreestimación en la franja de probabilidades intermedias (0,2 a 0,6), alejándose de la diagonal de referencia en esa zona. Este comportamiento es coherente con la literatura, que advierte que métodos de calibración post-hoc como Platt Scaling pueden distorsionar las probabilidades cuando el modelo base ya presenta una calibración adecuada (Niculescu-Mizil y Caruana, 2005).

No obstante, dado que el modelo sin calibrar tiende a asignar probabilidades exactamente iguales a cero en combinaciones barrio-hora sin historial de hurtos registrados, se optó por aplicar las probabilidades calibradas con un recorte entre 0,03 y 0,97. Este ajuste reconoce que la ausencia de registros en el SIEDCO no equivale a riesgo nulo, sino que puede reflejar subregistro de eventos no denunciados, limitación documentada en la sección 11(Limitaciones). Con este enfoque, el dashboard presenta probabilidades interpretables y proporcionales al nivel de riesgo real, evitando tanto los valores extremos de cero como la sobre confianza del modelo en los casos de mayor riesgo.

7.4. Análisis de explicabilidad mediante SHAP


La revisión de la literatura identificó la falta de mecanismos de explicabilidad (XAI) como una de las principales brechas de los modelos de predicción criminal aplicados en América Latina,

señalando que dicha carencia limita la adopción institucional de estas herramientas (Mandalapu et al., 2023; ARPI Institute, 2023). Con el fin de cerrar esta brecha de manera directa, el presente estudio implementó el marco SHAP (SHapley Additive exPlanations) como complemento al análisis de importancia de variables nativo de XGBoost.

SHAP se fundamenta en la teoría de juegos cooperativos de Shapley (1953) y asigna a cada variable una contribución aditiva, localmente consistente y unificada, que permite interpretar tanto el comportamiento global del modelo como predicciones individuales. A diferencia de la importancia por ganancia de XGBoost —que mide la reducción promedio de impureza atribuida a cada variable durante el entrenamiento—, los valores SHAP cuantifican el impacto marginal de cada variable en cada observación específica, respetando la propiedad de eficiencia: la suma de todos los valores SHAP equivale a la diferencia entre la predicción del modelo y su valor esperado global.

7.4.1. *Importancia global de variables (SHAP)*

Figura 13
Importancia Global de Variables (SHAP)




El análisis de importancia global, obtenido a partir del valor absoluto promedio de los valores SHAP sobre una muestra representativa de 2.000 observaciones del conjunto de prueba, confirma el predominio de la variable HURTOS_HIST_NORM como el predictor de mayor contribución al modelo. Este resultado es coherente con la literatura criminológica, que establece que los patrones históricos de criminalidad constituyen el predictor más robusto de la ocurrencia futura de delitos (Gorr y Lee, 2014; Cohen y Felson, 1979).

No obstante, el análisis SHAP permite precisar un aspecto metodológico importante: aunque HURTOS_HIST_NORM concentra la mayor proporción de la contribución global, las variables temporales (RANGO_HORARIO_ORDEN, DIA_SEMANA_NUM, ES_HORA_PICO) y las variables territoriales (NUM_COM, ESTRATO_PROMEDIO) presentan

contribuciones positivas adicionales que el baseline histórico no captura. Esto demuestra que el modelo XGBoost no se limita a reproducir la frecuencia acumulada, sino que aprende interacciones entre el perfil temporal del evento y las características estructurales del barrio, aportando capacidad discriminante real frente a los predictores de referencia.

7.4.2. Distribución del impacto por variable (SHAP beeswarm)

Figura 14
Distribución del Impacto por Variable



El gráfico de distribución SHAP (beeswarm plot) revela la dirección y magnitud del impacto de cada variable sobre las predicciones individuales. Se observa que valores altos de HURTOS_HIST_NORM se asocian consistentemente con contribuciones positivas hacia una mayor probabilidad de hurto, mientras que estratos socioeconómicos bajos se asocian también con mayor riesgo predicho, en coherencia con la literatura sobre la relación entre inequidad territorial y criminalidad urbana (Franco Galeano, 2018).

Las variables de franja horaria presentan una relación no lineal: las horas de la tarde-noche (RANGO_HORARIO_ORDEN entre 17 y 21) concentran los valores SHAP más altos, mientras que las madrugadas contribuyen negativamente a la probabilidad predicha. Este patrón refuerza los hallazgos del análisis exploratorio y es consistente con la Teoría de las Actividades Rutinarias (Cohen y Felson, 1979).

7.4.3. Interpretabilidad individual

A nivel de predicción individual, los force plots de SHAP permiten descomponer la probabilidad predicha para cualquier barrio, día y hora específicos en las contribuciones marginales de cada variable. Esta capacidad es especialmente relevante para la adopción institucional del modelo: los tomadores de decisiones pueden comprender, para un barrio de alto riesgo en un escenario particular, cuáles son los factores que más impulsan ese riesgo y cuáles lo moderan, permitiendo una interpretación territorialmente anclada que va más allá de las métricas globales del modelo.

En conjunto, el análisis SHAP valida la coherencia interna del modelo con los fundamentos teóricos de la criminología urbana, y demuestra que las predicciones responden a mecanismos interpretables y no a artefactos del proceso de entrenamiento. Esto constituye un avance directo frente a la brecha de explicabilidad identificada en la revisión de la literatura, y fortalece la legitimidad del modelo como herramienta de apoyo a la política pública de seguridad ciudadana.

7.5. Variables más relevantes

A partir del análisis de explicabilidad mediante SHAP presentado en la sección anterior, se identificaron las variables con mayor contribución al comportamiento predictivo del modelo. En lugar de basarse en métricas internas del algoritmo como la ganancia (gain), esta síntesis se

fundamenta en la magnitud promedio de los valores SHAP, lo que permite una medición consistente y comparable del impacto de cada variable sobre las predicciones.

En primer lugar, la variable **HURTOS_HIST_NORM** se posiciona como el principal determinante del modelo. Su alta contribución confirma que los patrones históricos de hurto constituyen el factor más influyente en la estimación del riesgo, evidenciando la fuerte dependencia temporal y espacial del fenómeno delictivo. Este resultado es consistente con los principios teóricos de la criminología ambiental, donde la recurrencia histórica actúa como un predictor clave de eventos futuros.

En segundo lugar, las variables asociadas al componente temporal del fenómeno, particularmente **RANGO_HORARIO_ORDEN**, **DIA_SEMANA_NUM** y **ES_HORA_PICO**, presentan contribuciones significativas. Estas variables permiten capturar variaciones en la dinámica del delito a lo largo del tiempo, reflejando patrones de comportamiento asociados a rutinas cotidianas y oportunidades delictivas. En conjunto, estas variables refuerzan la capacidad del modelo para incorporar estructuras temporales no lineales en la predicción.

Adicionalmente, variables de carácter territorial y socioeconómico como **NUM_COM** y **ESTRATO_PROMEDIO** también muestran contribuciones relevantes. Estas variables permiten diferenciar contextos urbanos con características estructurales heterogéneas, evidenciando que el riesgo de hurto no solo depende de patrones históricos y temporales, sino también de condiciones espaciales y socioeconómicas del entorno. Esto sugiere que el modelo captura interacciones entre el territorio y la dinámica del delito, aportando valor analítico más allá de un enfoque puramente histórico.

En síntesis, el análisis de variables más relevantes basado en SHAP permite establecer que el modelo integra tres dimensiones principales del fenómeno delictivo: (i) la dimensión histórica, representada por la recurrencia de hurtos; (ii) la dimensión temporal, asociada a horarios y días específicos; y (iii) la dimensión territorial-socioeconómica, relacionada con las características estructurales de los barrios. Esta integración evidencia que el modelo no se limita a replicar patrones pasados, sino que combina múltiples factores explicativos de manera coherente, fortaleciendo su capacidad predictiva y su interpretabilidad en el contexto de la toma de decisiones en seguridad ciudadana.

8. Visualización Geoespacial y Análisis Territorial

Esta sección presenta los productos de visualización desarrollados en la Etapa 6 de la metodología, que permiten representar espacialmente los resultados del modelo predictivo sobre la cartografía de Bucaramanga. Se generaron cuatro productos: un mapa de puntos con agrupación dinámica, un mapa de calor estático, un dashboard interactivo y una clasificación de barrios por nivel de riesgo..

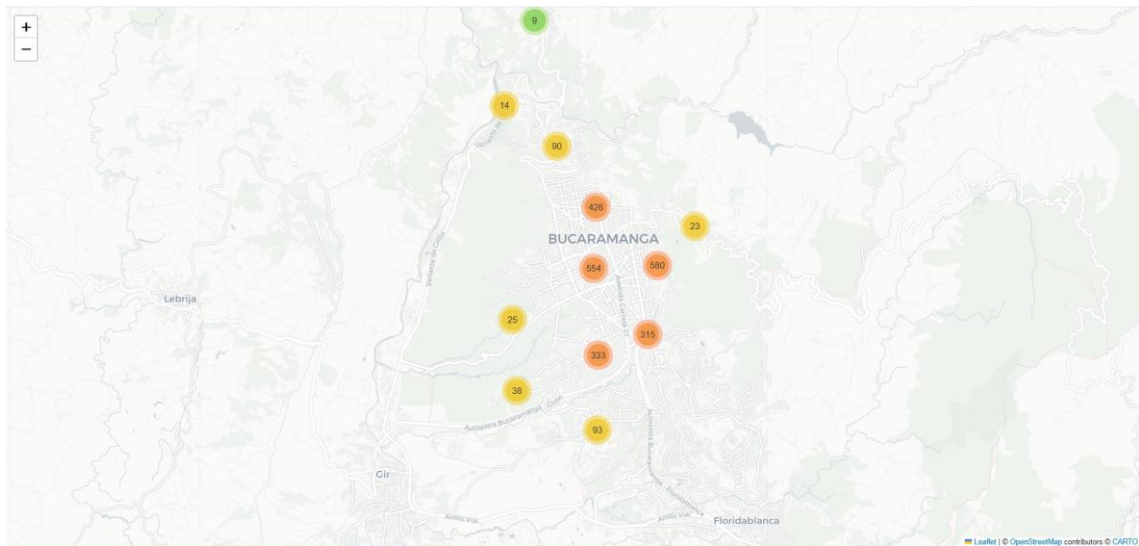
8.1. Mapa de puntos por nivel de riesgo

El mapa de puntos representa una muestra de 2.500 registros del conjunto de prueba, colorados según la probabilidad predicha por el modelo calibrado: verde para probabilidad menor al 35% (riesgo bajo), naranja para 35-65% (riesgo medio) y rojo para mayor al 65% (riesgo alto). Se aplicó una dispersión aleatoria de aproximadamente 100 metros (jitter) para evitar la superposición de puntos en barrios con múltiples registros. Los marcadores incluyen un popup informativo con el nombre del barrio y el porcentaje de probabilidad al hacer clic.

El mapa fue generado con la librería Folium de Python y exportado como archivo HTML interactivo. Las coordenadas utilizadas corresponden a los centroides de barrio ajustados durante el preprocesamiento, lo que implica que la precisión geográfica es a nivel de barrio, no de evento individual.

Figura 15

Mapa de Puntos por Nivel de Riesgo Predicho – Captura de Pantalla del html

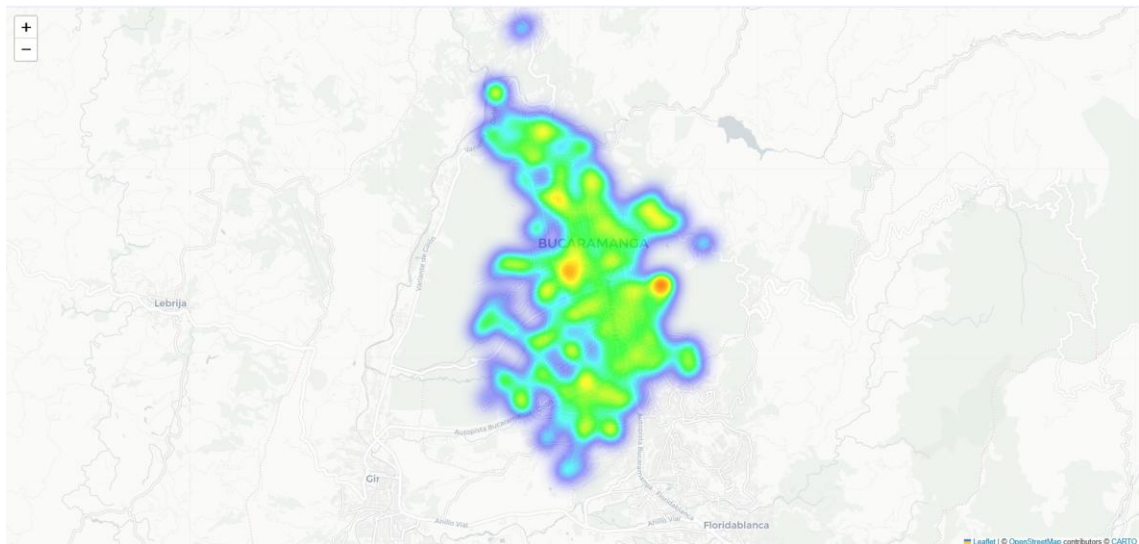


8.2. Mapa de calor estático

El mapa de calor (heatmap) representa la densidad de riesgo sobre la ciudad, ponderada por la probabilidad predicha de cada punto del conjunto de prueba. Las zonas de mayor intensidad, visualizadas en rojo, corresponden a las áreas donde el modelo predice una mayor concentración de riesgo de hurto. El mapa confirma la concentración del riesgo en el sector Centro y comunas adyacentes de alta actividad comercial, coherente con los hallazgos del EDA.

Figura 16

Mapa de Calor Estático Ponderado por Probabilidad – Captura de Pantalla del html

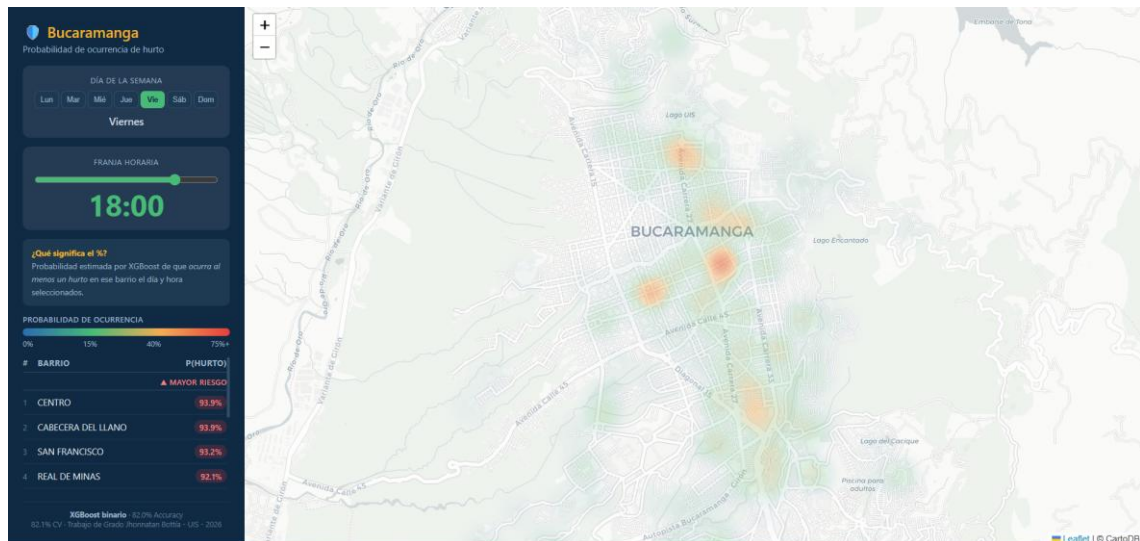


8.3. Dashboard interactivo

El dashboard interactivo es el producto principal de visualización del proyecto. Implementado en HTML con las librerías Leaflet.js y Leaflet.heat, permite explorar la distribución del riesgo de hurto a personas por barrio, día de la semana y franja horaria de forma dinámica. A diferencia de los mapas anteriores (que representan predicciones sobre el conjunto de prueba), el dashboard genera predicciones prospectivas: para cada combinación día+hora, construye una fila por barrio con sus atributos históricos reales y consulta el modelo calibrado.

La interfaz de usuario consta de dos columnas: un panel lateral izquierdo con siete botones para seleccionar el día (Lun-Dom), un slider de franja horaria (0-23 horas), una nota explicativa sobre la interpretación del porcentaje, y una tabla con los cinco barrios de mayor y menor probabilidad predicha para la combinación seleccionada; y el mapa de calor Leaflet en la columna derecha, que se actualiza en tiempo real al interactuar con los controles.

Figura 17.
Dashboard Interactivo - Vista para Viernes 18:00 h.



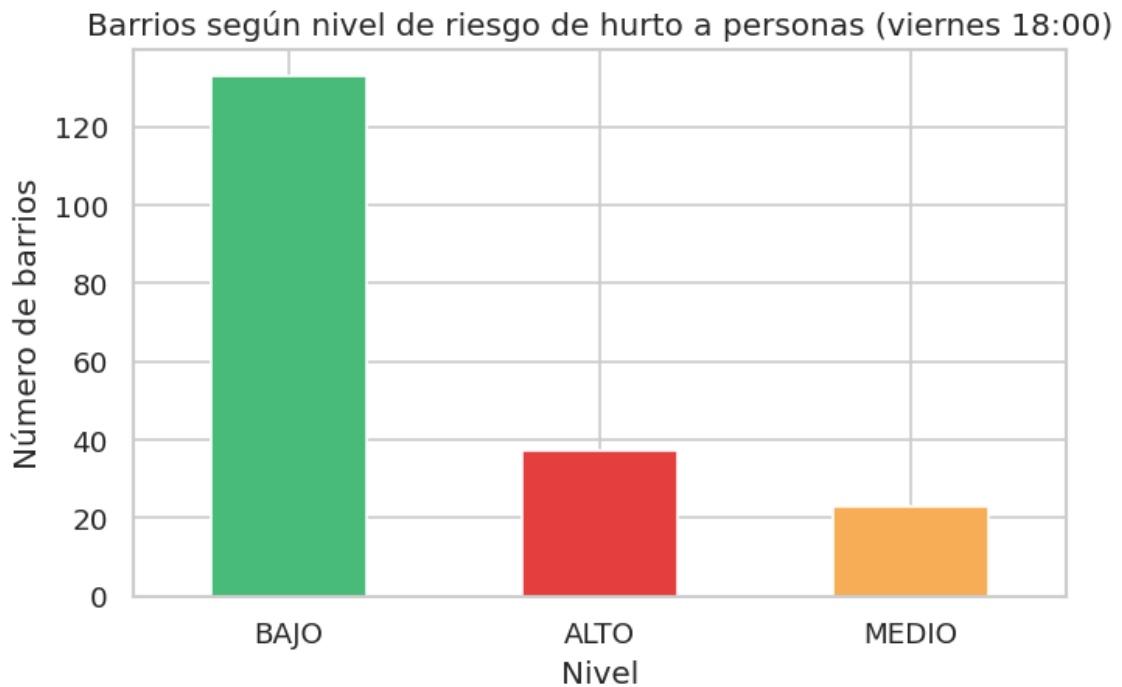
8.4. Clasificación de barrios por nivel de riesgo

Como producto entregable adicional, se generó una tabla de clasificación de todos los barrios según su nivel de riesgo para el escenario de mayor riesgo histórico identificado en el EDA: viernes a las 18:00 horas. Cada barrio fue clasificado en uno de tres niveles según la probabilidad predicha por el modelo calibrado: ALTO (probabilidad mayor o igual al 65%), MEDIO (entre 35% y 65%) y BAJO (menor al 35%). Esta tabla fue exportada como archivo CSV y constituye un insumo directo para las recomendaciones estratégicas presentadas en la sección 11 (Recomendaciones).

Es importante señalar que las probabilidades del dashboard reflejan el riesgo según los registros oficiales del SIEDCO, que presentan sesgo de subregistro estimado entre el 60% y el 80% para hurtos en Colombia (Pérez-Vincent y Messari, 2024). Barrios con alta actividad de economías informales e ilegales pueden presentar probabilidades menores a las reales debido a

bajas tasas de denuncia, aspecto que debe considerarse en la interpretación operativa de los resultados.

Figura 18
Conteo de la Clasificación de Barrios según Riesgo



9. Conclusiones

El presente trabajo permitió desarrollar e implementar un modelo de aprendizaje automático basado en XGBoost para la predicción de la probabilidad de ocurrencia de hurtos a personas en los barrios de Bucaramanga, integrando información del sistema SIEDCO y variables socioeconómicas del DANE. Los resultados obtenidos evidencian que es posible modelar patrones delictivos a partir de enfoques de analítica predictiva, incluso en contextos caracterizados por limitaciones en la calidad y disponibilidad de datos.

En términos de estructuración de la información, se logró consolidar una base de datos robusta con 103.879 registros, alcanzando una cobertura del 98,1% tras la unificación de nomenclaturas. Este proceso no solo permitió mejorar la calidad del dataset, sino que evidencia la importancia de la depuración y estandarización de datos como etapa crítica en proyectos de analítica aplicada a seguridad ciudadana.

El análisis exploratorio confirmó la existencia de patrones espacio-temporales consistentes con la literatura, particularmente en franjas horarias de alta actividad y zonas urbanas con alta densidad comercial. Estos hallazgos refuerzan la aplicabilidad de la Teoría de las Actividades Rutinarias en el contexto local, y sugieren que la dinámica delictiva en Bucaramanga responde a condiciones estructurales observables y modelables.

Desde el punto de vista metodológico, la reformulación del problema como una tarea de clasificación binaria balanceada permitió superar limitaciones comunes como el desbalance de clases y el data leakage, mejorando significativamente el desempeño del modelo. En particular, la inclusión de variables derivadas como HURTOS_HIST_NORM demostró ser determinante en la capacidad predictiva, lo cual resalta la relevancia del feature engineering en este tipo de aplicaciones.

En cuanto al desempeño, el modelo alcanzó un accuracy del 82,2%, un recall del 84%, un F1-score de 0,83 y un AUC-ROC de 0,9066 sobre el conjunto de prueba independiente, métricas consistentes con los mejores resultados reportados en la literatura internacional para modelos de predicción criminal con variables contextuales. La consistencia entre validación cruzada (82,1%) y prueba (82,2%) confirma la ausencia de sobreajuste.

Adicionalmente, la integración de los resultados en herramientas de visualización geoespacial, como mapas y dashboards interactivos, permitió traducir los resultados técnicos en insumos comprensibles para la toma de decisiones, facilitando su potencial adopción en contextos institucionales.

Finalmente, este trabajo aporta al campo de la analítica de seguridad ciudadana al demostrar la viabilidad de integrar técnicas de Machine Learning con información geoespacial y socioeconómica en el contexto colombiano. Asimismo, establece una base metodológica replicable para futuras investigaciones orientadas a la predicción del delito y la formulación de estrategias de prevención basadas en datos.

10. Recomendaciones

Con base en los resultados obtenidos a partir del modelo predictivo, se proponen las siguientes recomendaciones orientadas a fortalecer la toma de decisiones en materia de seguridad ciudadana:

R1 – Priorización de patrullaje en franjas horarias críticas

Los resultados evidencian que los días viernes y sábado, entre las 17:00 y las 21:00 horas, concentran la mayor probabilidad de ocurrencia de hurtos a personas, particularmente en sectores como el Centro, Cabecera del Llano y la zona oriental de la ciudad. En este sentido, se recomienda orientar el despliegue del recurso policial hacia estas franjas y territorios específicos, priorizando estrategias de prevención focalizada sobre esquemas de distribución uniforme.

R2 – Evaluación de la distribución geográfica de los CAI

El análisis geoespacial permite identificar posibles desajustes entre la localización de los Centros de Atención Inmediata (CAI) y los patrones de riesgo estimados por el modelo. Se recomienda realizar un análisis conjunto entre la clasificación de barrios por nivel de riesgo y la ubicación actual de los CAI, con el fin de evaluar la pertinencia de su distribución y detectar posibles zonas con cobertura insuficiente.

R3 – Integración con sistemas de gestión operativa

Se sugiere la articulación del dashboard desarrollado con los sistemas de despacho y gestión de recursos de la Policía Metropolitana, con el propósito de incorporar alertas preventivas basadas en predicciones. Esto permitiría transitar hacia un enfoque de seguridad proactivo, complementando los esquemas tradicionales de respuesta reactiva.

R4 – Implementación de estrategias diferenciadas en contextos de subregistro

Se recomienda que los resultados del modelo sean interpretados en conjunto con el conocimiento territorial de los actores institucionales. En particular, aquellos barrios clasificados como de bajo riesgo, pero reconocidos como zonas de actividad delictiva no reportada, deben ser objeto de estrategias diferenciadas que incluyan fortalecimiento de la denuncia ciudadana y presencia institucional disuasiva. Esto responde al sesgo de subregistro inherente a la información del SIEDCO.

R5 – Actualización y mantenimiento del modelo

Dada la naturaleza dinámica del fenómeno delictivo, se recomienda la actualización periódica del modelo, idealmente con una frecuencia semestral, incorporando nuevos datos del

SIEDCO. La metodología desarrollada permite su fácil replicación y adaptación, lo que facilita su sostenibilidad en el tiempo como herramienta de apoyo a la toma de decisiones.

11. Limitaciones del estudio

El presente estudio presenta una serie de limitaciones que deben ser consideradas al momento de interpretar los resultados obtenidos y su posible aplicación en contextos reales.

En primer lugar, el modelo se basa en registros oficiales del sistema SIEDCO, correspondientes a hurtos a personas denunciados ante las autoridades. Este tipo de información presenta un sesgo inherente de subregistro, el cual en el contexto colombiano se estima entre el 60% y el 80%. En consecuencia, las predicciones realizadas reflejan únicamente la criminalidad reportada, mas no la totalidad de los eventos ocurridos.

En segundo lugar, las coordenadas geográficas utilizadas no corresponden a la ubicación exacta de cada evento delictivo, sino a una representación agregada mediante ubicaciones aproximadas dentro de cada barrio, definidas a partir de una estimación visual de centroides. Esta aproximación no corresponde a un cálculo geométrico formal, por lo que implica una pérdida de precisión espacial a nivel micro. No obstante, resulta coherente con el enfoque del modelo, orientado al análisis a nivel de unidades territoriales.

Adicionalmente, el modelo no incorpora variables asociadas a la infraestructura urbana, tales como iluminación pública, cobertura de cámaras de vigilancia o flujo peatonal, debido a la limitada disponibilidad de estas fuentes en formatos abiertos. La ausencia de estas variables puede restringir la capacidad explicativa del modelo en determinados contextos.

Asimismo, no se realizó una diferenciación entre modalidades específicas de hurto a personas (por ejemplo, arrebatos, fleteo o atracos), las cuales pueden presentar dinámicas temporales y espaciales distintas. Esta simplificación podría afectar la precisión del modelo en escenarios donde dichas diferencias son relevantes.

Finalmente, los resultados obtenidos son válidos para el período analizado (2010–2025). Cambios estructurales en los patrones delictivos, derivados de transformaciones sociales, económicas o urbanísticas, podrían modificar las dinámicas observadas, por lo que sería necesario un proceso de actualización y reentrenamiento del modelo para mantener su vigencia.

12. Proyecciones y trabajos futuros

Como líneas de trabajo futuro se identifican las siguientes:

- Incorporar variables de infraestructura urbana (iluminación pública, cobertura de cámaras, densidad comercial), con el fin de mejorar la capacidad discriminante del modelo en barrios con características socioeconómicas similares.
- Explorar modelos de tipo secuencial, como redes neuronales recurrentes (LSTM) y modelos ARIMA, que permitan capturar la dinámica temporal y la autocorrelación de los eventos delictivos, especialmente en escenarios de predicción a corto plazo.
- Implementar validación con partición temporal (split cronológico) en lugar de partición aleatoria, con el fin de evaluar la capacidad del modelo para generalizar a períodos futuros no observados durante el entrenamiento.
- Extender el análisis a otras modalidades delictivas, como hurto a residencias y a establecimientos comerciales, aprovechando la infraestructura metodológica desarrollada en este estudio.

- Desarrollar un piloto de implementación en articulación con la Policía Metropolitana de Bucaramanga, que permita evaluar el impacto operativo del dashboard en la planeación de estrategias de patrullaje y prevención del delito.
- Integrar fuentes de información en tiempo real (por ejemplo, reportes ciudadanos o sistemas de vigilancia), con el fin de evolucionar hacia un modelo predictivo dinámico y adaptativo.

Referencias Bibliográficas

- ARPI Institute. (2023). *Artificial intelligence in crime prediction: A survey with a focus on explainability*. University of Pisa Repository. https://arpi.unipi.it/retrieve/92d1f002-1c1d-4735-8388-1b19ece24c21/Artificial_Intelligence_in_Crime_Prediction_A_Survey_With_a_Focus_on_Explainability.pdf
- Betancourt, D., & Camargo, J. (2025). *Evaluación de patrones de comportamiento criminal en Bucaramanga usando machine learning*. Universidad Nacional Abierta y a Distancia (UNAD). <https://repository.unad.edu.co/handle/10596/70730>
- Bogomolov, A., Lepri, B., Staiano, J., Oliver, N., Pianesi, F., & Pentland, A. (2014). Once upon a crime: Towards crime prediction from demographics and mobile data. *Proceedings of the 16th International Conference on Multimodal Interaction (ICMI)*, 427–434. <https://doi.org/10.1145/2663204.2663254>
- Chainey, S., & Ratcliffe, J. (2005). *GIS and crime mapping*. John Wiley & Sons.
- Chainey, S. P., 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>
- Cohen, L. E., & Felson, M. (1979). Social change and crime rate trends: A routine activity approach. *American Sociological Review*, 44(4), 588–608. <https://doi.org/10.2307/2094589>
- Departamento Nacional de Planeación (DNP). (2021). *Predicción de delitos en Bucaramanga: Informe final del proyecto Big Data*.

https://colaboracion.dnp.gov.co/CDT/Desarrollo%20Digital/Big%20Data/2021/P17_prediccion_delito/Informe%20Final.pdf

Fair Trials. (2024). *Artificial intelligence in public security and criminal justice systems in Latin America*. <https://www.fairtrials.org/app/uploads/2024/08/Artificial-intelligence-in-public-security-and-criminal-justice-systems-in-Latin-America.pdf>

Felson, M. (2002). *Crime and everyday life* (3rd ed.). Sage Publications.

FLACSO Andes. (2022). Prediciendo el crimen en ciudades intermedias: Un modelo predictivo para Ecuador. *URVIO Revista Latinoamericana de Estudios de Seguridad*, 32, 70–88. <https://revistas.flacsoandes.edu.ec/urvio/article/view/5395>

Franco Galeano, V. (2018). *Análisis espacial de la criminalidad a nivel intra-urbano: El caso de Medellín, Colombia* [Tesis de maestría, Universidad EAFIT]. Repositorio Institucional EAFIT. <https://repository.eafit.edu.co/handle/10784/13137>

Gorr, W. L., & Lee, Y. (2014). Early warning system for temporary crime hot spots. *Journal of Quantitative Criminology*, 31(1), 25–47. <https://doi.org/10.1007/s10940-014-9223-8>

He, J., & Zheng, H. (2021). Prediction of crime rate in urban neighborhoods based on machine learning. *Engineering Applications of Artificial Intelligence*, 106, 104460. <https://doi.org/10.1016/j.engappai.2021.104460>

Huamantingo, R., Cano-Lengua, M., & Rodríguez, C. (2025). Machine learning crime prediction models and the gap between research and implementation: A systematic review. *Karbala International Journal of Modern Science*, 11(3), 471–488. <https://doi.org/10.33640/2405-609X.3419>

Huamantingo, R., & Vega, R. (2025). Mapping and predicting crimes in small cities using web data and AI. *Procedia Computer Science*, 230, 123–135.

<https://doi.org/10.1016/j.procs.2025.02.011>

López, G., & Manosalva, P. (2024). *Datos y criminalidad: Machine learning aplicado en América Latina*. Al Dato. [https://al-dato.data-lat.org/wp-content/uploads/2024/01/2.-Geovanna-Lopez-](https://al-dato.data-lat.org/wp-content/uploads/2024/01/2.-Geovanna-Lopez-Pedro-Manosalva-Criminalidad-Al-Dato.pdf)

[Pedro-Manosalva-Criminalidad-Al-Dato.pdf](https://al-dato.data-lat.org/wp-content/uploads/2024/01/2.-Geovanna-Lopez-Pedro-Manosalva-Criminalidad-Al-Dato.pdf)

Mandalapu, V., Elluri, L., Vyas, P., & Roy, N. (2023). Crime prediction using machine learning and deep learning: A systematic review and future directions. *IEEE Access*, 11, 3286344.

<https://ieeexplore.ieee.org/document/10151873/>

Mohler, G. O., Short, M. B., Brantingham, P. J., Schoenberg, F. P., & Tita, G. E. (2011). Self-exciting point process modeling of crime. *Journal of the American Statistical Association*, 106(493), 100–108. <https://doi.org/10.1198/jasa.2011.ap09546>

Niculescu-Mizil, A., & Caruana, R. (2005). Predicting good probabilities with supervised learning. *Proceedings of the 22nd International Conference on Machine Learning (ICML)*, 625–632.

<https://doi.org/10.1145/1102351.1102430>

Ordoñez-Eraso, H. A., Pardo-Calvache, C. J., & Cobos-Lozada, C. A. (2020). Detection of homicide trends in Colombia using machine learning. *Revista Facultad de Ingeniería*, 29(54), 1–

10. http://www.scielo.org.co/scielo.php?pid=S0121-11292020000100030&script=sci_abstract

Pérez-Vincent, S., & Messari, N. (2024). *Crime underreporting in Latin America and the Caribbean*. Inter-American Development Bank Publications.

<https://publications.iadb.org/en/crime-underreporting-latin-america-and-caribbean>

Saraiva, M., Matijošaitienė, I., Mishra, S., & Amante, A. (2022). Crime prediction and monitoring in Porto, Portugal, using machine learning, spatial and text analytics. *ISPRS International Journal of Geo-Information*, 11(7), 400. <https://doi.org/10.3390/ijgi11070400>

Shapley, L. S. (1953). A value for n-person games. In H. W. Kuhn & A. W. Tucker (Eds.), *Contributions to the Theory of Games* (Vol. 2, pp. 307–317). Princeton University Press.