

Facultad Latinoamericana de Ciencias Sociales, FLACSO Ecuador

Departamento de Asuntos Públicos

Convocatoria 2021-2023

Tesis para obtener el título de Maestría en Estudios Urbanos con  
mención en Geografía y Procesos Territoriales

Análisis de delitos en el barrio La Mariscal (Quito) desde perspectivas espacial, *machine learning* y de *smart city*

Cristian Andrés Betancourt Lema

Asesor: Pablo Cabrera Barona

Lectores: Pablo Danilo Ordoñez y Pablo Edilberto Melo

Quito, septiembre de 2023

## **Dedicatoria**

A Dios y la virgen María por brindarme sabiduría y fortaleza desde que inicié la maestría hasta su culminación, ya que el camino para llegar a este punto no ha sido fácil, pero con la fe puesta en mi padre celestial he podido sobrellevar y superar todas las dificultades que se me han presentado y tan solo me queda por decir gracias DIOS y a la Virgen de Guadalupe.

A mi papá que desde pequeño me inculcó mis valores religiosos y me demostró que con fe, esperanza y trabajo duro se puede salir adelante. Muchas gracias por luchar día a día para que a sus hijos no les falte alimentos y educación, por eso y mucho más le estaré eternamente agradecido.

A mi mamá, la mujer que sin importar la situación siempre ha estado conmigo y no se ha alejado de mí. Usted es un ejemplo de persona trabajadora y honesta, estoy seguro que sin importar el tiempo todos sus consejos y ejemplo quedarán marcados en mi mente y mi corazón. Muchas gracias por demostrarme que el amor de madre es inquebrantable y por apoyarme en todos mis sueños. La presente tesis se la dedico a usted mami.

A mi hermana que es para mí un gran ejemplo a seguir. Las palabras me quedan cortas para expresarle todo el agradecimiento y admiración que tengo por la persona que me apoyó en el transcurso de mi maestría. Muchas gracias por tus consejos, deseos y experiencias de vida compartidas conmigo, ten por seguro que voy a luchar por todos mis sueños y seguiré tus pasos.

## Índice de contenidos

<b>Resumen</b> .....	9
<b>Agradecimientos</b> .....	11
<b>Introducción</b> .....	12
<b>Capítulo 1. Revisión analítica de literatura</b> .....	17
1.1. Crimen urbano .....	17
1.2. Análisis espacial del crimen .....	18
1.3. <i>Machine learning</i> y crimen.....	19
1.4. <i>Smart city</i> .....	20
<b>Capítulo 2. Metodología</b> .....	23
2.1. Área de estudio .....	23
2.2. Variables e Indicadores .....	24
2.3. Métodos .....	25
2.3.1. Estadística descriptiva de los delitos.....	25
2.3.2. Significancia estadística y prueba de hipótesis .....	26
2.3.3. Correlaciones y regresiones .....	28
2.3.4. Patrones espaciales y temporales de los delitos .....	29
2.3.5. <i>Machine learning</i> para la predicción de los delitos .....	36
2.3.6. <i>Smart mapping</i> para <i>smart city</i> .....	39
2.4. Flujograma metodológico.....	40
<b>Capítulo 3. Resultados</b> .....	43
3.1. Calendario de delitos .....	43
3.2. Frecuencia de delitos .....	45
3.3. Diferencias significativas de delitos .....	54
3.4. Causalidad de delitos .....	56
3.5. Densificación y patrón espacial de delitos .....	58

3.6. Patrones espacio-temporales de delito.....	62
3.7. Predicción de delitos mensual en el año 2019.....	67
3.8. <i>Dashboard</i> de delitos del sector La Mariscal .....	76
<b>Capítulo 4. Discusión.....</b>	<b>78</b>
<b>Conclusiones .....</b>	<b>82</b>
<b>Referencias.....</b>	<b>84</b>

## Lista de ilustraciones

### Figuras

Figura 2.1. Proceso visual de estimación de la densidad de Kernel (KDE).....	31
Figura 2.2. Cubo espacio-tiempo .....	34
Figura 2.3. Smart mapping para smart city .....	39
Figura 2.4. Flujograma metodológico .....	42
Figura 3.1. Dashboard de delitos del sector La Mariscal .....	77

### Gráficos

Gráfico 2.1. Serie temporal de predicción basado en Random Forest .....	37
Gráfico 3.1. Calendario del crimen del año 2016 .....	43
Gráfico 3.2. Calendario del crimen del año 2017 .....	44
Gráfico 3.3. Calendario del crimen del año 2018 .....	45
Gráfico 3.4. Cantidad de delitos reportados en el año 2016 según su tipología .....	46
Gráfico 3.5. Cantidad de delitos reportados en el año 2017 según su tipología .....	46
Gráfico 3.6. Cantidad de delitos reportados en el año 2018 según su tipología .....	47
Gráfico 3.7. Cantidad total de delitos reportados en cada mes del año 2016.....	47
Gráfico 3.8. Cantidad total de delitos reportados en cada mes del año 2017.....	48
Gráfico 3.9. Cantidad total de delitos reportados en cada mes del año 2018.....	48
Gráfico 3.10. Delitos reportados según su tipología en cada mes del año 2016.....	49
Gráfico 3.11. Delitos reportados según su tipología en cada mes del año 2017 .....	49
Gráfico 3.12. Delitos reportados según su tipología en cada mes del año 2018.....	50
Gráfico 3.13. Delitos reportados por mes mediante polígonos de frecuencias del año 2016 ..	50
Gráfico 3.14. Delitos reportados por mes mediante polígonos de frecuencias del año 2017 ..	51
Gráfico 3.15. Delitos reportados por mes mediante polígonos de frecuencias del año 2018 ..	51

Gráfico 3.16. Delitos reportados por día de semana mediante gráfico de radar del año 2016.	52
Gráfico 3.17. Delitos reportados por día de semana mediante gráfico de radar del año 2017.	53
Gráfico 3.18. Delitos reportados por día de semana mediante gráfico de radar del año 2018.	54
Gráfico 3.19. Matriz de correlación de Spearman entre las variables explicativas .....	57
Gráfico 3.20. Visualización 3D del cubo espacio-tiempo de delitos del año 2016.....	63
Gráfico 3.21. Visualización 3D del cubo espacio-tiempo de delitos del año 2017.....	63
Gráfico 3.22. Visualización 3D del cubo espacio-tiempo de delitos del año 2018.....	64
Gráfico 3.23. Visualización 3D del cubo espacio-tiempo de delitos del año 2016, 2017 y 2018 .....	68
Gráfico 3.24. Valores de RMSE de predicción y validación del modelamiento de delitos en el sector La Mariscal .....	76

## Mapas

Mapa 2.1. Zona de estudio - La Mariscal.....	23
Mapa 2.2. Elipse de desviación estándar de robos .....	30
Mapa 3.1. Densificación de delitos del año 2016 por el método KDE .....	59
Mapa 3.2. Densificación de delitos del año 2017 por el método KDE .....	60
Mapa 3.3. Densificación de delitos del año 2018 por el método KDE .....	61
Mapa 3.4. Mapa de puntos calientes emergentes de delitos del año 2016.....	65
Mapa 3.5. Mapa de puntos calientes emergentes de delitos del año 2017.....	66
Mapa 3.6. Mapa de puntos calientes emergentes del año 2018 .....	67
Mapa 3.7. Predicción de delitos en enero del 2019.....	69
Mapa 3.8. Predicción de delitos en febrero del 2019 .....	70
Mapa 3.9. Predicción de delitos en marzo del 2019.....	70
Mapa 3.10. Predicción de delitos en abril del 2019 .....	71
Mapa 3.11. Predicción de delitos en mayo del 2019.....	71
Mapa 3.12. Predicción de delitos en junio del 2019 .....	72

Mapa 3.13. Predicción de delitos en julio del 2019 .....	72
Mapa 3.14. Predicción de delitos en agosto del 2019 .....	73
Mapa 3.15. Predicción de delitos en septiembre del 2019 .....	73
Mapa 3.16. Predicción de delitos en octubre del 2019.....	74
Mapa 3.17. Predicción de delitos en noviembre del 2019 .....	74
Mapa 3.18. Predicción de delitos en diciembre del 2019.....	75

## **Tablas**

Tabla 2.1. Listado y fuente de variables.....	24
Tabla 2.2. Información alfanumérica del registro de delitos en el sector “La Mariscal” .....	25
Tabla 2.3. Tipos de patrones espacio-temporales .....	35
Tabla 3.1. Prueba de hipótesis de la ocurrencia de delitos por su nivel de importancia entre las manzanas de La Mariscal en el año 2016, 2017 y 2018.....	54
Tabla 3.2. Prueba de hipótesis de la ocurrencia de delitos por su nivel de importancia entre determinados períodos de tiempo en el año 2016, 2017 y 2018 .....	55
Tabla 3.3. Prueba de hipótesis de la ocurrencia de delitos por su nivel de importancia entre los meses del año 2016, 2017 y 2018 .....	56
Tabla 3.4. Valor de significancia de los coeficientes del modelo de regresión lineal .....	58
Tabla 3.5. Análisis de la tasa de aciertos (TA), índice de precisión predictiva (PAI) e índice de tasa de recuperación (RRI) de los KDE .....	62

## Declaración de cesión de derecho de publicación de la tesis

Yo, Cristian Andrés Betancourt Lema, autor de la tesis titulada “Análisis de delitos en el barrio La Mariscal (Quito) desde perspectivas espacial, *machine learning* y de *smart city*”, declaro que la obra es de mi exclusiva autoría, que la he elaborado para obtener el título de maestría, concedido por la Facultad Latinoamericana de Ciencias Sociales, FLACSO Ecuador.

Cedo a la FLACSO Ecuador los derechos exclusivos de reproducción, comunicación pública, distribución y divulgación, bajo la licencia Creative Commons 3.0 Ecuador (CC BY-NC-ND 3.0 EC), para que esta universidad la publique en su repositorio institucional, siempre y cuando el objetivo no sea obtener un beneficio económico.

Quito, septiembre de 2023



Firmado electrónicamente por:  
CRISTIAN ANDRES  
BETANCOURT LEMA

---

Firma

Cristian Andrés Betancourt Lema

## Resumen

La delincuencia es un problema que afecta a la mayoría de ciudades de todo el mundo y especialmente a las urbes de América Latina donde los gobiernos de la región y diversas organizaciones internacionales han destinado fondos para elaborar programas orientados a reconstruir sectores marginados, proteger los derechos de las personas más vulnerables, mejorar la seguridad ciudadana y fomentar un desarrollo económico, político y social más inclusivo con el objetivo de contrarrestar el crimen y reducir los altos niveles de inseguridad. La presente investigación analiza la ocurrencia de delitos en el espacio-tiempo desde la *perspectiva espacial*, *machine learning* y de *smart city* en el sector La Mariscal que es conocida como la zona rosa más grande de la ciudad de Quito-Ecuador y se caracteriza porque mensualmente ha sido visitada por aproximadamente 200.000 turistas. Sin embargo, sus calles están marcadas por robos, ventas de drogas, microtráfico, riñas callejeras y prostitución, por lo que, desde el año 2013 la policía nacional y administradores de negocios han intentado implementar un plan de seguridad que permita a los residentes y turistas disfrutar de las opciones culturales que ofrece el centro norte de la ciudad.

El uso de tecnologías geo-espaciales permitió espacializar y depurar una base de datos de 505.724 incidentes del 2016, 2017 y 2018 con base a criterios técnicos (geo-localización) y legales (código orgánico integral penal) para disponer finalmente de 17.734 delitos que fueron considerados en el presente estudio, lo que permitió evaluar y contextualizar con estadística descriptiva la dinámica de delitos. Luego se generó una evidencia empírica con respecto a diferencias significativas en la ocurrencia de delitos entre manzanas, horas del día y meses en una zona que se caracteriza por ser un punto de encuentro para la diversión nocturna. Usando un modelo de regresión lineal por mínimos cuadrados se identificó que el número de cámaras de videovigilancia y lugares de ocio podrían explicar en un 95% la ocurrencia de delitos, mientras que no existe evidencia significativa que el arbolado urbano, tamaño poblacional y número de bloques constructivos sean considerados como atractores del crimen.

Por otro lado, las técnicas geo-informáticas combinadas con la minería de datos y aprendizaje automático permitieron avances significativos en el análisis delictivo de La Mariscal, pues se corroboró que la ocurrencia de delitos es dinámica en el espacio y tiempo y el entorno urbano brinda las condiciones requeridas para la criminalidad puesto que la mayoría de los patrones detectados están relacionados con *clusters* de tipo *HotSpot*. Además, para el 2019 la actividad delictiva se mantendrá en el epicentro de la zona de estudio, mientras que en otros sitios se intensificará según la temporalidad.

Finalmente, el *Dashboard* de delitos presenta beneficios en cada uno de los pilares de una *smart city* y podría convertirse en la piedra angular para promover la participación ciudadana en la lucha contra la inseguridad y mejorar la toma de decisiones en materia de prevención y gestión de la ciudad.

## **Agradecimientos**

Especial agradecimiento a Dios, a la Virgen y a mi familia por ser los pilares de mi vida en el ámbito personal y profesional.

Agradezco a la Facultad Latinoamericana de Ciencias Sociales (FLACSO) y a quienes pertenecen al programa de Estudios Urbanos con mención en Geografía y Procesos Territoriales por confiar en mi desempeño académico. Especialmente a mi director de tesis el Dr. Pablo Cabrera Barona, quién siempre estuvo dispuesto a ayudarme, guiarme y compartir todo su conocimiento para el éxito de mi proyecto de investigación.

Agradezco al Servicio Integrado de Seguridad ECU 9-1-1 por facilitarme toda la información necesaria para el desarrollo de mi tesis.

A todos mis amigos más cercanos, quienes han estado en las buenas y en malas, gracias porque todos sus consejos y palabras de aliento han influido en el éxito de mi trabajo de investigación.

## **Introducción**

### **Antecedentes**

Las ciudades de América Latina se encuentran entre las más inseguras del mundo. Por ejemplo, Muggah y Aguirre (2017) mencionan que en la región la tasa de crímenes es al menos tres veces mayor que el promedio mundial, nueve de los diez países más violentos del mundo fuera de las zonas de guerra se encuentran en América Latina y sus ciudadanos registran una mayor sensación de inseguridad.

Este panorama no es reciente, y así los países del sur global tienen una reputación de estar entre las regiones más propensas a la violencia, movimientos guerrilleros, narcotráfico, guerras civiles y dictaduras (Imbusch, Misse, y Carrión 2011). Los gobiernos latinoamericanos y diversas organizaciones internacionales, han diseñado una serie de políticas para contrarrestar el crimen, y reducir los altos niveles de inseguridad en la región. Por ejemplo, se han implementado duras intervenciones por parte de la policía y se han destinado fondos para elaborar programas orientados a reconstruir sectores marginados, proteger los derechos de las personas más vulnerables, mejorar la seguridad ciudadana y fomentar un desarrollo económico, político y social más inclusivo (Schultze-Kraft, Chinchilla, y Moriconi 2018).

Dammert (2015) argumentó que hasta finales de la década de 1990, las políticas de seguridad estaban centradas en la gestión policial, en definir un marco de actuación democrática, y en responder a los robos, hurtos, homicidios y violaciones de una forma particular. Sin embargo, el mismo autor reporta que los gobiernos de la región han optado por asumir un rol de promotor de estrategias encaminadas a la prevención del delito, con el objetivo de interrumpir organizaciones delictivas a través de una prevención situacional y un incremento en el patrullaje policial. En este contexto, la sociedad civil ha sido llamada a desempeñar un papel activo en la provisión de su propia seguridad, pero desafortunadamente su participación ciudadana se ha visto reducida por diversos factores. Por ejemplo, Scarlascini (2019) menciona que en América Latina la confianza de los ciudadanos en las políticas de seguridad es baja, y la razón es porque la ineficacia de los sistemas judiciales ha ocasionado una falta de credibilidad de la población en el marco institucional, incluida la policía (Reyna y Toche 1999).

Para contrarrestar la delincuencia, es necesario mejorar el sistema de justicia y control penal con un correspondiente aumento de la inversión pública, y además es fundamental involucrar

a diversos actores en la llamada coproducción de seguridad (Moreira 2016). Blanco y Tudela (2010) reconocen que la criminalidad es un fenómeno multidimensional influenciada por múltiples factores y los actores llamados a dar respuesta a esta problemática son diversos. En consecuencia, el control del delito por parte del Estado no es suficiente, sino que es fundamental un trabajo articulado entre el Estado y la población.

Según Chainey y Lazarus (2021), la delincuencia está relacionada con el tamaño de la población de delincuentes, la frecuencia con la que cada delincuente comete un delito y la duración de las carreras delictivas de los mismos. Sin embargo, existe una investigación limitada sobre estos factores en los entornos latinoamericanos y cómo explican los altos niveles de delincuencia en la región. Al examinar cómo la dinámica delictiva influye en las variaciones de los niveles delictivos, el primer paso que se debe tomar es determinar cuántas personas participan en el comportamiento criminal (Blumstein y Graddy 1981). Hasta lo que mejor conocemos, ningún estudio ha proporcionado detalles sobre el tamaño de la población de delincuentes en un entorno latinoamericano (Chainey y Lazarus 2021).

### **Justificación**

Brantingham y Brantingham (1984) definen a la ciudad desde un punto de vista criminológico como espacios llenos de delincuencia, enfermedades y conflictos. Y según Hashim et al. (2019), estas son características inevitables de las ciudades. Ante esta problemática diversos investigadores han enfocado sus estudios hacia temas relacionados con la criminalidad. Las publicaciones científicas buscan identificar correlaciones entre la tasa de delincuencia y la densidad poblacional, tasa de desempleo, problemas raciales, trabajos ilegales, entre otros. Sin embargo, muy pocas investigaciones han tomado en consideración aspectos espaciales de la ubicación de los incidentes delictivos (Singh 2005; Hashim et al. 2019).

Braga, Papachristos, y Hureau (2010) argumentaron que el análisis de puntos calientes del crimen, es una de las estrategias más efectivas por parte de la policía en contra de la delincuencia. A través del tipo de delito, la georreferenciación del incidente y la fecha/hora, se han generado mapas de calor aplicando métodos de densificación espacial (Eck, Chainey, y Wilson 2005). Una estrategia policial aún más efectiva que la anterior, podría ser la reubicación de agentes del orden público en zonas donde ocurrirán focos de delincuencia en el futuro, permitiendo mejorar el tiempo de respuesta y evitar la ocurrencia de delitos (Wheeler y Steenbeek 2020).

Es por esa razón que existe una elevada aceptación por parte de las fuerzas del orden público en aplicar modelos que predigan futuros delitos en micro-lugares de crimen (Perry et al. 2018). Las técnicas de *machine learning* (ML) se han utilizado para identificar espacialmente los delitos que tienen más probabilidades de ocurrir (Han, Kamber, y Pei 2012). Desde el punto de vista de criminalidad, existen muchos algoritmos de ML que se pueden implementar; los algoritmos aprenden más sobre la *data* a medida que se entrenan, todo ello con el objetivo de identificar los delitos que tienen más probabilidades de ocurrir (Suhong et al. 2018).

Según McClendon y Meghanathan (2015), las técnicas de predicción de delitos son útiles para visualizar redes delictivas, reducir riesgos y aumentar la productividad de los analistas de delito; para ello es fundamental mantener una base de datos del registro georreferenciado del crimen, y detalles relacionados con el lugar, tiempo y naturaleza del crimen.

La criminalidad es un problema que afecta a la mayoría de ciudades de todo el mundo y diversos estudios han encontrado una correlación directa entre el índice delictivo y la densidad poblacional (Vallejo y Villegas Barrientos 2018). Se estima que para 2030, el 70% de la población mundial vivirá en ciudades, por lo que, es fundamental elaborar planes que garanticen entornos urbanos seguros, sostenibles y con recursos eficientes (Kieu et al. 2019). Ante este panorama, a nivel mundial se ha empleado el término ciudades inteligentes o *smart cities*, el cual aprovecha las tecnologías de la información y las comunicaciones (TICs) para aumentar la eficiencia, reducir los costos y mejorar la calidad de vida de los ciudadanos (Falconer y Mitchell 2012).

Cabe recalcar que no existe una definición y clasificación universalmente aceptada de *smart cities* (Albino, Berardi, y Dangelico 2015), pero según la investigación Cohen (2013), los seis pilares de una ciudad inteligente son: (1) Economía inteligente, (2) Gobernanza inteligente, (3) Entorno inteligente, (4) Gente inteligente, (5) Movilidad inteligente y (6) Vida inteligente. Sin embargo, al no existir un marco claro que permita a los tomadores de decisiones comprender la gran cantidad de datos e información proveniente de los pilares de las *smart cities*, Loo and Tang (2019) proponen un Mapeo Inteligente, que además de interrelacionar la información de los 6 indicadores, mejore el uso de datos espacio-temporales y de las TICs, con el objetivo de reducir las tasas de delincuencia y aumentar la participación ciudadana en la seguridad pública.

En este contexto, la presente investigación emplea la perspectiva de *smart cities* propuesta por Loo y Tang (2019) y aplica técnicas de ML para predecir espacialmente zonas con alto riesgo

delictivo en el sector La Mariscal. El área de estudio es conocida como la zona rosa más grande de la ciudad de Quito, que mensualmente es visitada por aproximadamente 200.000 turistas (La Hora 2019). Sin embargo, sus calles están marcadas por robos de celulares, ventas de drogas, libadores, riñas callejeras y prostitución (Jácome 2019), por lo que, desde el año 2013; autoridades municipales, policía nacional y administradores de negocios (bares, discotecas y restaurantes) han intentado implementar sistemas de seguridad que permitan a los turistas disfrutar de las opciones culturales que ofrece el centro norte de la ciudad (Romero 2017).

Los Sistemas de Información Geográfica (SIG) brindan la facilidad de comprender la distribución geográfica de los delitos, ya que los mapas constituyen una poderosa herramienta para representar fenómenos criminológicos y establecer relaciones entre el espacio y el crimen (Owusu y Frimpong 2020). En la actualidad, las instituciones encargadas de la seguridad ciudadana usan los SIG para mapear patrones del crimen, georreferenciar eventos delictivos, realizar modelos de distribución del crimen en el espacio, cartografiar puntos críticos de delincuencia, entre otras acciones. Tal es el caso, que la aplicabilidad de los SIG y el análisis espacial, se han convertido en herramientas integrales de las organizaciones policiales (Hu et al. 2018).

Singh y Kumar (2022) argumentan que el mapeo de crímenes y la identificación de puntos calientes (*Hot-Spot*) son cruciales para contrarrestar el accionar criminal y mejorar la calidad de vida junto con el desarrollo sostenible del espacio urbano. Identificar puntos críticos y densificar áreas de criminalidad son insumos indispensables para analizar la distribución espacial y controlar los actos delictivos (Braga 2006).

La cartografía y análisis de delitos tienen un rol sumamente importante en los pilares fundamentales de una *smart city*, ya que permiten representar y visualizar el registro de crímenes y facilitar la toma de decisiones para plantear medidas más inteligentes para contrarrestar esta problemática. Según Panigrahi, Barik y Sahu (2021) los SIG posibilitan plantear soluciones inteligentes para ciudades inteligentes y sobre todo facilitan una función efectiva en el gestión del crimen.

### **Pregunta de investigación, objetivos y alcance**

En el presente estudio se formulan las siguientes preguntas de investigación: 1) ¿Cómo se concentra el delito en el barrio La Mariscal?, y 2) ¿Cómo se comportará el delito en el barrio La Mariscal?

Los objetivos de la investigación son: 1) analizar la concentración y patrones de delito, 2) evaluar la influencia de factores urbanos en el delito, 3) realizar análisis predictivo de crimen, 4) contrastar y reflexionar sobre los resultados obtenidos en función de presencia o ausencia de cámaras de vigilancia.

El alcance del estudio, se encamina a la identificación de zonas de alto riesgo delictivo en áreas urbanas y predecir de manera confiable las tendencias delictivas en el sector con herramientas geo-espaciales y técnicas de ML. El proceso metodológico se compone de varios pasos. En primer lugar, las áreas de alta densidad delictiva (puntos críticos de delincuencia) se descubren a través de un enfoque de análisis espacial. Posteriormente, se analiza la red de predicción de delitos específica que se ajuste a las variables de estudio. El resultado final, es un modelo de predictivo de delitos espacio-temporal y una cartografía que represente geográficamente las zonas con mayor susceptibilidad de incidentes criminales.

El análisis propuesto anteriormente, toma como caso de estudio el sector “La Mariscal”, que según la División Político Administrativa del DMQ tiene una superficie de aproximadamente 185 ha. Para el análisis predictivo de delitos, se utilizó el registro georreferenciado de incidentes del año 2016, 2017 y 2018 otorgado por el Servicio Integrado de Seguridad ECU 9-1-1 y se pretende modelar la ocurrencia de delitos en el espacio-tiempo del año 2019.

## **Capítulo 1. Revisión analítica de literatura**

### **1.1. Crimen urbano**

Todas las ciudades del mundo experimentan crímenes. No obstante, existen diversas zonas en las cuales la concentración de delitos es mayor en comparación a otros lugares en los que la cantidad de crímenes es menor (Kinney et al. 2008). Investigaciones de crímenes en la ciudad se remontan desde el siglo XIX, con estudios de Quetelet (1994) y Mayhew (1851), hasta principio del siglo XX con Shaw y McKay (1942) de la Escuela de Sociología de Chicago, y se extiende a trabajos más recientes como el de Brantingham y Brantingham (1984), Hirschfield, Bowers, y Brown (1995) y Felson (2006). Estos autores consideran al crimen como formas de actividad humana, que se desplazan en el espacio y se concentran en lugares de trabajo, escuelas, áreas comerciales, centro de diversión, suburbios etc.

Estos trabajos fueron pilares fundamentales para el desarrollo empírico e investigativo del crimen hasta el siglo XX. Para el año 1920 con el apoyo de la Universidad de Chicago, se realizó un cambio de paradigma dónde los estudios de esta área, no solo se enfocaban en analizar al delincuente, sino también abordaban el estudio de cómo la composición urbana puede influir en la criminalidad (Umar 2017).

Weisburd, Bruinsma, y Bernasco (2009) argumentan que los factores ambientales tienen una gran influencia en la ocurrencia de crímenes. Elliott (1997), identificó que los lugares donde se concentran familias con escasos recursos económicos y vecindarios desorganizados, son lugares susceptibles a la ocurrencia de actos de criminalidad, mientras que Michael, Hull, y Zahm (2001) en su estudio de factores ambientales que influyen en el robo de autos en Washington, DC, identificaron que el arbolado urbano propicia el cometimiento de actos criminales.

El crimen es un fenómeno multidimensional que para ser comprendido debe analizarse desde un enfoque multidisciplinario. Por ejemplo, los entornos urbanos cambian rápidamente, sobre todo cuando experimentan una inversión y afluencia de nuevos residentes con mayores recursos por la gentrificación del espacio (Hwang and Lin 2016). Por sí solo, este fenómeno atrae a residentes de clase media a alta por las oportunidades laborales, precios accesibles de viviendas, nuevos servicios urbanos (cafeterías, restaurantes, unidades bancarias) y reducción de condiciones sociales negativas como la delincuencia. Según Schnake-Mahl et al. (2020) uno de los principales beneficios de la gentrificación es la disminución de las tasas de criminalidad.

Por el contrario, autores como Van Welsem, Wittebrood, y De Graaf (2006) encontraron que la gentrificación aumenta a corto plazo los niveles de delincuencia, debido a la alteración del orden local y ruptura de la cohesión social entre los nuevos y originales residentes. Por consiguiente, la forma en cómo se manifiesta el crimen puede variar según la zona de estudio.

Las obras clásicas de la Escuela de Chicago contribuyeron a entender el delito desde la perspectiva de las ciencias sociales, motivando a los investigadores a realizar un cambio de enfoque para estudiar el crimen urbano. Es decir, ya no solo se analiza al delincuente, sino que se considera la composición del entorno y su influencia en la delincuencia urbana. Según Andresen (2006), en el año 1929 sucedió un hito en el estudio de este fenómeno social, porque se encontró una correlación entre la tasa de delincuencia y características de los vecindarios en la ciudad de Chicago, Estados Unidos.

En otras palabras, para entender el crimen urbano es necesario considerar todos los elementos que influyen en la ocurrencia del mismo. Por ejemplo, características del agresor y la víctima, espacio urbano, temporalidad y cualquier variable que propicie los actos delictivos (Umar 2017).

## **1.2. Análisis espacial del crimen**

El análisis espacial del crimen es un conjunto de métodos utilizados para comprender los patrones espaciales de la delincuencia. Es un método geográfico que se ha convertido en una herramienta fundamental para las instituciones que están a cargo de mantener el control en los espacios públicos y la seguridad ciudadana (Inlow 2021).

El desarrollo del análisis espacial en la criminología se atribuye a la necesidad de estudiar la relación entre la ocurrencia del crimen y el lugar (Peet 1975), lo que dio paso a un conjunto de reflexiones e investigaciones sobre la geografía aplicada, que sería bautizada a priori como la *New Geography* o Geografía Cuantitativa, la misma que está basada en la formulación matemática y modelamiento espacial (Lacoste 1990).

A finales del siglo XX, era evidente el interés por comprender la relación entre el crimen y el lugar. Así lo detallan Sherman, Gartin, y Buerger (1989), y además los resultados de su investigación fueron fundamentales para generar un punto de inflexión para volver a centrar las investigaciones en torno a las características espaciales del crimen. Este interés abarca en cómo el lugar es un factor del crimen, ya sea influyendo o atrayendo a personas con inclinaciones delincuenciales.

Los avances tecnológicos fueron fundamentales en el desarrollo de técnicas y análisis de delitos basados en el lugar. El advenimiento de los Sistemas de Información Geográfica (SIG) en esta área de las ciencias sociales, permitieron representar las relaciones espaciales de los datos de crimen. Tal es su aplicabilidad, que hoy en día los SIG son herramientas muy utilizadas y demandadas en las oficinas de policías locales. Desde la década de los 70 del siglo XX, Ronald Horvath durante 20 años capacitó a personal policial de Sydney en SIG y delincuencia, teniendo como resultado a largo plazo que cada estación de Australia cuente como mínimo con un agente que realice análisis espacial y cartografía del crimen (Bunge 2017).

Las capacidades que ofrecen los SIG han apoyado significativamente en el análisis del crimen basado en el lugar y en la elaboración de matrices de contigüidad para representar las relaciones de vecindad entre diferentes unidades de área (Getis et al. 2000). Por ejemplo, el Departamento de Justicia de los Estados Unidos utiliza técnicas avanzadas SIG y cartografía para examinar y analizar el crimen espacialmente e identificar las zonas con altas densificación de delitos (Eck et al. 2005). Según Badurek (2007), los SIG se han posicionado a la vanguardia, ya que estas herramientas permiten mejorar la comprensión de los patrones espaciales del crimen y sus causas subyacentes.

### **1.3. *Machine learning* y crimen**

Arthur Samuel fue pionero en el campo del *machine learning* (ML) e inteligencia artificial, y consideraba que estas técnicas brindan la oportunidad a las computadoras de aprender sin la necesidad de ser programadas para esa actividad (McCarthy y Feigenbaum 1990). Existen diversos algoritmos de ML para entrenar grandes cantidades de datos, y en general, se los puede clasificar en 1) aprendizaje supervisado y 2) aprendizaje no supervisado. En esencia, el primer grupo trabaja infiriendo información a partir de datos de entrenamiento etiquetados, y el segundo tipo de algoritmos aprende más del conjunto de datos a medida que se incluya más información (Mcclendon y Meghanathan 2015).

Las técnicas de ML se han utilizado en diferentes áreas de la ciencia como pronóstico del clima, finanzas, inteligencia de negocios y criminología. En este último, debido a la variedad de tipos de delitos, métodos de manejo y técnicas de prevención del crimen, los algoritmos de ML se han convertido en herramientas poderosas y ampliamente utilizadas por brindar facilidades para el análisis de grandes cantidades de datos y extracción inmediata de patrones delictivos (Feng et al. 2019). Además, los datos georreferenciados del crimen han sido

insumos fundamentales para aplicar algoritmos de ML, ya que han permitido entrenar modelos precisos de predicción del crimen (Iqbal et al. 2013). Según Toppireddy, Saini, y Mahajan (2018) la ubicación geográfica juega un rol importante en los modelos predictivos, ya que existen áreas con alta y baja ocurrencia de delitos.

Desde año 2013, Berk y Bleich reportaban que existe literatura científica que ilustra varios modelos de ML orientados a la predicción de delitos. Otras investigaciones como las de Rummens, Hardyns, y Pauwels (2017), Hipp, Kane, y Kim (2017), y Mohler y Porter (2018), han empleado inteligencia artificial para modelar comportamiento del crimen basados en la geolocalización.

Bandekar y Vijayalakshmi (2020) mencionan que diversos son los algoritmos de ML que se pueden emplear para análisis de crimen, como *k-means clustering* (Kadhim y Swadi 2011), *naïve bayesian* y *back propagation* (Babakura, Sulaiman, y Yusuf 2014), *support vector machine* (Premalatha y Vijayalakshmi 2015), *k-nearest neighbour* (Sivaranjani, Sivakumari, y Aasha 2017), *random forest* (Wheeler y Steenbeek 2020) entre otros.

Realizar modelos de predicción del crimen de manera manual implica una gran cantidad de tiempo y recursos, por lo que, las técnicas de ML reducen dicho esfuerzo y además permiten extraer patrones del crimen y predecir eventos futuros (Dakalbab et al. 2022). Esta es una aplicación de la vida real, por lo que, diversos investigadores y departamentos de policía han priorizado la construcción de modelos de inteligencia artificial que sean interoperables, interpretables y transparentes (Vinuesa y Sirmacek 2021).

#### **1.4. Smart city**

Desde el siglo XX en los centros urbanos, han comenzado a surgir dos tendencias importantes, la urbanización y las tecnologías de la información y comunicación (TICs). Según Caragliu, Bo, y Nijkamp (2011), desde los años 80 y 90 el avance tecnológico, crecimiento económico y bienestar social que ofrecen los centros urbanos, han sido detonantes para los procesos migratorios del campo a la ciudad, lo que ha generado efectos positivos como diversidad cultural, creación de nuevas fuentes de empleo y dinamización de la economía local. Por otro lado, los efectos negativos pueden ser la sobrepoblación, aumento de la contaminación ambiental y gases de efecto invernadero (Cocchia 2014). Ante este panorama, nace la idea de *smart city*, es decir, ciudades que tengan la capacidad de resolver problemas urbanos tomando en consideración el medio ambiente (Nam y Pardo 2011).

A nivel internacional, instituciones como la Comisión Europea y la Organización para la Cooperación y el Desarrollo Económicos (OCDE) adoptaron el término *smart city* para lograr cumplir los objetivos establecidos en el Protocolo de Kioto sobre cambio climático (Cocchia 2014) . Por lo general, el término *smart city*, está relacionado con iniciativas de ciudades sostenibles, progreso de la calidad de vida, implementación y uso de las TICs, participación ciudadana en la gestión pública y reducción brecha digital (Bouskela et al. 2016). Es decir, *smart city* se refiere a un territorio dotado con tecnología, que tenga la capacidad de innovación, creatividad, investigación y que se ajuste a la teoría de sostenibilidad (Fernández 2017). Según Loo y Tang (2019) y Cocchia (2014), cada vez más el término *smart city* es más recurrente en artículos científicos, pero pocas veces se aclara un significado que sea universalmente aceptado.

En la última década el término *smart city* ha sido el foco de atención en todo el mundo, debido un exponencial crecimiento poblacional y disminución de recursos naturales (Eremia, Toma, y Sanduleac 2017), ya que la forma de gestionar las ciudades ha cambiado hacia un modelo más eficiente y por tanto más inteligentes en cuanto al aprovechamiento de los recursos disponibles y uso de nuevas tecnologías (Maestre Góngora 2015). Se proyecta que más del 60% de la población mundial vivirá en áreas urbanas para el año 2030 y actualmente las ciudades representan más del 70 % del consumo mundial de energía y emisiones de gases de efecto invernadero (Ritchie y Roser 2018).

Según Vidal Tejedor (2015) una *smart city* se define por la capacidad de brindar soluciones a las problemáticas antes mencionadas y crear oportunidades para transformar las ciudades en lugares habitables para los ciudadanos.

El término *smart city* también se asocia con una ciudad moderna que utiliza las TICs y un sinnúmero de tecnologías para mejorar la calidad de vida de las personas, la productividad y la eficiencia de los servicios urbanos. De la misma manera, asegura que los recursos sociales, económicos y ambientales se encuentren disponibles para las generaciones actuales y futuras (Kumar et al. 2020).

Varios académicos y expertos argumentan que una *smart city* no se define solamente por la tecnología, ya que involucra procesos, tecnologías y personas. Según Cabrera-Barona y Merschorf (2018), la tecnología es una de las dimensiones de la *smart city*, pero no es la primordial. Más bien consideran a la comunidad humana como un factor principal, ya que una

sociedad inteligente es equivalente a una ciudad inteligente porque son ciudadanos educados que están comprometidos y tienen el conocimiento para construir una *smart city*.

En general el término de Ciudad Inteligente abarca 6 pilares fundamentales que son: Economía Inteligente, Gente Inteligente, Gobernanza Inteligente, Movilidad Inteligente, Entorno Inteligente y Vida Inteligente (Deloitte 2015).

La seguridad ciudadana ocupa un rol fundamental en cada uno de los pilares de una *smart city* (Colado et al. 2014). Dentro de este contexto, los elementos más relevantes para la gestión de la seguridad son los datos e información que se puede obtener de una ciudad que presenta en su infraestructura tecnológica redes de sensores hiperconectados y sistemas de seguridad. Por ejemplo, Truntsevsky et al. (2018) utilizan una aplicación móvil que se asocia con un SIG para identificar espacialmente los niveles de criminalidad y concentración de los delitos, con el objetivo que los ciudadanos puedan conocer áreas seguras de la ciudad y si fuese necesario modificar su ruta para evitar cualquier evento adverso que atente contra su integridad.

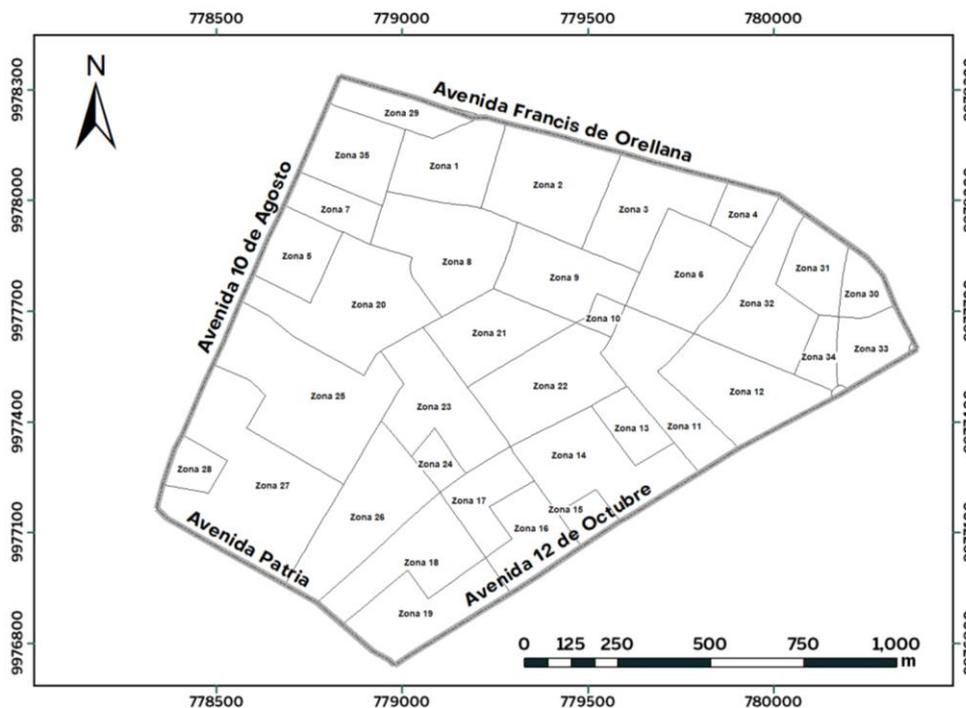
Las ciudades inteligentes están concebidas para optimizar recursos, mantener la sostenibilidad y mejorar la calidad de vida de las personas. Por ende, muchas tecnologías urbanas se han empleado para convertir ciudades en una *smart city*. Sin embargo, la tecnología geoespacial no ha sido examinada a profundidad en este ámbito, ya que no se ha considerado la importancia y la aplicabilidad de la geolocalización y las plataformas de mapas en contra de la criminalidad y en consecuencia, para beneficiar los 6 pilares de una ciudad inteligente, lo que facilitan la participación ciudadana, apoyando a la comunidad a mejorar su capacidad para construir comunidades informadas y sobre todo posibilitando una gobernanza inteligente (Loo y Tang 2019; Cabrera-Barona y Merschdorf 2018).

## Capítulo 2. Metodología

### 2.1. Área de estudio

La zona de estudio de la presente investigación corresponde al sector La Mariscal y está delimitada por la Avenida Francisco de Orellana (N), Avenida Patria (S), Avenida 10 de agosto (O) y la Av. 12 de octubre (E), con una superficie de aproximadamente 185 ha.

#### Mapa 2.1. Zona de estudio - La Mariscal



Elaborado por el autor con base a datos de Gobierno Abierto (2021)

Para realizar el análisis estadístico del crimen en el sector “La Mariscal”, se utilizó la información proporcionada por el Servicio Integrado de Seguridad ECU 9-1-1 (SIS ECU 9-1-1), institución pública encargada de gestionar todas las emergencias reportadas por los ciudadanos a nivel nacional a través de un número único y las que se generan por unidades de videovigilancia.

La información proporcionada corresponde al registro de incidentes georreferenciados del año 2016, 2017 y 2018 que se han suscitado en el Distrito Eugenio Espejo. Aproximadamente se analizaron 505.724 emergencias, de las cuales se excluyeron aquellos incidentes que no se localizaban geográficamente en la zona de estudio. Paso seguido, se eliminó del análisis las emergencias que no son consideradas como delitos y se corrigió la información alfanumérica de la base datos. Por último, los tipos de delitos fueron parametrizados y estandarizados.

Teniendo como resultado de este proceso de análisis y depuración de la información un total de 17.734 delitos que fueron considerados para esta investigación.

El análisis de densificación, autocorrelación y predicción de delitos con técnicas espaciales y de *machine learning* se realizaron con base a los 17.734 delitos que se obtuvieron como producto del proceso metodológico descrito en el apartado anterior. Además, se tomó en consideración variables geográficas que pueden ser consideradas como atractores y detractores de delitos: lugares de ocio, arbolado urbano, tamaño poblacional, bloques constructivos, cámaras de videovigilancia, entre otros.

## 2.2. Variables e Indicadores

El marco metodológico está diseñado desde un enfoque cuantitativo y socio-espacial, para ello, fue fundamental el uso de la siguiente información:

**Tabla 2.1. Listado y fuente de variables**

Dimensión	Variable	Indicador	Escala	Fuente
<b>Crimen Urbano</b>	Registro multitemporal de delitos	Número de crímenes/zona	1:1000	Servicio Integrado de Seguridad ECU 9-1-1
		Número de crímenes/m <sup>2</sup>		
<b>Físico-Ambiental</b>	Lugares de ocio	Número de lugares ocio/zona	1:500	Cueva (2022)
	Arbolado urbano	Número de árboles/zona	1:500	Autor
	Bloques constructivos	Número de edificaciones/zona	1:1000	Dirección Metropolitana de Catastros-DMQ
	Cámaras de videovigilancia	Número de cámaras de videovigilancia/zona	1:1000	Servicio Integrado de Seguridad ECU 9-1-1
<b>Socioeconómica</b>	Población Total	Número de personas/zona	1:1000	Dirección Metropolitana de Catastros-DMQ

Elaborado por el autor

## 2.3. Métodos

Para desarrollar la presente investigación, se emplearon métodos cuantitativos y socioespaciales. Según Wuschke, Henning, y Stewart (2022), el modelamiento del delito es un proceso complejo que requiere ser analizado desde puntos de vista multidisciplinarios, ya que numerosos son los factores que influyen en la ocurrencia de este fenómeno social. Por tal motivo, en principio, se evaluó la estadística espacial y no-espacial de delitos, correlaciones entre las variables. Y por último, se aplicó técnicas geo-informáticas y algoritmos de inteligencia artificial para predecir el comportamiento del crimen y con ello proponer un mapeo inteligente desde la perspectiva de *smart city* (Loo y Tang 2019).

### 2.3.1. Estadística descriptiva de los delitos

La información depurada de delitos con la que se trabajó en este apartado presenta la siguiente estructura:

**Tabla 2.2. Información alfanumérica del registro de delitos en el sector “La Mariscal”**

Año	Mes	Fecha	Longitud	Latitud	Turno	Delito	Clave
2016	Enero	2016-01-24	-78,49	-0,21	22h00 a 06h00	Robos	Clave Roja
2016	Enero	2016-01-08	-78,49	-0,20	22h00 a 06h00	Maltrato Animal	Clave Naranja
:	:	:	:	:	:	:	:
2017	Enero	2017-01-23	-78,49	-0,20	22h00 a 06h00	Secuestro	Clave Roja
2017	Enero	2017-01-13	-78,48	-0,20	06h00 a 14h00	Hurto	Clave Roja
:	:	:	:	:	:	:	:
2018	Enero	2018-01-05	-78,48	-0,20	14h00 a 22h00	Violación	Clave Roja
2018	Enero	2018-01-05	-78,48	-0,20	14h00 a 22h00	Venta Drogas	Clave Roja
2018	Enero	2018-01-31	-78,49	-0,20	22h00 a 06h00	Maltrato Animal	Clave Naranja
:	:	:	:	:	:	:	:

Elaborado por el autor con base a datos del SIS ECU 9-1-1

Para realizar este análisis se utilizó la información depurada de delitos en el software estadístico R.

El primer paso fue filtrar la información y realizar un análisis particular de los incidentes según su temporalidad en los siguientes rangos:

- 1-enero-2016 al 31-diciembre-2016
- 1-enero-2017 al 31-diciembre-2017
- 1-enero-2018 al 31-diciembre-2018

Se utilizó esta temporalidad, ya que períodos extensos de tiempo permiten garantizar que los modelos capturen la dinámica de delitos a largo plazo. Los análisis que se basan en lapsos de tiempo muy cortos corren el riesgo de omitir las tendencias que se originan a corto y mediano plazo (Campedelli, Serena, y Piquero 2020).

En este estudio la medida de tendencia central usada fue la moda, con lo que se identificó los tipos de delitos que se repiten con mayor frecuencia.

### **2.3.2. Significancia estadística y prueba de hipótesis**

La significancia estadística se relaciona con la necesidad de probar hipótesis. Esta idea fue introducida en los estudios de Ronald Fisher en la década de 1930, para identificar si sus hallazgos podrían ser causales o no. La significancia estadística típicamente es evaluada mediante el valor- p (Llobell et al. 2000).

El valor-p mide la probabilidad de que cualquier diferencia observada entre grupos se deba al azar y se fundamenta con base al supuesto de no diferencia (hipótesis nula), de obtener un resultado igual o más extremo que el observado. Al ser una probabilidad, puede tomar cualquier valor entre 0 y 1. Mientras más cercano sea el valor-p a 0, esto significa baja la probabilidad de que la diferencia observada se deba al azar, y mientras más cercano sea el valor-p a 1, esto sugiere que no existe diferencia significativa entre los grupos más que lo debido al azar (Dahiru 2008).

Fisher sugirió un valor-p  $< 0.05$  (5% significación) como valor de referencia para concluir que hay evidencia contra la hipótesis probada. Cabe recalcar que no es una regla absoluta. Neyman y Pearson propusieron las pruebas de Hipótesis, con dos hipótesis (Sterne y Smith 2001):

$$\left\{ \begin{array}{l} \text{Hipótesis Nula } (H_0): \quad \text{Normalmente un enunciado de efecto nulo} \\ \text{Hipótesis Alternativa } (H_1): \quad \text{Normalmente lo contrario a } H_0 \end{array} \right.$$

Para trabajar con pruebas de Hipótesis se deben seguir los siguientes pasos:

1. Plantearse una Hipótesis Nula ( $H_0$ ) e Hipótesis Alternativa ( $H_1$ )
2. Determinar un estadístico de prueba bajo el supuesto que  $H_0$  es verdadera
3. Especificar el valor crítico bajo el supuesto que  $H_0$  es verdadera
4. Calcular el estadístico de prueba a partir de los datos

Para realizar pruebas de significación estadística se deben plantear las hipótesis de la siguiente manera (Gómez, Vivo, y Soria 2001):

$$\left\{ \begin{array}{l} H_0: \text{No hay diferencias significativas entre las muestras comparadas} \\ H_1: \text{Hay diferencias significativas} \end{array} \right.$$

Generalmente el umbral de decisión es de 0.05, y se acepta  $H_0$  si  $p > 0.05$  mientras que se rechaza la  $H_0$  si  $p < 0.05$

Con la finalidad de identificar diferencias significativas entre los grupos de datos. Se debe considerar la jerarquización de cada delito. Esto se puede obtener a través del tipo de alerta que se detallan a continuación desde el incidente con importancia extrema hasta el moderadamente más importante (Changoluisa 2021):

- Rojo: Es todo incidente donde hay un riesgo urgente
- Naranja. Es todo incidente que no tiene amenaza y/o afectación a la población
- Amarillo. Es todo incidente donde hay una urgencia con menor preferencia
- Verde. Es todo incidente donde existe una urgencia relativa con una menor preferencia y por ende no requiere de atención inmediata

Y a través de la prueba estadística no paramétrica Kruskal-Wallis, se determinó si existe diferencias significativas de delitos en manzanas del sector La Mariscal, en horarios del día (6h00-14h00; 14h00-22h00; 22h00-6h00), y años (2016-2017-2018), entre todos los delitos según su nivel de importancia (Rojo-Naranja-Amarrillo y Verde).

### 2.3.3. Correlaciones y regresiones

La correlación es una medida de asociación entre 2 o más variables, y su valor puede variar desde -1 (asociación negativa perfecta), 0 (sin asociación) hasta +1 (asociación positiva perfecta). En el estudio de correlaciones, todas las variables se tratan por igual ya que ninguna se considera como un predictor. Mientras que la regresión consiste en generar un modelo matemático que indica la correlación entre las variables y además considera que una variable es un resultado y las otras variables son predictores (Crawford 2006). En otras palabras, mide la influencia de las variables independientes en la variable dependiente.

Los modelos de regresión lineal simple presentan la siguiente estructura:

$$Y_1 = \beta_0 + \beta_1 X_1 + e_1 \quad Ec. 1$$

Dónde:

$\beta_0$  es la ordenada en el origen o interceptor

$\beta_1$  es el coeficiente de pendiente del modelo

$e_1$  es el residuo o error

$X_1$  variable independiente

$Y_1$  variable dependiente

El modelo de regresión simple anterior se puede extender a regresión multivariada (más de una variable independiente). Con base a los estudios de Cueva (2022), Escobedo et al. (2018), Hashim et al. (2019), Zahnow y Corcoran (2019) y Sánchez (2016) se planteó la siguiente regresión:

$$Y_1 = B_0 + B_1 X_1 + B_2 X_2 + B_3 X_3 + B_4 X_4 + B_5 X_5 + e_1 \quad Ec. 2$$

Dónde:

$Y_1$  es la variable delitos

$\beta_0$  es la ordenada en el origen

$B_1, B_2 \dots B_5$  son los coeficientes de las variables independientes

$X_1$  es la variable lugares de ocio

$X_2$  es la variable arbolado urbano

$X_3$  es la variable bloques constructivos

$X_4$  es la variable cámaras de videovigilancia

$X_5$  es la variable de población total

$e_1$  es el residuo o error

A partir de la Ecuación 2 se identificó las variables independientes que podrían explicar a la dependiente. El modelo aplicado fue una Regresión Lineal por Mínimos Cuadrados.

### 2.3.4. Patrones espaciales y temporales de los delitos

Hart y Zandbergen (2014) argumentan que los puntos calientes o *Hot-Spots* de delitos son áreas dónde se concentran los incidentes delictivos con un patrón no aleatorio en el espacio-tiempo. Existe una gran variedad de técnicas estadísticas para identificar geográficamente puntos críticos de delincuencia, pero los 2 métodos más utilizados se basan en delitos agregados y análisis de ubicaciones de eventos delictivos.

El método de delitos agregados tiene como objetivo la generación de una cuadrícula en la cual se realicen pruebas de asociación espacial. Las dos pruebas más comunes son:

- I de Moran Local: Es una medida de autocorrelación espacial, su metodología se basa en el cálculo para cada unidad de área en función de los recuentos de delitos agregados, ponderados por una matriz espacial (Bivand y Wong 2018). Su fórmula de cálculo es la siguiente:

$$I_i = \frac{x_i - \bar{X}}{\frac{\sum_{j=1, j \neq i}^n w_{ij}}{n-1}} \sum_{j=1, j \neq i}^n w_{i,j} (x_j - \bar{X}) \quad Ec. 3$$

Dónde:

$I_i$  es el valor de I de Moran Local

$x_i$  es un atributo para la característica  $I$

$\bar{X}$  es la media del atributo correspondiente,

$w_{ij}$  es el peso espacial entre las características  $i$  y  $j$

$n$  es el número total de elementos

- $G_i^*$  de Getis-Ord: Para ser considerado como punto caliente estadísticamente significativo, es necesario que una entidad tenga un alto valor y además esté rodeada por otras

entidades con valores altos (Esri 2005). La fórmula de cálculo está definida de la siguiente manera:

$$G_i^* = \frac{\sum_{j=1}^n w_{i,j} x_j - \bar{X} \sum_{j=1}^n w_{i,j}}{S \sqrt{\left[ n \sum_{j=1}^n w_{i,j}^2 - \left( \sum_{j=1}^n w_{i,j} \right)^2 \right]}} \quad Ec. 4$$

$$\bar{X} = \frac{\sum_{j=1}^n x_j}{n} \quad Ec. 5$$

$$S = \sqrt{\frac{\sum_{j=1}^n x_j^2}{n} - (\bar{X})^2} \quad Ec. 6$$

Dónde:

$G_i^*$  es el estadístico  $G_i^*$  de Getis-Ord (puntuación z)

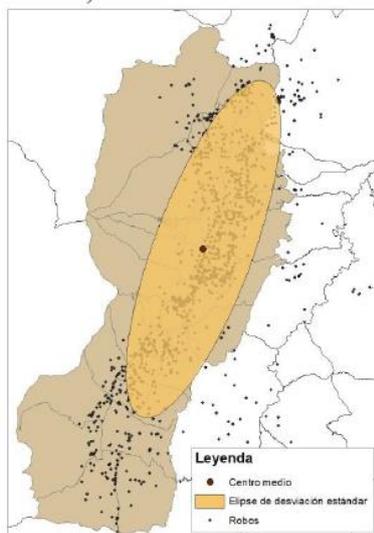
$x_j$  el valor del atributo para la característica  $j$

$w_{i,j}$  es el peso espacial entre la característica  $i$  y  $j$

$n$  es igual al número total de características

El segundo método empleado para la detección de puntos críticos de delincuencia está relacionado con los patrones espaciales. El objetivo de este proceso metodológico es identificar la localización de eventos delictivos discretos agrupados espacialmente. Y los resultados son áreas definidas geoméricamente como elipses o cascos convexos.

### Mapa 2.2. Elipse de desviación estándar de robos

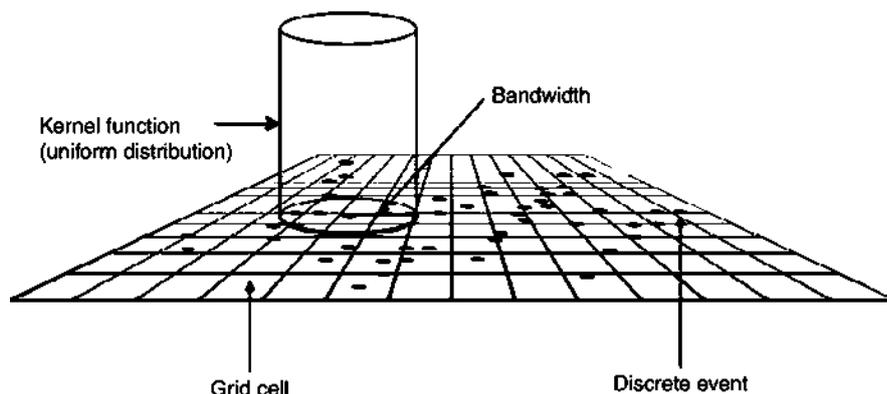


Fuente: Cueva (2022)

En los últimos años, diversos investigadores han propuestos otros enfoques para elaborar modelos que permitan identificar con certeza patrones espaciales del crimen (Hart y Zandbergen 2014). Chainey, Tompson, y Uhlig (2008) demostraron que la Estimación de Densidad de Kernel (KDE, por sus siglas en inglés) producen resultados que son más precisos desde el punto de vista predictivo que otros enfoques.

El proceso de KDE se basa en estimar la densidad de delincuencia en un área de estudio bidimensional en función de la localización de los eventos delictivos. El primer paso es generar y sobreponer una cuadrícula de n celdas sobre la zona de estudio. A continuación, se calcula una estimación de densidad basada en los puntos centrales de la cuadrícula. Por último, las distancias entre los incidentes y los centros de cuadrícula se ponderan en función del método de interpolación y ancho de banda (Hart y Zandbergen 2014).

**Figura 2.1. Proceso visual de estimación de la densidad de Kernel (KDE)**



Fuente: Hart y Zandbergen (2014)

El KDE en una nueva ubicación (X,Y) se determina con la siguiente fórmula:

$$Density = \frac{1}{(radio)^2} \sum_{i=1}^n \left[ \frac{3}{\pi} * pop_i * \left( 1 - \left( \frac{dist_i}{radio} \right)^2 \right)^2 \right] \quad Ec. 7$$

Dónde:

$i$  es los puntos de entrada. Pero solos se incluyen los registros que están geográficamente dentro de la distancia del radio de búsqueda

$pop_i$  es el valor de campo de población del punto  $i$  (opcional)

$dist_i$  es la distancia entre el punto  $i$  y la ubicación (X,Y)

Diversos estudios han sugerido varias reglas para el cálculo de la densidad de kernel. ArcGIS es uno de los softwares SIG que incorpora en sus geo-procesamiento el análisis de KDE y trabaja de la siguiente manera para definir el tamaño de celda y estimar el ancho de banda por defecto (Esri 2022c).

- El tamaño de celda se calcula a partir del ancho o alto del área de estudio dividido por 250.
- El radio de búsqueda se calcula con base a la variante espacial de la regla de oro de Silverman:

$$h = \left( \frac{4\sigma^5}{3n} \right)^{1/5} \quad Ec. 8$$

Dónde:

$\sigma$  es la desviación estándar de los puntos muestreados

$n$  es el número de puntos muestreados

Los beneficios de trabajar con el método de Silverman es por su resistencia a valores atípicos espaciales y puntos que están dispersos del resto de registros georreferenciados (Esri 2022c).

Chainey, Tompson, y Uhlig (2008) y Drawve (2014) evaluaron la precisión predictiva de la información resultante del KDE a través de la siguiente tasa e índices:

- Tasa de aciertos (TA): Es el porcentaje (%) de los delitos suscitados en un período de tiempo (t+1) que se encuentran localizados dentro de los puntos críticos calculados con base a un período de tiempo t. Su fórmula de cálculo es la siguiente:

$$TA = \frac{n_H}{N_C} \quad Ec. 9$$

Dónde

TA es la Tasa de aciertos

$n_H$  es el número de delitos en un período de tiempo (t+1) que se localizan en los *Hot-Spots* calculados con base un tiempo (t)

$N_C$  es el número total de delitos en un período de tiempo (t+1)

- Índice de precisión predictiva (PAI, por sus siglas en inglés): Es la relación entre la tasa de aciertos y el porcentaje del área y se utiliza para evaluar las predicciones. Mientras más alto sean los valores de PAI indica una mayor precisión predictiva.

$$PAI = \frac{\frac{n_h}{N_c}}{\frac{a_h}{A_s}} \quad Ec. 10$$

Dónde

*PAI* es el Índice de precisión predictiva

$n_h$  es el número de delitos que se localizan en los *Hot-Spots* predichos

$N_c$  es el número total de delitos en un período de tiempo (t)

$a_h$  es el área de los *Hot-Spots*

$A_s$  es el área total del área de estudio

- Índice de tasa de recuperación (RRI, por sus siglas en inglés): Mide si los puntos críticos delictivos se están volviendo más o menos densos entre los tiempos t y t+1. Las puntuaciones RRI = 1 indican un cambio proporcional en los delitos que se localizan en los *Hot-Spots* en relación con el cambio general en el volumen de delincuencia dentro de la zona de estudio. En cambio las puntuaciones RRI <1 se refieren a una disminución en la precisión de los *Hot-Spots* (White, Hunt, y Green 2022; Hart and Zandbergen 2014).

$$RRI = \frac{\frac{\binom{n_2}{N_2}}{\binom{n_1}{N_1}}}{\frac{\binom{a_2}{A}}{\binom{a_1}{A}}} \quad Ec. 11$$

Dónde

*RRI* es el Índice de tasa de recuperación

$n_2$  es el número de delitos que se localizan en los *Hot-Spots* en un período de tiempo t+1

$n_1$  es el número de delitos que se localizan en los *Hot-Spots* en un período de tiempo definido

t

$N_2$  es el número total de delitos en un período de tiempo (t+1)

$N_1$  es el número total de delitos en un período de tiempo (t)

$a_2$  es el área de los *Hot-Spots* en un período de tiempo (t+1)

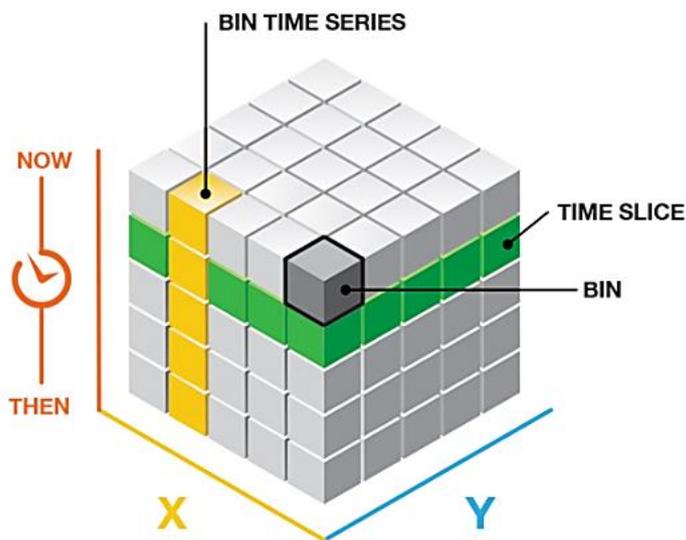
$a_1$  es el área de los *Hot-Spots* en un período de tiempo (t)

A es el área total de la zona de estudio

La minería de patrones espacio-temporales corresponde al agrupamiento espacial de tendencias temporales. Esta metodología permite identificar espacialmente puntos calientes y puntos fríos del crimen y patrones de delitos en términos de tendencias persistentes, decrecientes e intensivas en un área de estudio (Saraiva et al. 2022; Lal et al. 2023).

Para identificar estos patrones es necesario crear un cubo espacio-tiempo con dimensión (x,y) y una dimensión temporal (t). El mismo, está compuesto por un *bin* que es cualquier punto espacial en un tiempo (t), el *bin time-series* representa la serie temporal de cualquier ubicación. Mientras que *time-slice* es una instantánea del conjunto de datos espaciales.

**Figura 2.2. Cubo espacio-tiempo**



Fuente: Esri (2022a)

Según Lal et al. (2023) y Hägerstraand (1970) la metodología para trabajar con minería de patrones espacio-temporales es la siguiente:

- Crear un cubo espacio-tiempo

- Cada *bin* en un intervalo de tiempo (*time-slice*) se le asigna a un grupo de puntos calientes o puntos fríos según la estadística  $G_i^*$  de Getis-Ord con base a un umbral. Esta medida estadística toma en consideración los *bin* vecinos teniendo como resultado valores  $z$ . La puntuación  $z$  es la medida que permite clasificar a los *bin* en grupos de *Hot-Spot* o *Cold-Spot*. Este proceso se repite en cada *time-slice*.
- Paso seguido se realiza la prueba de tendencias Mann-Kendall para las estadísticas  $G_i^*$  de Getis-Ord de cada serie temporal, con el objetivo de determinar la tendencia de agrupamiento espacial.
- Posteriormente, se realiza la misma prueba de tendencias Mann-Kendall a cada *bin time-series*, para identificar si las tendencias son significativas ( $p < 0,05$ ).
- Por último, las puntuaciones  $z$  resultantes de los dos pasos anteriores se combinan para generar los patrones espacio-temporales. Esta combinación puede generar los siguientes tipos:

**Tabla 2.3. Tipos de patrones espacio-temporales**

Símbolo	Tipo del patrón espacio-temporal
	No se detectó ningún patrón
	Nuevo punto caliente
	Punto caliente consecutivo
	Punto caliente creciente
	Punto caliente persistente
	Punto caliente decreciente

	Punto caliente esporádico
	Punto caliente oscilante
	Punto caliente histórico
	Nuevo punto frío
	Punto frío consecutivo
	Punto frío creciente
	Punto frío persistente
	Punto frío decreciente
	Punto frío esporádico
	Punto frío oscilante
	Punto frío histórico

Fuente: Esri (2022d)

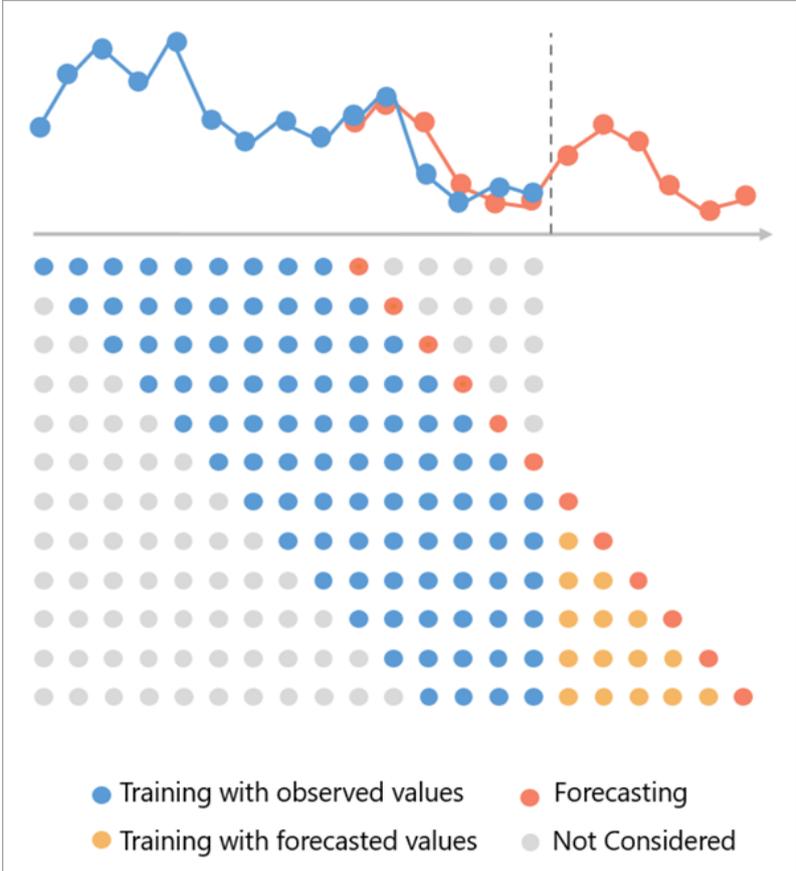
### 2.3.5. Machine learning para la predicción de los delitos

*Random forest* (RF) es un método de *machine learning* propuesto por Leo Breiman y Adele Cutler que utiliza múltiples árboles para entrenar y predecir muestras. RF en comparación con los modelos tradicionales de aprendizaje automático pueden lograr predicciones precisas y además son menos propensos al sobreajuste, y se puede aplicar a problemas de regresión y clasificación, por ejemplo, el resultado de la regresión es un valor medio de todos los árboles

de regresión, mientras que la decisión mayoritaria de todos los árboles de clasificación es el resultado de las tareas de clasificación de bosques aleatorios (Breiman 2001).

*Random Forest* combina gran cantidad de árboles de decisión, utilizando características seleccionadas para dividir los nodos del árbol y muestreo repetido de diferentes subconjuntos de observaciones para entrenar los modelos. En investigaciones anteriores, se han utilizado modelos de RF para detectar y predecir posibles patrones criminológicos, pero dichos modelos no han considerado las relaciones espaciales y temporales de delitos (Jing et al. 2020). Según Xia, Stewart, y Fan (2021), estudios recientes han comenzado a abordar las dependencias espacio-temporales en modelos de *Random Forest*, los mismos que se entrenan con base ubicaciones y períodos de tiempo definidos.

**Gráfico 2.1. Serie temporal de predicción basado en *Random Forest***



Fuente: Esri (2022e)

Para evaluar los modelamientos de cada serie temporal con RF se utilizan los siguientes parámetros:

- **Modelo de Predicción:** Se construye creando un bosque con los valores de la serie temporal en cada ubicación de un cubo espacio-tiempo. Este bosque se utiliza para predecir el valor de cada contenedor en el siguiente salto de tiempo. Y el nuevo valor predicho se incluye en el modelo de bosque para la predicción del siguiente período de tiempo. Este proceso es recurrente hasta cumplir con todos los períodos de tiempo futuros (Esri 2022b).

El ajuste del bosque de cada serie temporal se mide a través del error cuadrático medio (RMSE) de predicción y evalúa cuánto varían los valores ajustados del bosque con respecto a los valores brutos de cada serie temporal y su fórmula de cálculo es la siguiente:

$$\text{Forecast RMSE} = \sqrt{\frac{\sum_{t=1}^T (c_t - r_t)^2}{T}} \quad \text{Ec. 12}$$

Dónde:

$T$  es el número de períodos de tiempo

$c_t$  es el valor del modelo de bosque

$r_t$  es el valor bruto de la serie temporal en un período de tiempo (t)

- **Modelo de Validación:** Se genera para determinar cuan preciso es el modelo de predicción de valores futuros de cada serie temporal. El mismo se construye al excluir los datos de diversos períodos de tiempo y ajustar el modelo con la información no excluida. Paso seguido, predice los valores que se retuvieron y se comparan los valores predichos con los datos brutos (Esri 2022b). El modelo de validación determina la precisión de la predicción de los valores futuros de cada serie temporal y su fórmula de cálculo es la siguiente:

$$\text{Validation RMSE} = \sqrt{\frac{\sum_{t=T-m+1}^T (c_t - r_t)^2}{m}} \quad \text{Ec. 13}$$

Dónde:

$T$  es el número de períodos de tiempo

$m$  es el número de períodos de tiempo retenidos para la validación

$c_t$  es el valor predicho de los primeros  $T - m$  períodos de tiempo

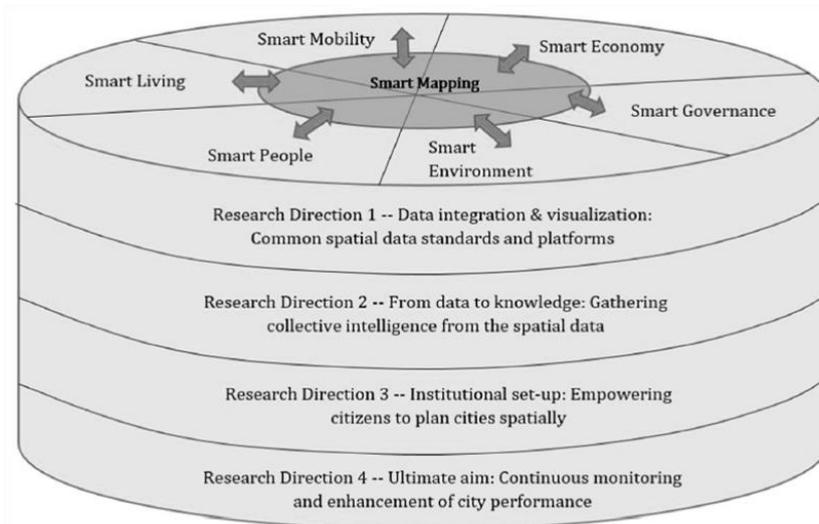
$r_t$  es el valor bruto de la serie temporal retenida en un período de tiempo (t)

### 2.3.6. *Smart mapping para smart city*

Las *smart cities* teóricamente están diseñadas para utilizar datos, optimizar recursos, mantener la sostenibilidad y mejorar la calidad de vida de los ciudadanos. Las investigaciones de Albino, Berardi, y Dangelico (2015); Ching y Ferreira (2015); Ramaprasad, Sánchez-Ortiz, y Syn (2017) mencionan que no existe una definición universalmente aceptada de *smart city* a pesar de que muchos investigadores han intentado proporcionar una definición unificada del término.

Con este antecedente Loo y Tang (2019) proponen un *smart mapping* para ciudades inteligentes, que en líneas generales tiene como objetivo aprovechar los mapas digitales y las TICs a través de los siguientes procesos: recolectar información, analizar datos, empoderar la participación ciudadana y realizar un monitoreo continuo. Y con ello proporcionar una amplia gama de datos de ubicación e información en beneficio de los 6 pilares de una *smart city*.

**Figura 2.3. *Smart mapping para smart city***



*Fuente:* Loo y Tang (2019)

Interrelacionando estos paradigmas con el tema principal de la presente investigación. Se propone el desarrollo de un Tablero de control web o *Dashboard* de delitos que permita a los tomadores de decisiones y ciudadanía en general, monitorear en tiempo real los eventos delictivos, analizar tendencias multitemporales del crimen e integrar mapas web con información relevante de esta problemática.

Los *Dashboard* de delitos presentan los siguientes beneficios en cada uno de los pilares de una *smart city*:

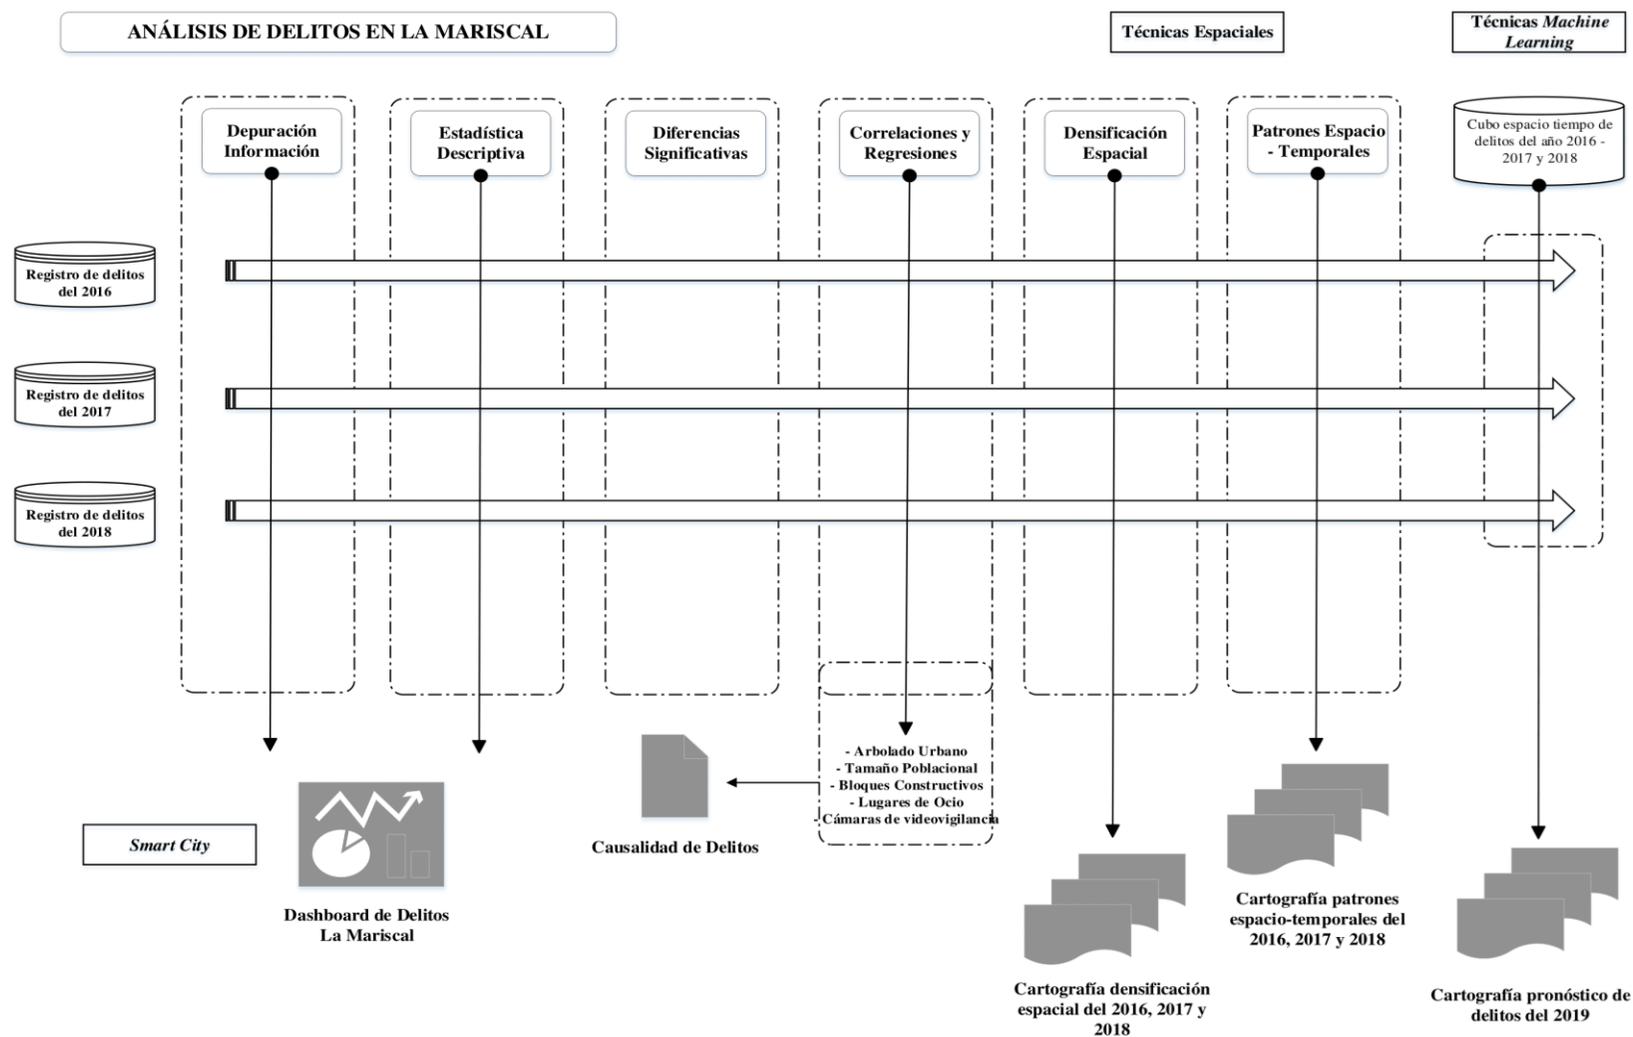
- **Economía inteligente:** Los mapas web de delitos ayudarían a los administradores de negocios y tomadores de decisiones a visualizar en tiempo real las zonas donde existe mayor ocurrencia de crímenes y conjuntamente con la policía nacional realizar planes de seguridad para aumentar el control en las zonas afectadas, y con ello evitar que los negocios modifiquen su actividad económica por los altos niveles de inseguridad.
- **Gente inteligente:** Los mapas inteligentes empoderan la participación ciudadana en el desarrollo de *smart cities* y facilitan la comunicación entre los ciudadanos y entes gubernamentales (Loo y Tang 2019), por lo que, los habitantes se convertirían en actores clave para brindar una solución a esta problemática, ya que podrían reportar geográficamente los lugares dónde suceden delitos y que no son monitoreados por las autoridades de control.
- **Gobernanza inteligente:** Al disponer de una gama de indicadores de delitos representados en una cartografía digital. El *smart mapping* apoyaría a los tomadores de decisiones en la gobernanza del crimen, para plantear políticas de seguridad en contra de la delincuencia de una manera ágil y óptima.
- **Movilidad inteligente:** El *smart mapping* favorecería a la policía nacional y agentes de control a identificar exactamente los lugares dónde se están suscitando eventos delictivos y seleccionar rutas alternativas para evitar la congestión vehicular y llegar en un menor tiempo a los sitios dónde se necesita su intervención.
- **Entorno inteligente:** Los datos de un *smart mapping* permitirían analizar patrones espaciales e identificar si existe una relación directa o inversamente proporcional del número de delitos con el arbolado urbano (Escobedo et al. 2018). Y con ello, apoyar a la gestión del entorno natural evitando talas innecesarias y minimizando el impacto ambiental.
- **Vida inteligente:** Los mapas web ayudarían a la policía nacional y agentes de control a identificar rápidamente patrones de crímenes y actuar de una manera inmediata, lo que daría paso a un entorno de vida seguro para los ciudadanos.

#### **2.4. Flujograma metodológico**

El análisis delictivo en La Mariscal, inicia con la especialización y depuración de los registros delictivos del 2016, 2017 y 2018. Paso seguido, se evaluó y contextualizó la dinámica de delitos con medidas clásicas de estadística descriptiva. En este sentido, la regresión lineal por

mínimos cuadrados permitió evaluar la influencia de factores urbanos (arbolado urbano, tamaño poblacional, bloques constructivos, lugares de ocio y cámaras de videovigilancia) en la ocurrencia de crímenes. Usando tecnologías geoespaciales, combinadas con técnicas de minería de datos y aprendizaje automático se identificó y predijo los patrones delictivos con el objetivo comprender su dinámica en el espacio-tiempo. Por último, los insumos generados brindaron la oportunidad de desarrollar una propuesta de mapeo inteligente desde el punto de vista de *smart city* para promover la participación ciudadana en la lucha contra la inseguridad y mejorar la toma de decisiones en materia de prevención y gestión de la ciudad.

Figura 2.4. Flujoograma metodológico



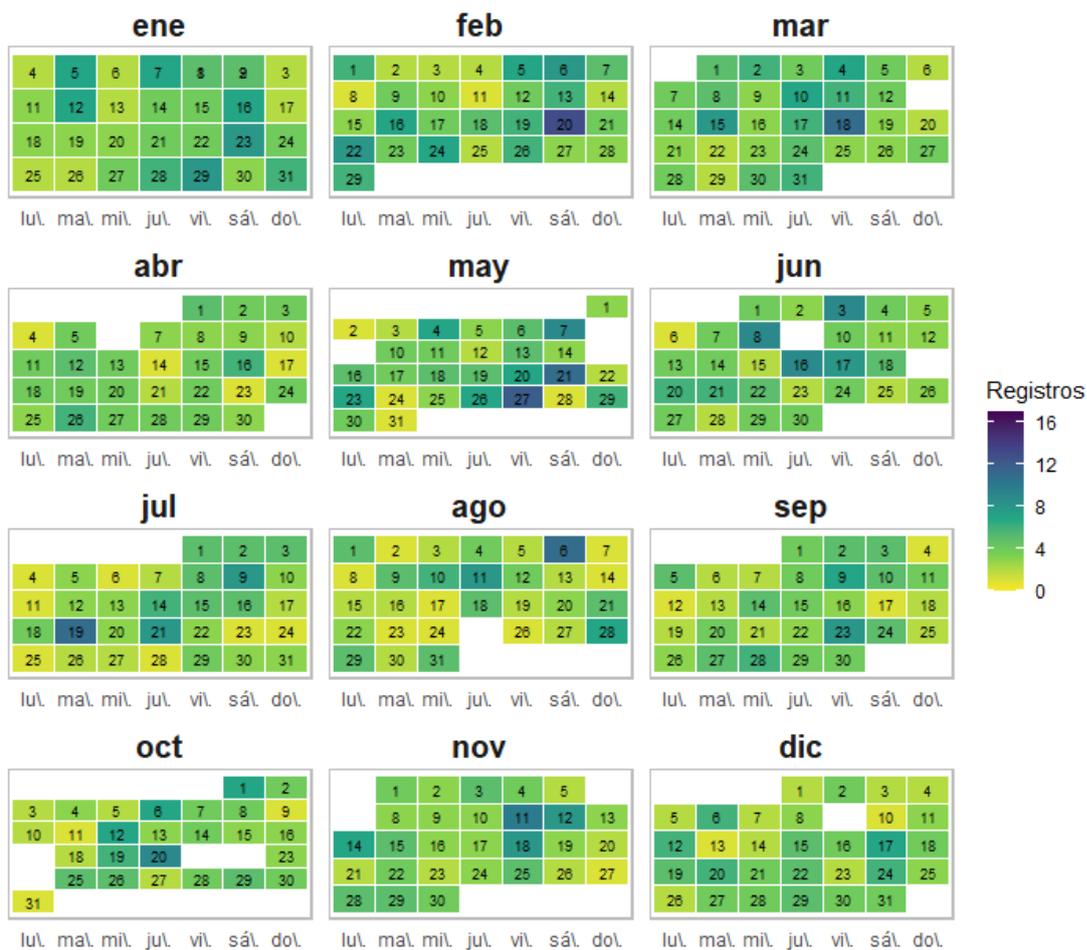
Elaborado por el autor

## Capítulo 3. Resultados

### 3.1. Calendario de delitos

En el 2016 se registraron 1.386 delitos y los resultados del calendario del crimen revelan que tan solo 14 días del año no se reportó ningún tipo delito en el sector La Mariscal. El sábado 20 de febrero y el viernes 27 de mayo fueron los más conflictivos, ya que se atendieron más de 16 delitos. A diferencia del resto de días que se han suscitado una cantidad inferior de incidentes. Además, se observó que no existe un patrón en la ocurrencia de delitos entre los días de los diferentes meses del año.

**Gráfico 3.1. Calendario del crimen del año 2016**

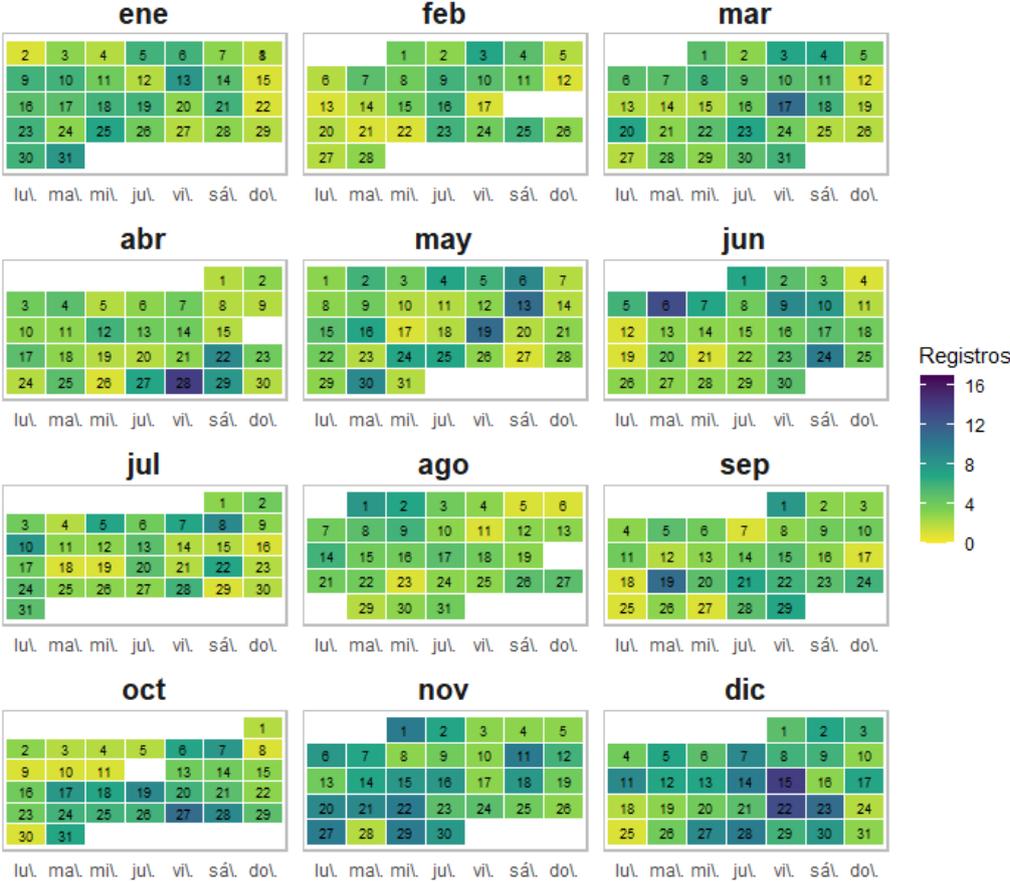


Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016)

En el 2017 se registraron 1.606 delitos y los resultados del calendario del crimen revelan que tan solo 7 días del año no se reportó ningún tipo delito en el sector La Mariscal. El sábado 28 de abril y el viernes 15 de diciembre fueron los más conflictivos, ya que se atendieron más de 16 delitos. A diferencia del resto de días que se han suscitado una cantidad inferior de

incidentes. Además, se observó que no existe un patrón en la ocurrencia de delitos entre los días de los diferentes meses del año.

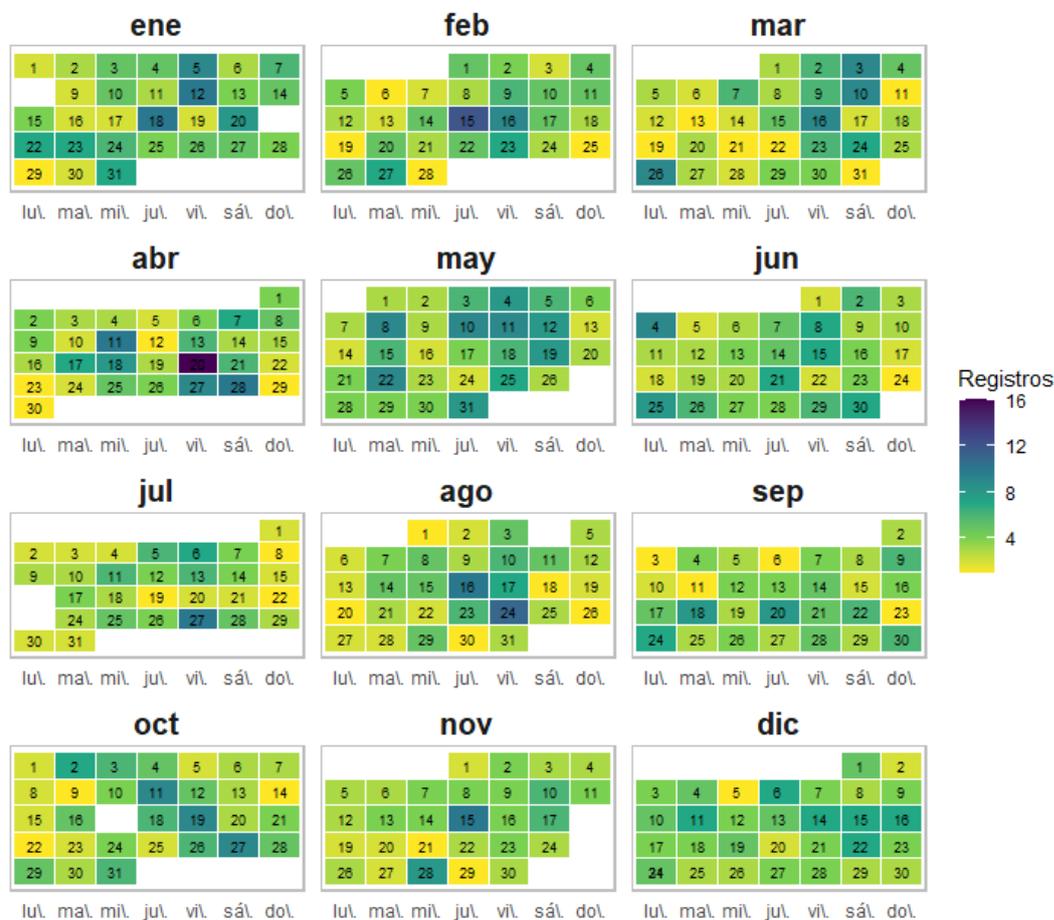
**Gráfico 3.2. Calendario del crimen del año 2017**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2017)

En el 2018 se registraron 1.485 delitos y los resultados del calendario del crimen revelan que tan solo 10 días del año no se reportó ningún tipo delito en el sector La Mariscal. El viernes 20 de abril fue el más conflictivo, ya que se atendieron más de 16 delitos. A diferencia del resto de días que se han suscitado una cantidad inferior de incidentes. Además, se observó que no existe un patrón en la ocurrencia de delitos entre los días de los diferentes meses del año.

**Gráfico 3.3. Calendario del crimen del año 2018**

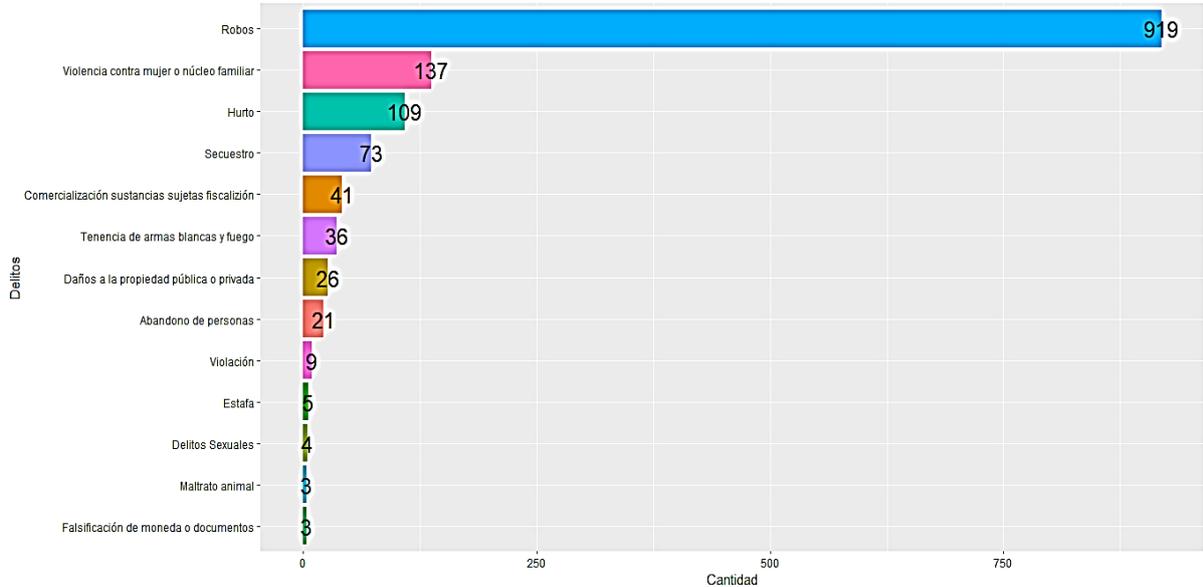


Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2018)

### 3.2. Frecuencia de delitos

La representación por diagrama de barras de la cantidad de delitos del año 2016 según su tipología refleja que los 3 delitos más comunes fueron: Robos, Violencia contra la mujer o núcleo familiar y Hurto. En cambio, los 3 delitos menos reportados fueron: Delitos sexuales, Maltrato animal y Falsificación de moneda o documentos.

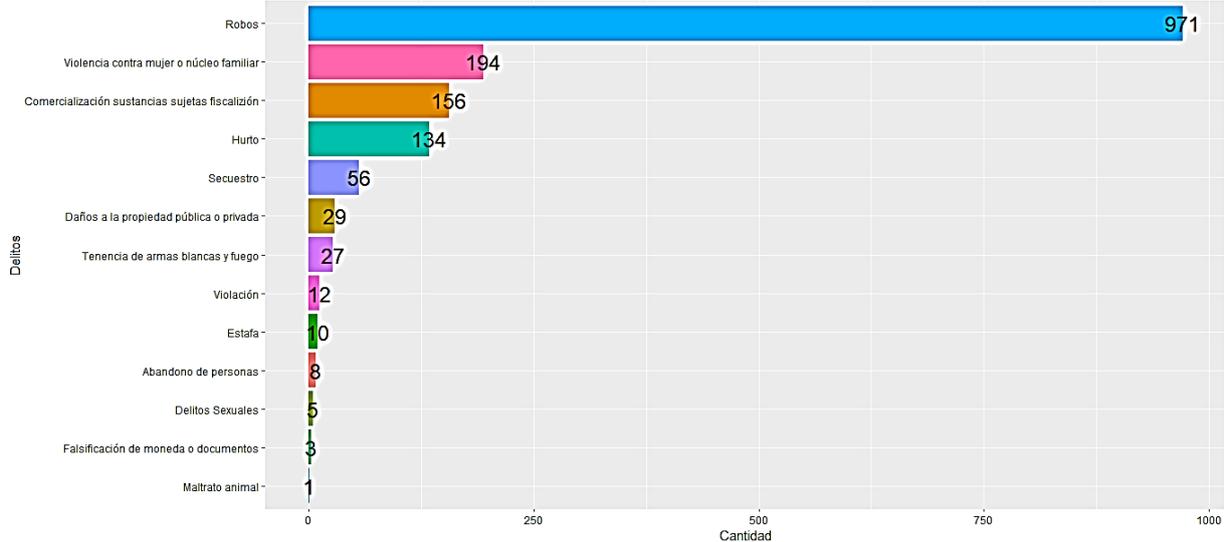
**Gráfico 3.4. Cantidad de delitos reportados en el año 2016 según su tipología**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016)

La representación por diagrama de barras de la cantidad de delitos del año 2017 según su tipología refleja que los 3 delitos más comunes fueron: Robos, Violencia contra la mujer y Comercialización sustancias sujetas fiscalización. En cambio, los 3 delitos menos reportados fueron: Delitos sexuales, Falsificación de monedas o documentos y Maltrato animal

**Gráfico 3.5. Cantidad de delitos reportados en el año 2017 según su tipología**

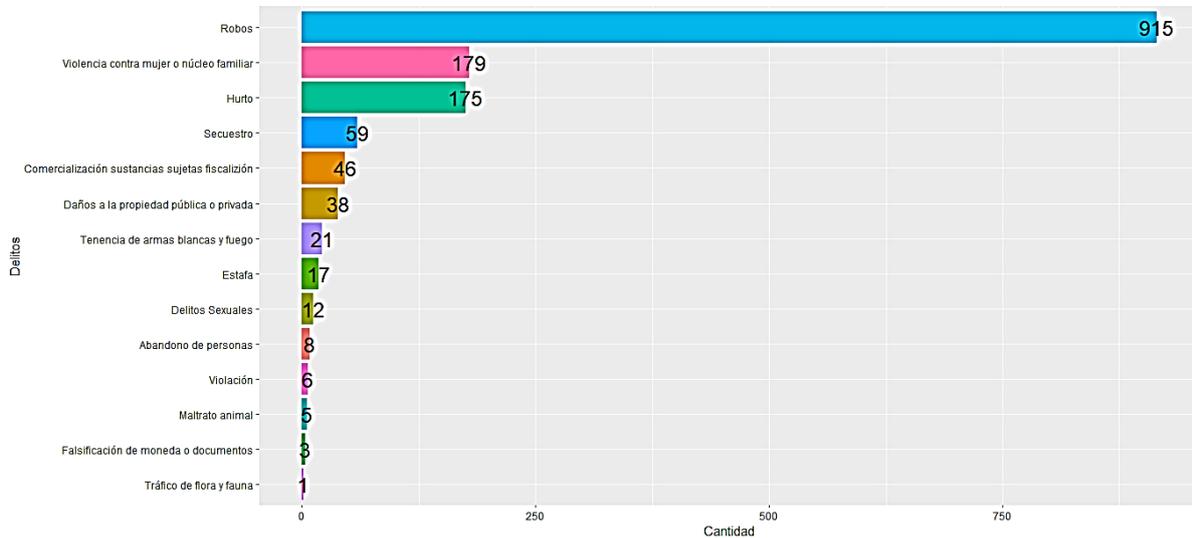


Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2017)

La representación por diagrama de barras de la cantidad de delitos del año 2018 según su tipología refleja que los 3 delitos más comunes fueron: Robos, Violencia contra la mujer y

Hurto. En cambio, los 3 delitos menos reportados fueron: Maltrato animal, Falsificación de monedas o documentos y Tráfico de flora y fauna.

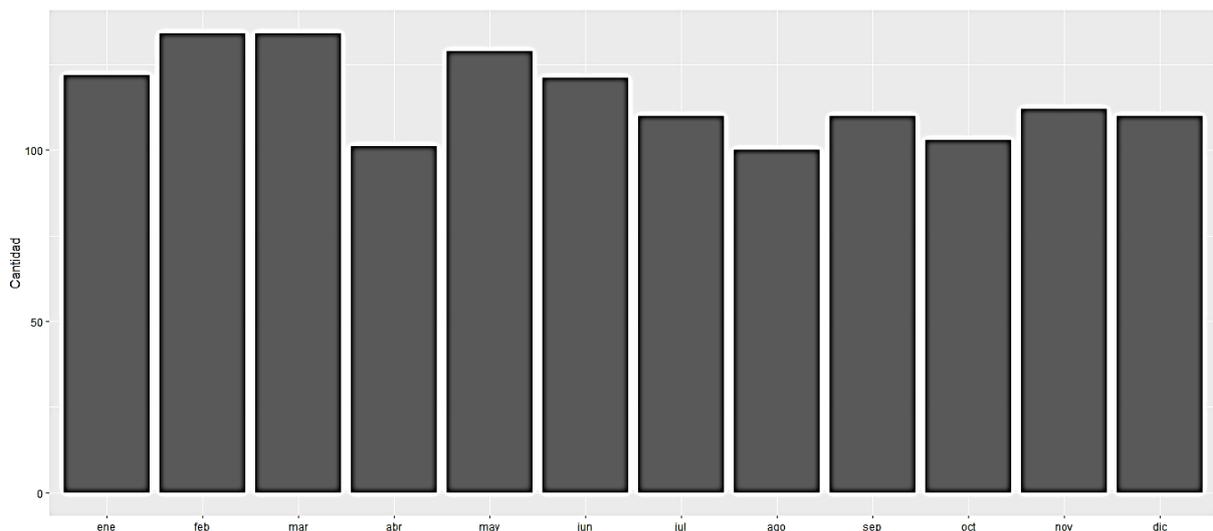
**Gráfico 3.6. Cantidad de delitos reportados en el año 2018 según su tipología**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2018)

La representación por diagrama de barras de la cantidad total de delitos reportados en cada mes del año 2016 refleja que los 3 meses más conflictivos fueron: febrero, marzo y mayo. En cambio, los 3 meses que se reportaron menos delitos fueron: abril, agosto y octubre.

**Gráfico 3.7. Cantidad total de delitos reportados en cada mes del año 2016**

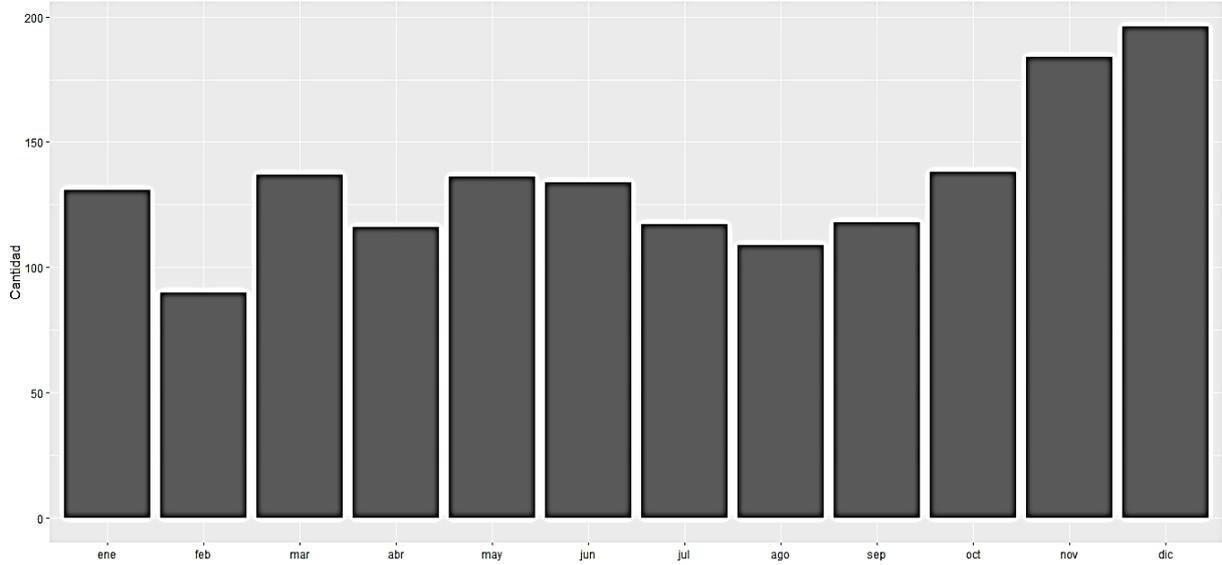


Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016)

La representación por diagrama de barras de la cantidad total de delitos reportados en cada mes del año 2017 refleja que los 3 meses más conflictivos fueron: marzo, noviembre y

diciembre. En cambio, los 3 meses que se reportaron menos delitos fueron: febrero, abril y agosto.

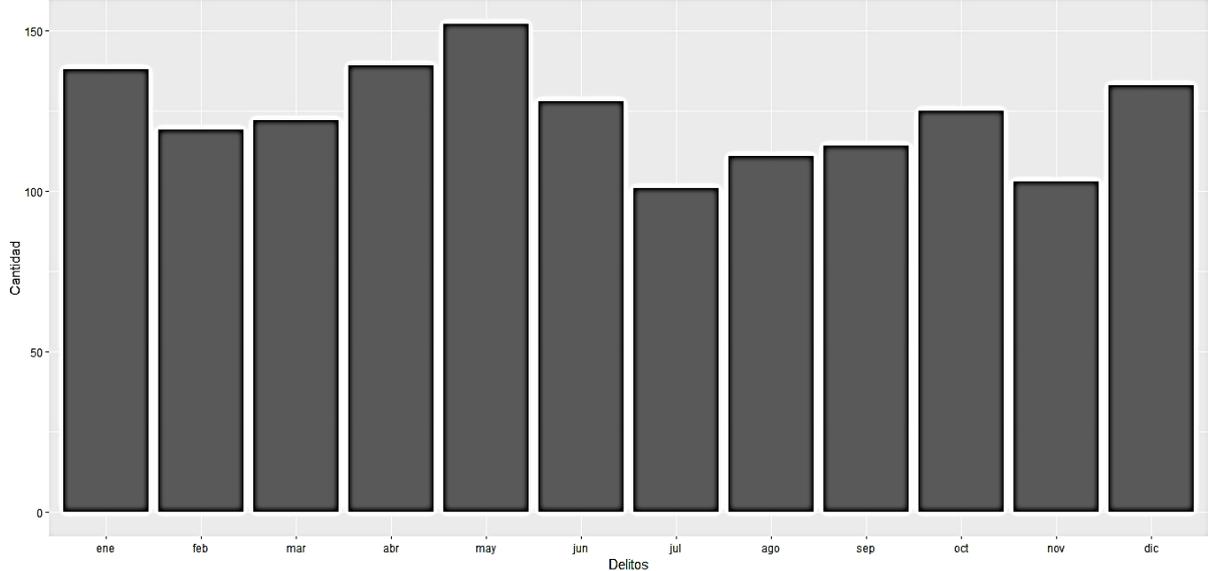
**Gráfico 3.8. Cantidad total de delitos reportados en cada mes del año 2017**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2017)

La representación por diagrama de barras de la cantidad total de delitos reportados en cada mes del año 2018 refleja que los 3 meses más conflictivos fueron: enero, abril y mayo. En cambio, los 3 meses que se reportaron menos delitos fueron: julio, agosto y noviembre.

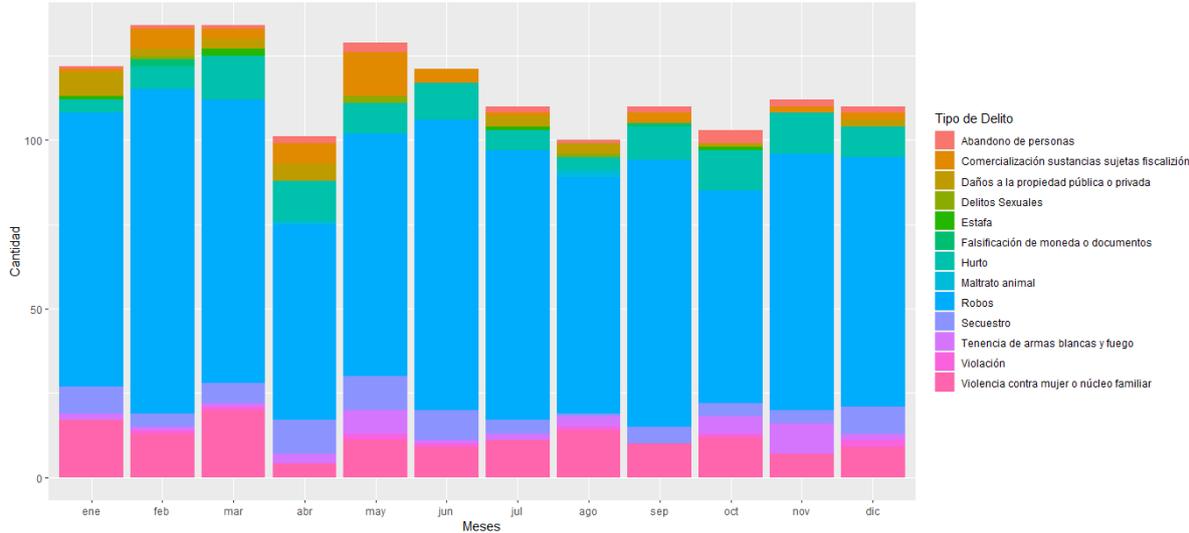
**Gráfico 3.9. Cantidad total de delitos reportados en cada mes del año 2018**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2018)

La representación por diagrama de barras apiladas según la tipología del delito en cada mes del año 2016 refleja una tendencia creciente de delitos desde el mes de enero a marzo y desde octubre a diciembre. En cambio, existe una tendencia decreciente desde el mes de mayo a agosto. Además, es evidente que el Robo es el delito más común de enero a diciembre.

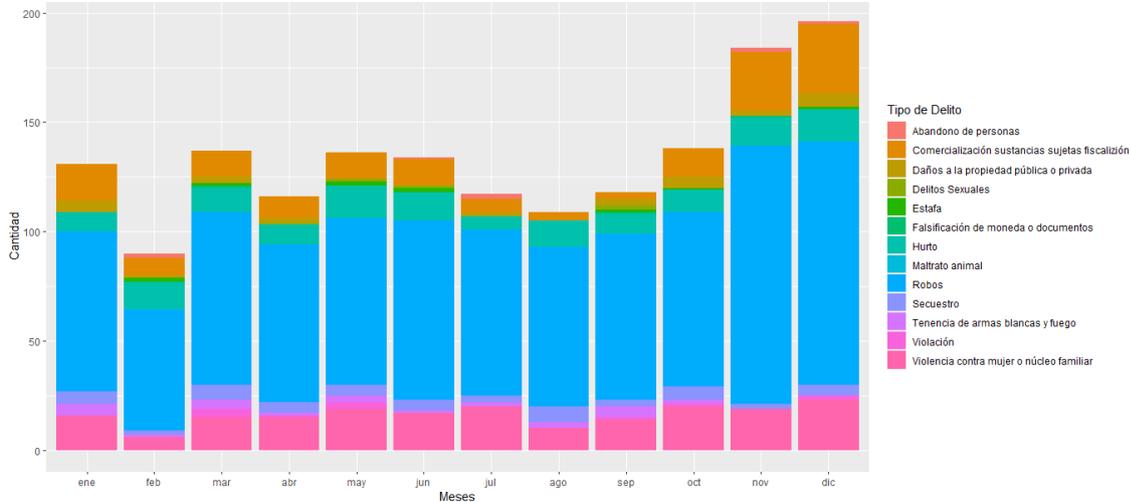
**Gráfico 3.10. Delitos reportados según su tipología en cada mes del año 2016**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016)

La representación por diagrama de barras apiladas según la tipología del delito en cada mes del año 2017 refleja una tendencia creciente de delitos desde el mes de agosto a diciembre. En cambio, existe una tendencia decreciente desde el mes de mayo a agosto. Además, es evidente que el Robo es el delito más común de enero a diciembre.

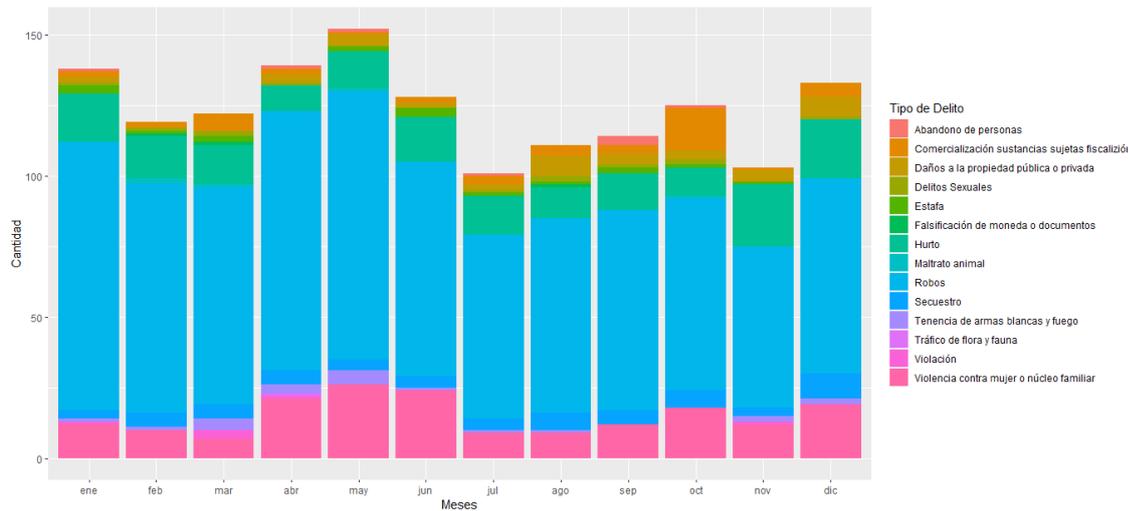
**Gráfico 3.11. Delitos reportados según su tipología en cada mes del año 2017**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2017)

La representación por diagrama de barras apiladas según la tipología del delito en cada mes del año 2018 refleja una tendencia creciente de delitos desde el mes de febrero a mayo y julio a octubre. En cambio, existe una tendencia decreciente desde el mes de mayo a julio. Además, es evidente que el Robo es el delito más común de enero a diciembre.

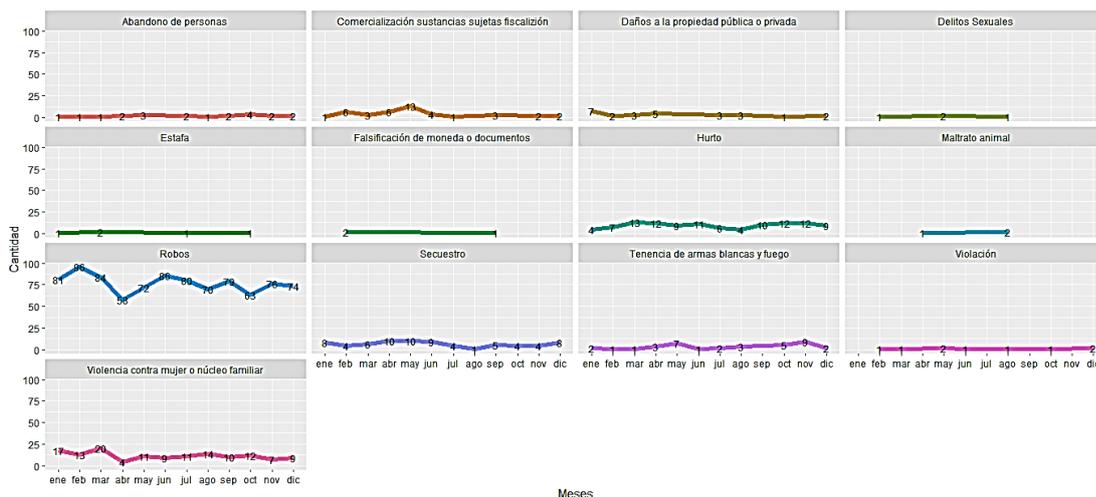
**Gráfico 3.12. Delitos reportados según su tipología en cada mes del año 2018**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2018)

Es evidente que existe una tendencia lineal en la mayoría de delitos reportados del 2016. A excepción de los Robos que presenta altibajos en cada mes del año.

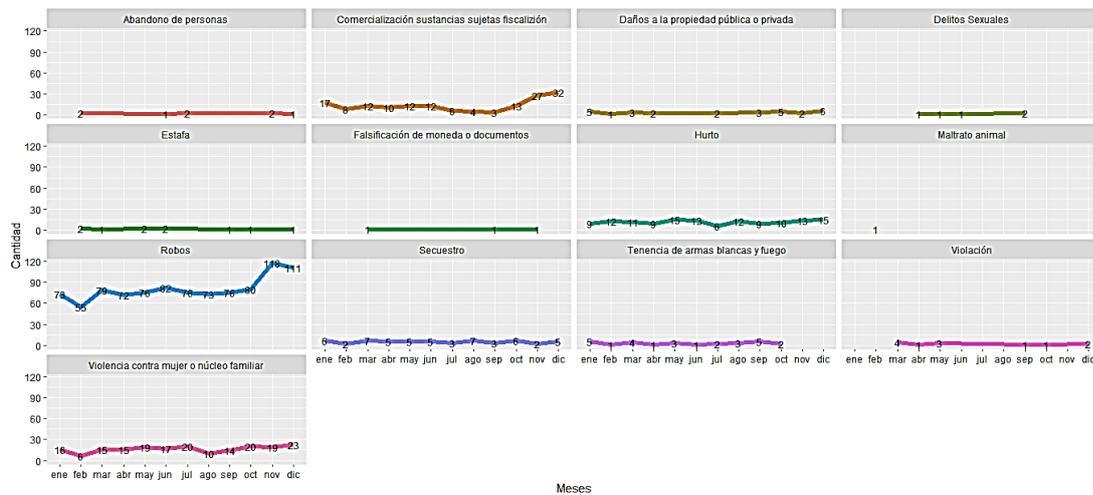
**Gráfico 3.13. Delitos reportados por mes mediante polígonos de frecuencias del año 2016**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016)

Es evidente que existe una tendencia lineal en la mayoría de delitos reportados del 2017. A excepción de los Robos que presenta altibajos en diferentes períodos de tiempo.

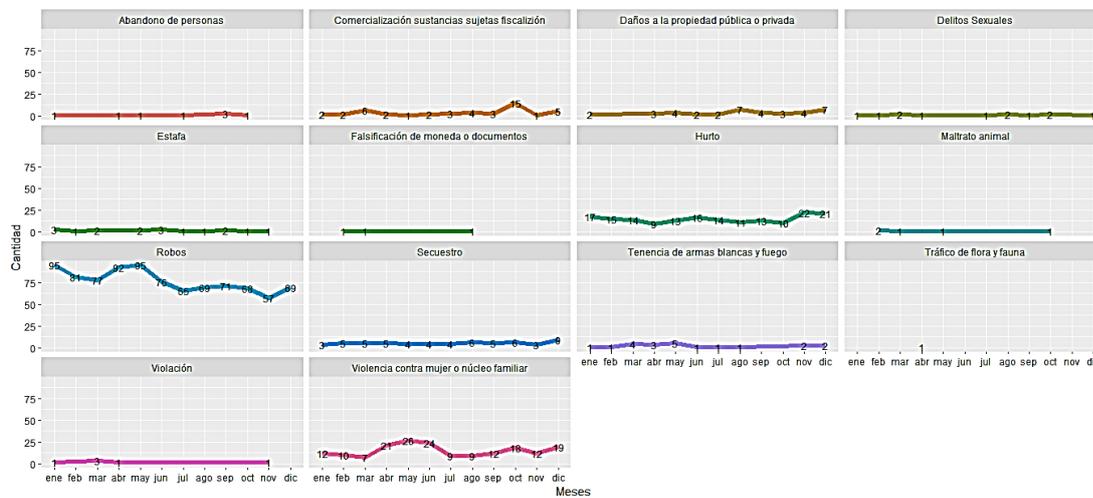
**Gráfico 3.14. Delitos reportados por mes mediante polígonos de frecuencias del año 2017**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2017)

Es evidente que existe una tendencia lineal en la mayoría de delitos reportados del 2018. A excepción de los Robos y Violencia contra la mujer o núcleo familiar que presentan altibajos en diferentes períodos de tiempo.

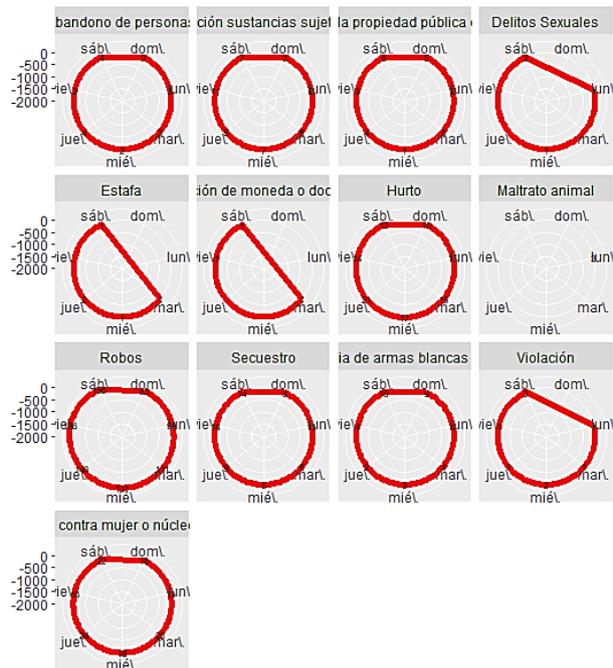
**Gráfico 3.15. Delitos reportados por mes mediante polígonos de frecuencias del año 2018**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2018)

En el año 2016 se reportó diariamente una ocurrencia similar de siguientes delitos: Abandono de personas, Comercialización de sustancias sujetas a fiscalización, Daño a la propiedad pública y privada, Hurto, Robos, Secuestro, Tenencia de armas blancas y Violencia contra la mujer o núcleo familiar. En otras palabras, los delitos mencionados anteriormente no descansan en el sector La Mariscal.

**Gráfico 3.16. Delitos reportados por día de semana mediante gráfico de radar del año 2016**

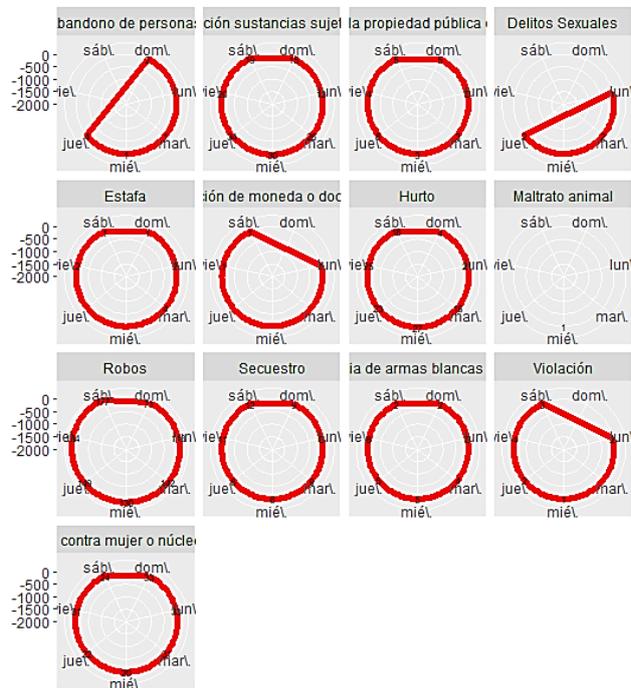


Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016)

En el año 2017 se reportó diariamente una ocurrencia similar de siguientes delitos:

Comercialización de sustancias sujetas a fiscalización, Daño a la propiedad pública y privada, Estafa, Hurto, Robos, Secuestro, Tenencia de armas blancas y Violencia contra la mujer o núcleo familiar. En otras palabras, los delitos mencionados anteriormente no descansan en el sector La Mariscal.

**Gráfico 3.17. Delitos reportados por día de semana mediante gráfico de radar del año 2017**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2017)

En el año 2018 se reportó diariamente una ocurrencia similar de siguientes delitos: Comercialización de sustancias sujetas a fiscalización, Daño a la propiedad pública y privada, Delitos sexuales, Hurto, Robos, Secuestro, Tenencia de armas blancas y Violencia contra la mujer o núcleo familiar. En otras palabras, los delitos mencionados anteriormente no descansan en el sector La Mariscal.

**Gráfico 3.18. Delitos reportados por día de semana mediante gráfico de radar del año 2018**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2018)

### 3.3. Diferencias significativas de delitos

Los resultados revelan que, en los años 2016, 2017 y 2018 no existen diferencias significativas en la ocurrencia de delitos por su nivel de importancia entre las diferentes manzanas de La Mariscal. Es decir, en cualquier lugar de la zona de estudio se reportó una similar frecuencia de delitos de riesgo urgente que amenazan y/o afectan a la población.

**Tabla 3.1. Prueba de hipótesis de la ocurrencia de delitos por su nivel de importancia entre las manzanas de La Mariscal en el año 2016, 2017 y 2018**

Año	Hipótesis Nula	Prueba de Hipótesis	Nivel de Significancia	Decisión
2016	La distribución de Nivel Importancia es la misma en todas las categorías de Manzanas	Prueba de Kruskal-Wallis de muestras independientes	0,102	Acepta la Hipótesis Nula

<b>2017</b>	La distribución de Nivel Importancia es la misma en todas las categorías de Manzanas	Prueba de Kruskal-Wallis de muestras independientes	0,307	Acepta la Hipótesis Nula
<b>2018</b>	La distribución de Nivel Importancia es la misma en todas las categorías de Manzanas	Prueba de Kruskal-Wallis de muestras independientes	0,090	Acepta la Hipótesis Nula

Elaborado por el autor

Los resultados revelan que, en los años 2016, 2017 y 2018 existen diferencias significativas en la ocurrencia de delitos por su nivel de importancia entre las 06h00-14h00, 14h00-22h00 y 22h00 a 06h00 horas en La Mariscal. Es decir, en determinados períodos de tiempo se reportaron delitos de riesgo urgente que amenazan y/o afectan a la población con mayor frecuencia que en otras horas del día.

**Tabla 3.2. Prueba de hipótesis de la ocurrencia de delitos por su nivel de importancia entre determinados períodos de tiempo en el año 2016, 2017 y 2018**

<b>Año</b>	<b>Hipótesis Nula</b>	<b>Prueba de Hipótesis</b>	<b>Nivel de Significancia</b>	<b>Decisión</b>
<b>2016</b>	La distribución de Nivel Importancia es la misma en todas las categorías de Turno	Prueba de Kruskal-Wallis de muestras independientes	0,002	Rechaza la Hipótesis Nula
<b>2017</b>	La distribución de Nivel Importancia es la misma en todas las categorías de Turno	Prueba de Kruskal-Wallis de muestras independientes	0,000	Rechaza la Hipótesis Nula
<b>2018</b>	La distribución de Nivel Importancia es la misma en todas las categorías de Turno	Prueba de Kruskal-Wallis de muestras independientes	0,000	Rechaza la Hipótesis Nula

Elaborado por el autor

Los resultados revelan que, en los años 2016, 2017 y 2018 no existen diferencias significativas en la ocurrencia de delitos por su nivel de importancia entre los diferentes meses del año en La Mariscal. Es decir, en cualquier mes del año se reportó una similar frecuencia de delitos de riesgo urgente que amenazan y/o afectan a la población.

**Tabla 3.3. Prueba de hipótesis de la ocurrencia de delitos por su nivel de importancia entre los meses del año 2016, 2017 y 2018**

<b>Año</b>	<b>Hipótesis Nula</b>	<b>Prueba de Hipótesis</b>	<b>Nivel de Significancia</b>	<b>Decisión</b>
<b>2016</b>	La distribución de Nivel Importancia es la misma en todas las categorías de Mes	Prueba de Kruskal-Wallis de muestras independientes	0,346	Acepta la Hipótesis Nula
<b>2017</b>	La distribución de Nivel Importancia es la misma en todas las categorías de Mes	Prueba de Kruskal-Wallis de muestras independientes	0,243	Acepta la Hipótesis Nula
<b>2018</b>	La distribución de Nivel Importancia es la misma en todas las categorías de Mes	Prueba de Kruskal-Wallis de muestras independientes	0,166	Acepta la Hipótesis Nula

Elaborado por el autor

### **3.4. Causalidad de delitos**

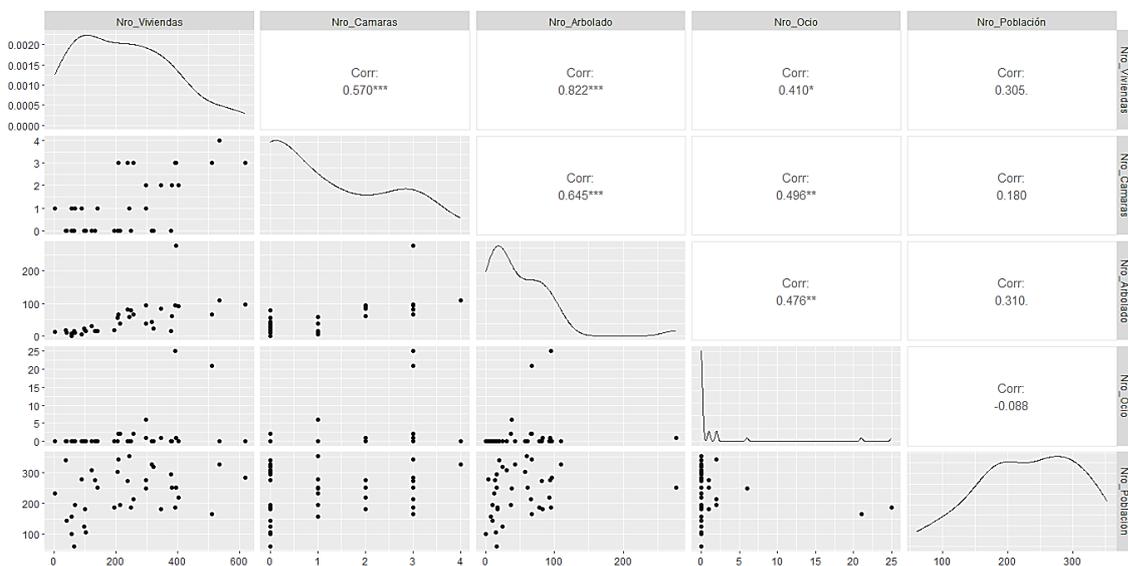
El modelo de regresión lineal por mínimos cuadrados permitió evaluar la causalidad de las variables independientes (lugares de ocio, arbolado urbano, bloques constructivos, cámaras de videovigilancia y población total) en la variable dependiente (delitos totales). Cabe recalcar, que para el presente análisis se tomó en consideración únicamente los incidentes de Robos y Hurtos, mismos que son los delitos más representativos y ocurrentes en el sector La Mariscal; y según la literatura pueden estar influenciados por las variables independientes de la presente investigación (Hashim et al. 2019).

En primera instancia se evaluó la normalidad de las variables explicativas mediante la prueba no paramétrica Kolmogórov-Smirnov y se reporta que las variables bloques constructivos (Nro\_Viviendas) y población total (Nro\_Población) presentan una distribución normal con p-valor de 0,2. En cambio, las variables de cámaras de videovigilancia (Nro\_Camaras), arbolado urbano (Nro\_Arbolado) y lugares de ocio (Nro\_Ocio) no presentan una distribución normal.

Paso seguido, se empleó el coeficiente de correlación de Spearman porque no todas las variables presentan una distribución normal; y con esta medida se determinó la fuerza de asociación entre las variables independientes.

Se reporta que no existe una alta correlación entre las variables predictoras. A excepción, de Bloques Constructivos (Nro\_Viviendas) y Arbolado Urbano (Nro\_Arbolado) que tienen una fuerte asociación positiva. Por lo tanto, en el modelo de regresión lineal no se consideró a la variable Nro\_Viviendas, con el objetivo de evitar una relación lineal entre las variables explicativas.

**Gráfico 3.19. Matriz de correlación de Spearman entre las variables explicativas**



Elaborado por el autor

El modelo de regresión lineal cumple los 3 supuestos fundamentales. Es decir, no hay multicolinealidad, existe normalidad de residuales y homocedasticidad. Por lo tanto, se reporta que no existe evidencia significativa que el arbolado urbano (Nro\_Arbolado) y el total poblacional (Nro\_Población) puedan influir en la ocurrencia de delitos.

Por otra parte, se obtuvo que el número de cámaras (Nro\_Camaras) y lugares de ocio (Nro\_Ocio) podrían explicar en un 95% la ocurrencia de delitos (Nro\_Delitos) en la Zona Rosa más grande de Quito.

**Tabla 3.4. Valor de significancia de los coeficientes del modelo de regresión lineal**

Modelo	Coeficientes No Estandarizados		Coeficientes Estandarizados		
	B	Std. Error	Beta	t	Significancia
Constante	12,272	34,509		0,356	0,725
Nro_Camaras	25,625	11,816	0,388	2,169	0,038
Nro_Arbolado	0,388	0,273	0,234	1,421	0,166
Nro_Ocio	4,725	2,156	0,303	2,192	0,036
Nro_Población	0,083	0,146	0,074	0,571	0,572

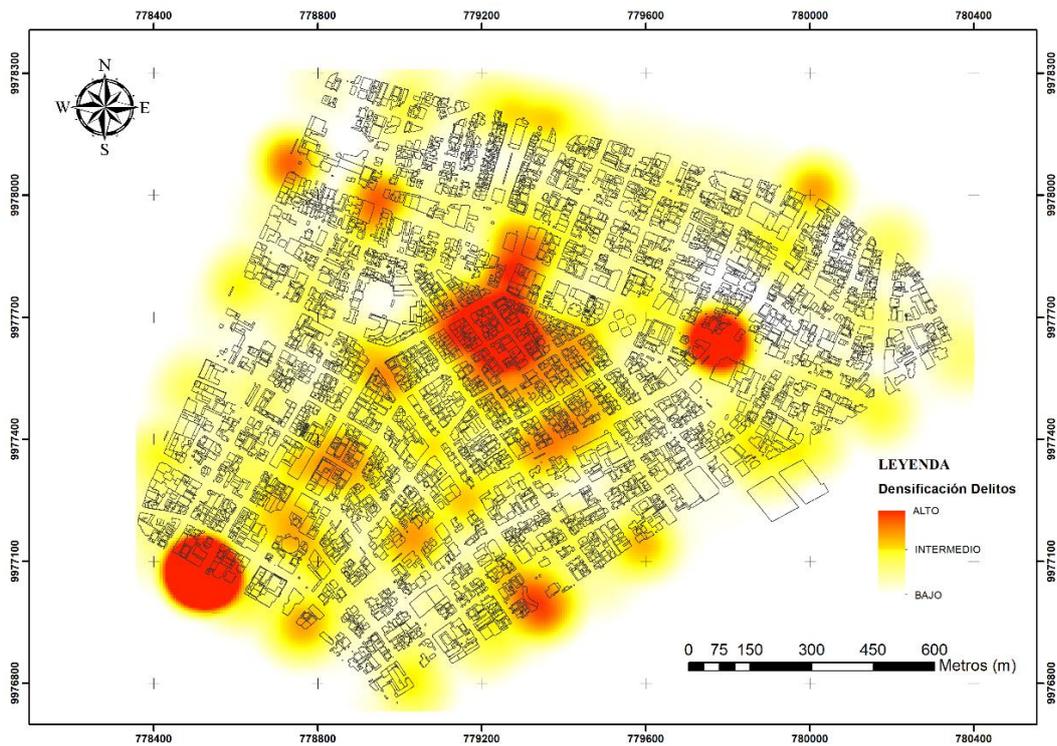
Variable Dependiente: Nro\_Delitos

Elaborado por el autor

### 3.5. Densificación y patrón espacial de delitos

Los resultados de la densificación espacial de delitos del año 2016 a través del método KDE revelan que en el epicentro del sector La Mariscal existe una mayor concentración de la actividad criminal. También se reporta la presencia de otras 2 áreas que agrupan una concentración relativamente importante de delitos, mismas que se localizan al Nor-Este y Sur-Oeste de la zona de estudio.

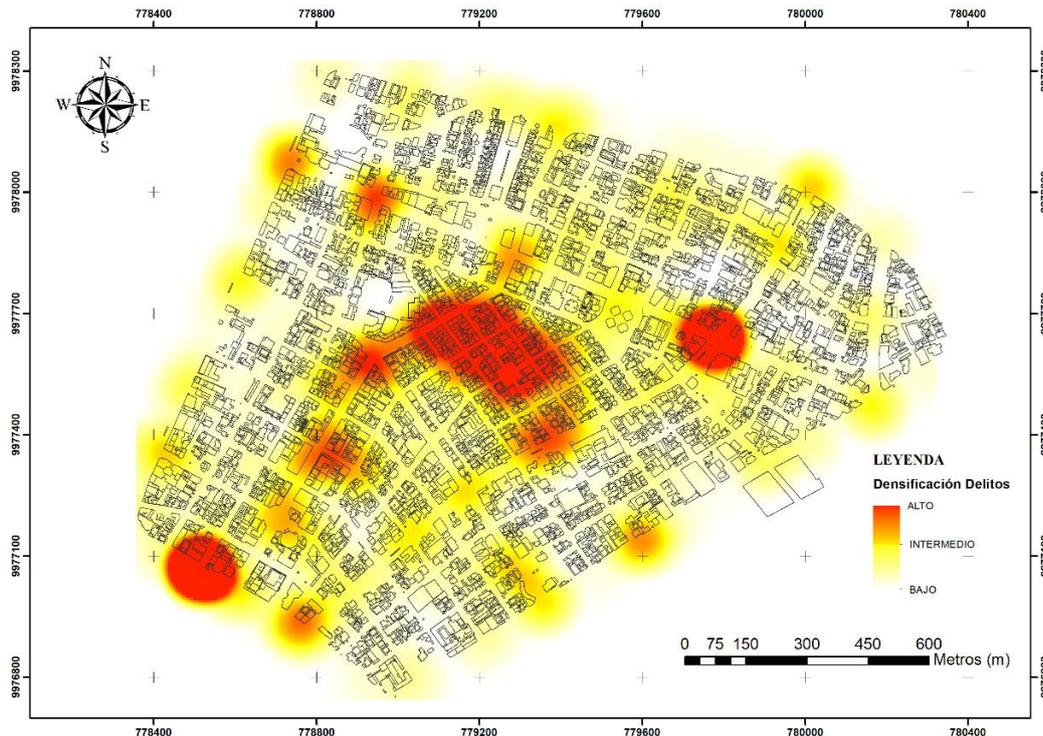
**Mapa 3.1. Densificación de delitos del año 2016 por el método KDE**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016)

Los resultados de la densificación espacial de delitos del año 2017 a través del método KDE revelan que en el epicentro y sus alrededores del sector La Mariscal existe una mayor concentración de la actividad criminal. También se reporta la presencia de otras 2 áreas críticas al Nor-Este y Sur-Oeste de la zona de estudio.

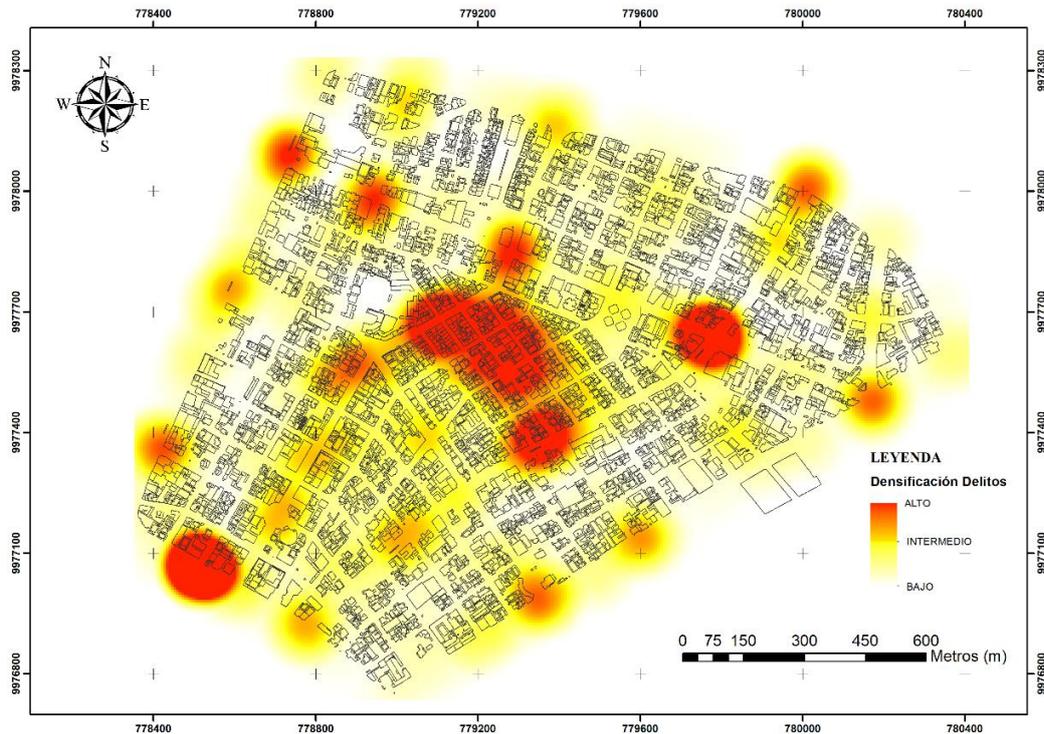
**Mapa 3.2. Densificación de delitos del año 2017 por el método KDE**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2017)

Los resultados de la densificación espacial de delitos del año 2018 a través del método KDE revelan que en el epicentro y sus alrededores del sector La Mariscal existe una mayor concentración de la actividad criminal. También se reporta la presencia de otras 3 áreas que agrupan una concentración relativamente importante de delitos, una de ellas se localiza a pocos metros del epicentro y las otras dos están ubicadas al Nor-Este y Sur-Oeste de la zona de estudio.

### Mapa 3.3. Densificación de delitos del año 2018 por el método KDE



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2018)

Con base a los análisis del KDE en el sector La Mariscal. Se reporta que la densificación de delitos del año 2016 presenta una tasa de acierto (TA) del 61%, mientras que la densificación de delitos del año 2017 presenta una tasa de acierto (TA) del 67%. Es evidente que existe una buena precisión del modelamiento del crimen en la zona de estudio. Cabe recalcar que no se evaluó a precisión del KDE del año 2018, ya que la presente investigación no dispone del registro georreferenciados de delitos del año 2019.

Una de las desventajas de trabajar con la TA es que está fuertemente influenciada por el tamaño del área de estudio y la cantidad de delitos observados en un tiempo (t+1). Por tal motivo, se utilizó el índice PAI para evaluar la calidad de las predicciones de delitos. Mientras el valor de PAI sea más alto, indica una mayor precisión predictiva. En consecuencia, se reporta que la densificación de delitos del año 2016 tiene una mejor precisión en comparación a los modelamientos delictivos del año 2017 y 2018.

Por último, las puntuaciones  $RRI < 1$  indican una disminución en la precisión del modelamiento delictivo. En este contexto, se reportan RRI de 0.94 y 1.03. El primer índice sugiere que la precisión del KDE 2017 es menor al modelamiento del KDE 2016. A diferencia del segundo RRI de 1.03 que evidencia una predicción más precisa del KDE 2018

en comparación al KDE 2017. Según Hart y Zandbergen (2014) el RRI se utiliza como una forma de contextualizar las puntuaciones PAI.

**Tabla 3.5. Análisis de la tasa de aciertos (TA), índice de precisión predictiva (PAI) e índice de tasa de recuperación (RRI) de los KDE**

	KDE 2016	KDE 2017	
Tasa de Aciertos (TA)	0.61	0.67	
	KDE 2016	KDE 2017	KDE 2018
Índice de precisión predictiva (PAI)	2.35	2.22	2.30
	KDE 2017-2016	KDE 2018-2017	
Índice de tasa de recuperación (RRI)	0.94	1.03	

Elaborado por el autor

### 3.6. Patrones espacio-temporales de delito

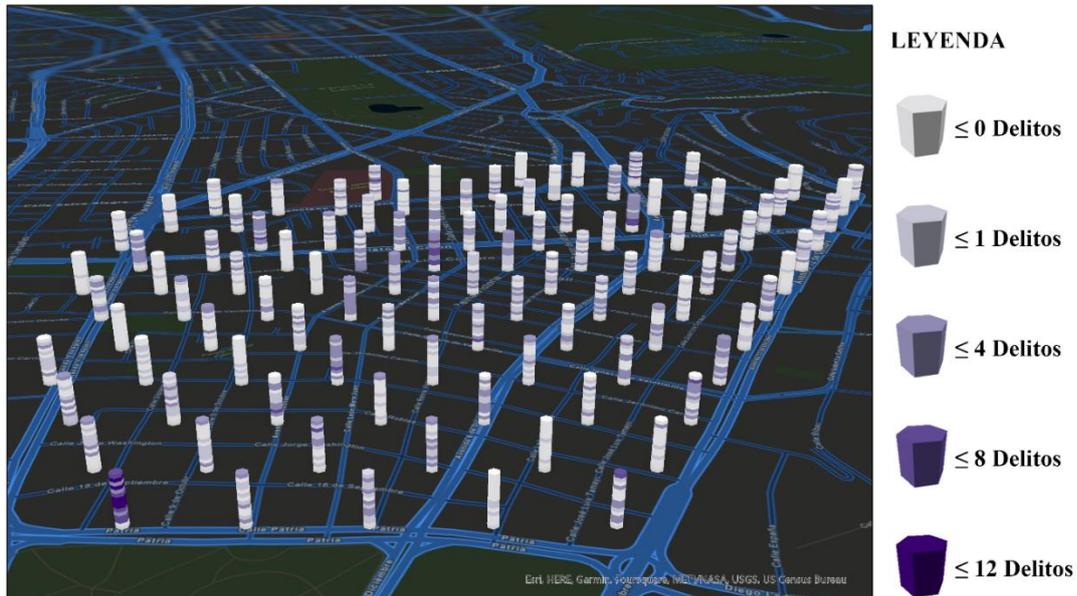
Para identificar patrones de delitos en el espacio-tiempo del año 2016, 2017 y 2018, fue necesario en primer lugar crear cubos en tres dimensiones dónde las coordenadas X, Y representan la geolocalización de los delitos reportados; mientras que la coordenada Z está asociada la fecha de dicho incidente. Los delitos más recientes se localizan en la parte superior del cubo, a diferencia de los delitos más antiguos que se ubican en las filas inferiores del cubo.

Todos los cubos espacio-tiempo generados se componen de contenedores y cada contenedor representa una ubicación dentro de la zona rosa más grande de Quito en un período de tiempo en particular. Los cubos del año 2016, 2017 y 2018 presentan las siguientes características:

- El período de tiempo seleccionado es 1 mes, ya que el objetivo es evaluar las tendencias mensuales de delitos en los años respectivos.
- El intervalo de distancia que define la altura de cada cuadrícula hexagonal es de 150 metros, ya que esa es la longitud aproximada de las calles que delimitan a las manzanas en el sector La Mariscal.

Esto quiere decir que en cada contenedor se hace un recuento por mes de todos los delitos suscitados dentro de la misma ubicación que está definida por las cuadrículas hexagonales que cubren el área de estudio.

**Gráfico 3.20. Visualización 3D del cubo espacio-tiempo de delitos del año 2016**



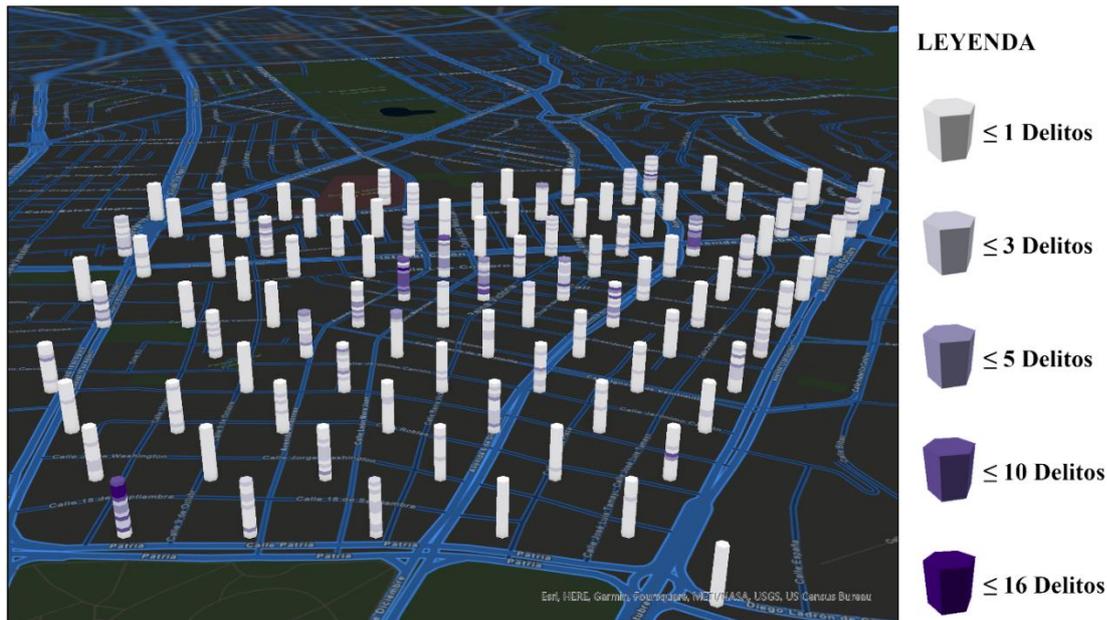
Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016)

**Gráfico 3.21. Visualización 3D del cubo espacio-tiempo de delitos del año 2017**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2017)

**Gráfico 3.22. Visualización 3D del cubo espacio-tiempo de delitos del año 2018**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2018)

Para determinar los patrones espacio-temporales de los puntos calientes (*HotSpot*), puntos fríos (*ColdSpot*), puntos en aumentos, puntos en disminución o puntos esporádicos de delitos en el sector la Mariscal, se identificaron las tendencias de las puntuaciones z y el p-valor de cada contenedor de los cubos espacio-tiempo creados del año 2016, 2017 y 2018.

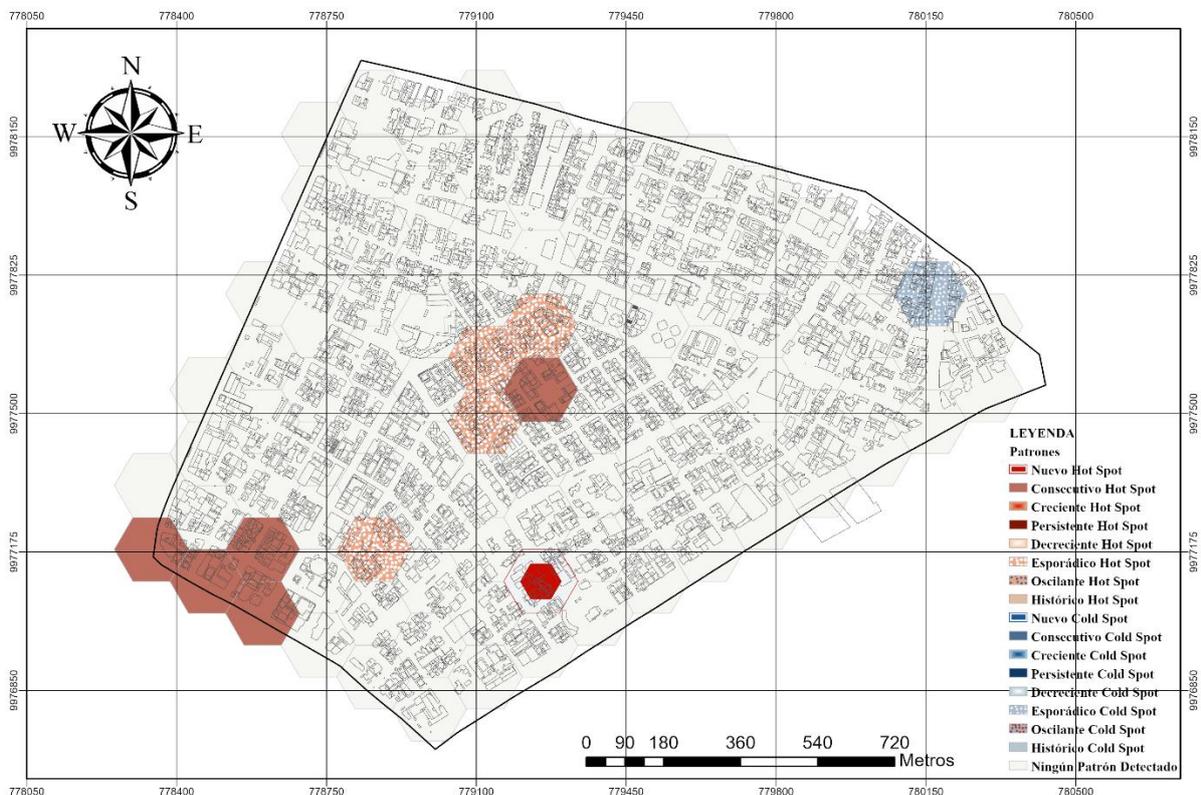
A través de la herramienta “Análisis de Puntos Calientes Emergentes” de ArcGIS Pro, se mapearon dichos patrones tomando en consideración las siguientes características:

- Para la conceptualización de relaciones espaciales se seleccionó la relación de bordes o esquinas de contigüidad, ya que los patrones de delitos están influenciados por el entorno que los rodean.
- Para identificar diferencias significativas delitos en períodos trimestrales, el paso de tiempo de vecindad seleccionado fue de 2, ya que la herramienta trabaja con base al período de tiempo del cubo espacio-temporal (1 mes), y analiza cada *bin* y los contenedores asociados en los 2 intervalos de tiempo anteriores (abarcando un total de 3 meses).

Los resultados de la representación cartográfica de los patrones espacio-temporales de delitos del año 2016 a través de la minería de datos revelan que en el epicentro y al suroeste del sector La Mariscal existe un patrón *Hot Spot* Consecutivo. Es decir, en los dos últimos meses del año se suscitó una cantidad de delitos que convierten a estas áreas en puntos calientes

significativos desde el punto de vista estadístico. Mientras que alrededor del epicentro se reporta el patrón *Hot Spot* Esporádico y se caracteriza porque en el mes de diciembre presentó un punto caliente significativo, pero en los meses anteriores tienen un historial que han sido puntos calientes y luego han dejado de serlo. Además, se identificó un punto *Cold Spot* Esporádico. Por ende, en el mes de diciembre se reportó un punto frío significativo, pero en los meses anteriores tienen un historial que han sido puntos fríos y luego han dejado de serlo. Adicionalmente en la zona sureste se localizó un patrón *Hot Spot* Nuevo, lo que quiere decir que en el mes de diciembre se presentó un punto caliente significativo, pero en los meses anteriores del año nunca lo fue.

**Mapa 3.4. Mapa de puntos calientes emergentes de delitos del año 2016**

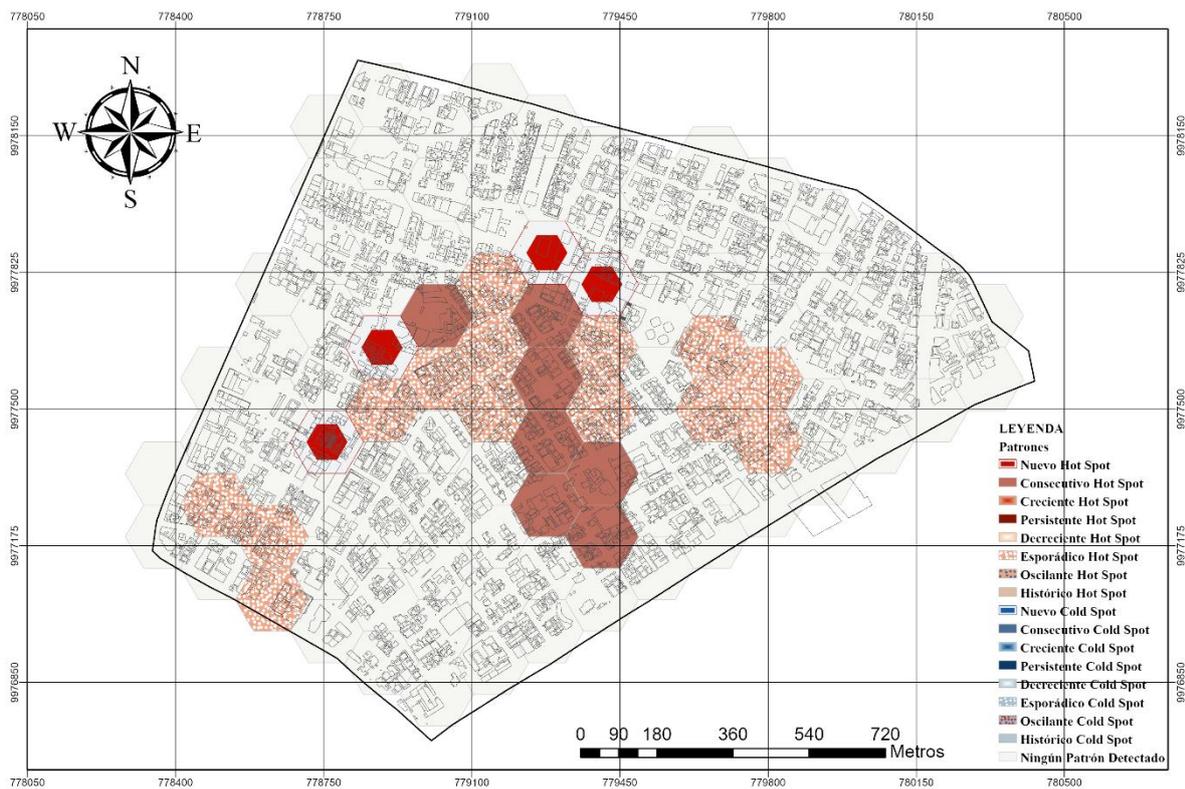


Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016)

Los resultados de la representación cartográfica de los patrones espacio-temporales de delitos del año 2017 a través de la minería de datos revelan que en sentido diagonal al epicentro del sector La Mariscal existe un patrón *Hot Spot* Consecutivo. Es decir, en los dos últimos meses del año se suscitó una cantidad de delitos que convierten a estas áreas en puntos calientes significativos desde el punto de vista estadístico, mientras que en diversas áreas de la zona de estudio se reporta el patrón *Hot Spot* Esporádico y se caracterizan porque en el mes de

diciembre presentó un punto caliente significativo, pero en los meses anteriores tienen un historial que han sido puntos calientes y luego han dejado de serlo. En cuatro puntos se observa un patrón *Hot Spot* Nuevo, lo que quiere decir que en el mes de diciembre se identificó un punto caliente significativo, pero en los meses anteriores nunca lo fue.

**Mapa 3.5. Mapa de puntos calientes emergentes de delitos del año 2017**

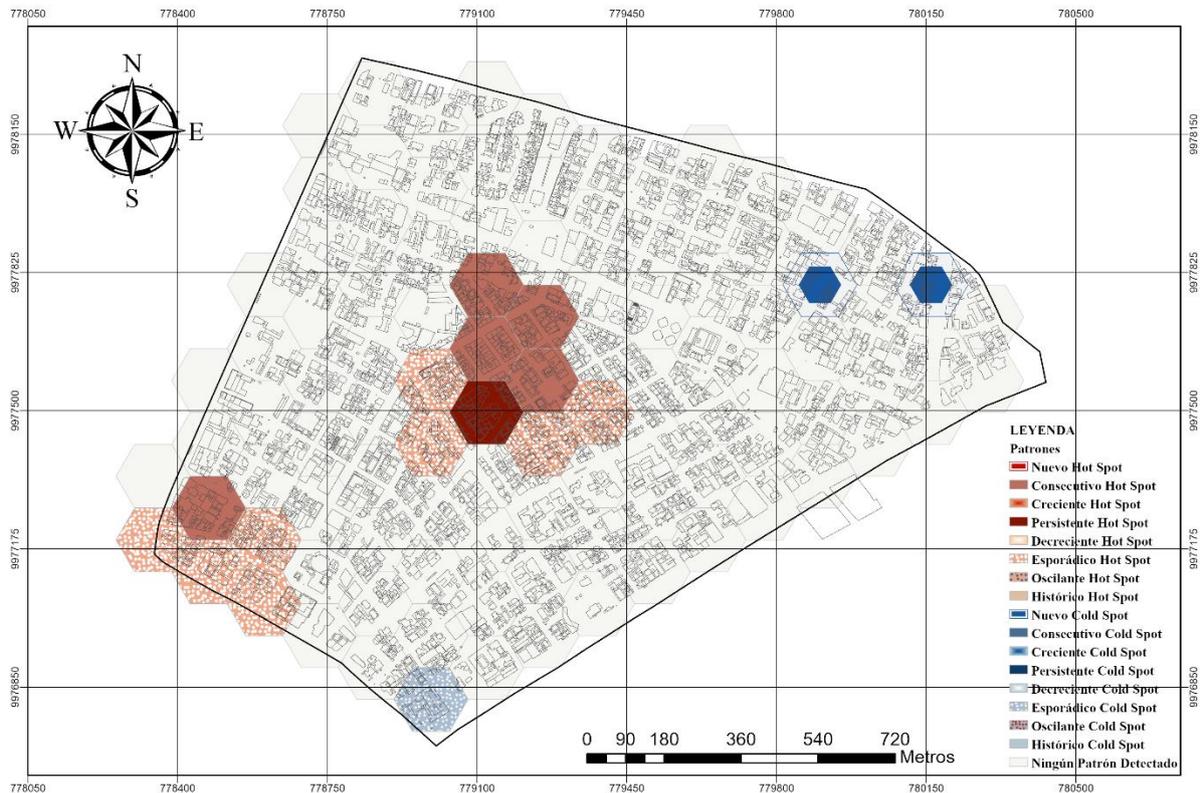


Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2017)

Los resultados de la representación cartográfica de los patrones espacio-temporales de delitos del año 2018 a través de la minería de datos revelan un patrón *Hot Spot* Persistente en el epicentro de La Mariscal. Es decir, en dicha zona en más del 90% de los meses se han suscitado puntos calientes significativos de delitos desde el punto de vista estadístico. Además, existe un patrón *Hot Spot* Consecutivo, por lo que en los dos últimos meses del año se suscitó una cantidad de delitos que convierten a estas áreas en puntos calientes significativos. Se reportan 8 puntos que presentan el patrón *Hot Spot* Esporádico y se caracterizan porque en el mes de diciembre se identificaron puntos calientes significativos, pero en los meses anteriores tienen un historial que han sido puntos calientes y luego han dejado de serlo. Además, se identificó un punto *Cold Spot* Esporádico y se caracteriza porque en el mes de diciembre se consideró como un punto frío significativo, pero en los meses

anteriores tienen un historial que han sido puntos fríos y luego han dejado de serlo. Adicionalmente en la zona Norte-Este se localizó un patrón *Cold Spot* Nuevo, lo que quiere decir que el mes de diciembre presentó un punto frío significativo, pero en los meses anteriores nunca lo fue.

**Mapa 3.6. Mapa de puntos calientes emergentes del año 2018**



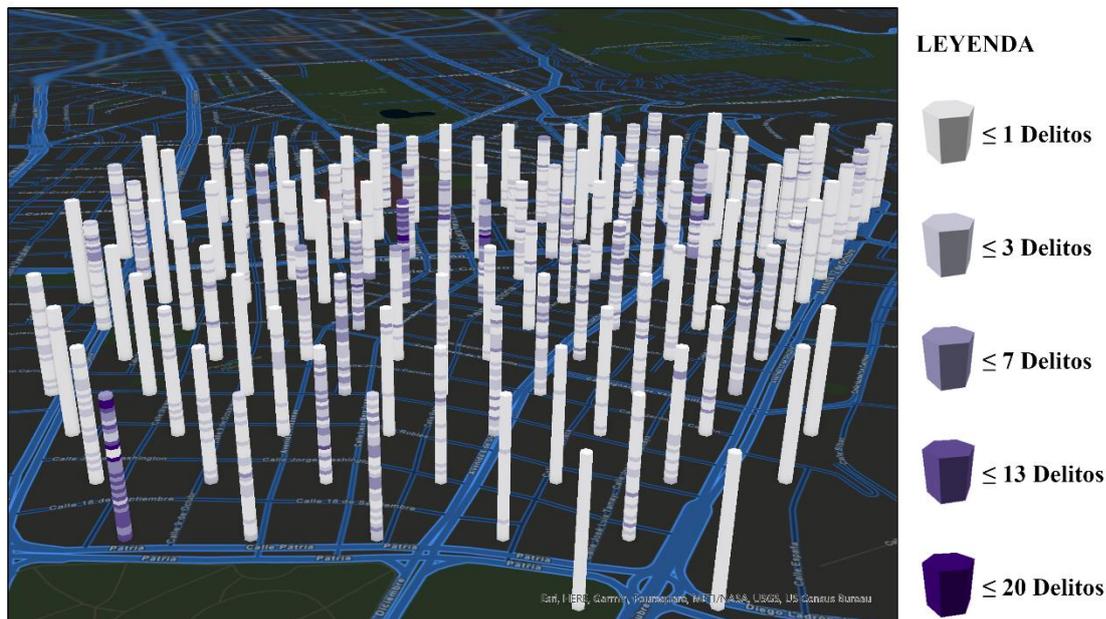
Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2018)

### 3.7. Predicción de delitos mensual en el año 2019

Para predecir la ocurrencia de delitos en cada mes del año 2019, en primera instancia, se utilizó la minería de datos y se creó un cubo espacio-tiempo con el registro de crímenes del año 2016, 2017 y 2018, que presenta las siguientes características:

- El período de tiempo de cada contenedor es de 1 mes, ya que el objetivo es predecir el número de delitos mensual en el año 2019.
- El intervalo de distancia que define la altura de cada cuadrícula hexagonal es de 150 metros, ya que esa es la longitud aproximada de las calles que delimitan a las manzanas en el sector La Mariscal.

**Gráfico 3.23. Visualización 3D del cubo espacio-tiempo de delitos del año 2016, 2017 y 2018**



Elaborado por el autor con base a datos del SIS ECU 9-1-1 (2016,2017 y 2018)

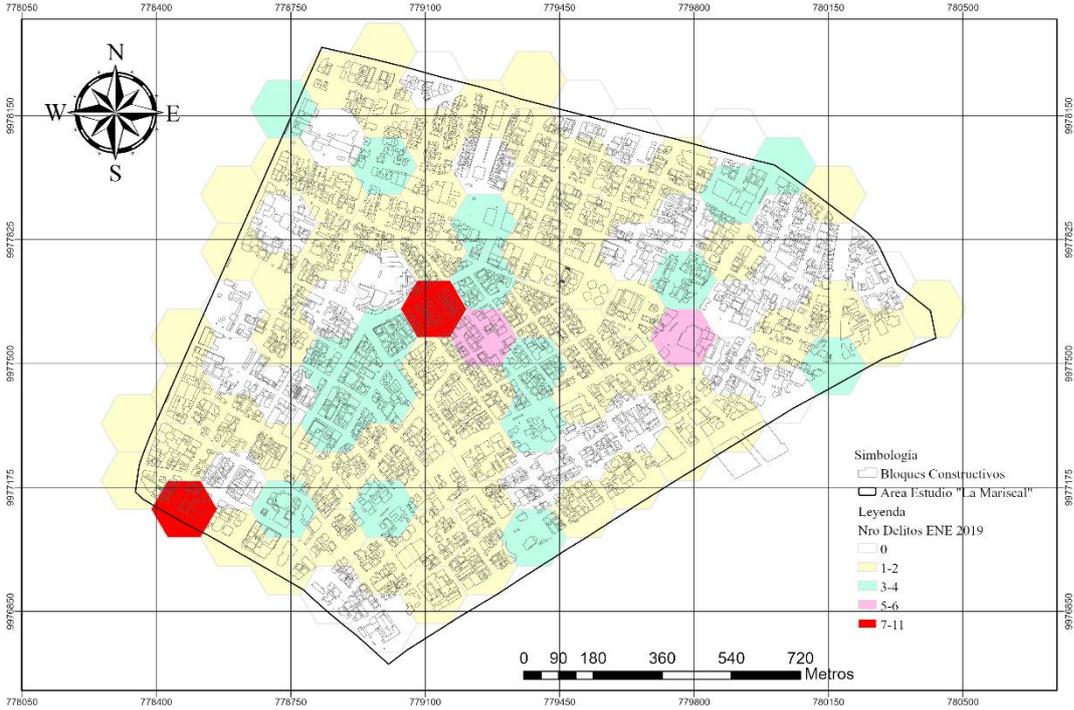
*Random Forest* es un algoritmo de inteligencia artificial que utiliza los datos de entrenamiento para crear modelos de regresión utilizando la información recopilada en cada paso de tiempo del cubo espacio-tiempo. A través de la herramienta “Predicción basada en bosque” de ArcGIS Pro, se predijo el número de delitos en el año 2019 tomando en consideración las siguientes características:

- El modelo se entrenó con base al cubo espacio-tiempo que contiene la información de delitos del año 2016, 2017 y 2018 con un paso de tiempo de un mes en cada año.
- Para el entrenamiento de la red se excluyó el 10% de la información del cubo espacio-tiempo. Mismos datos que son empleados para validar el modelo.
- Con el objetivo de obtener un modelo más preciso se utilizó 800 árboles para entrenar al algoritmo de RF.

Los resultados revelan que de enero a septiembre y de noviembre a diciembre del año 2019, el *cluster* principal de delitos se encuentra en el epicentro del sector La Mariscal con una ocurrencia de crímenes que oscila de 6 a 15 dependiendo el mes. El segundo *cluster* más recurrente en el año 2019 se localiza al Sur-Oeste de la zona de estudio, con un número de delitos que oscila entre 6 a 15 a excepción de los meses de abril, agosto, octubre y diciembre. El mes de octubre del 2019 se caracteriza porque los 2 *cluster* recurrentes de delitos se

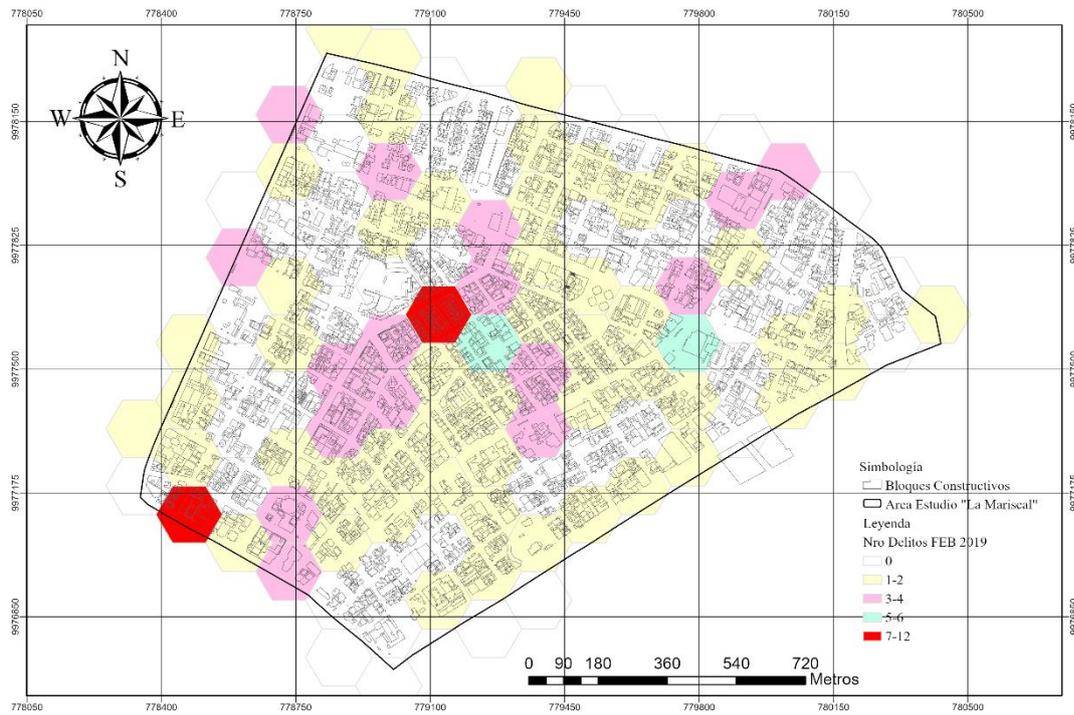
trasladan al Nor-Este y Sur-Este de La Mariscal con una presencia de crímenes de 7 a 15. Los meses de julio, septiembre, noviembre y diciembre del año 2019 presentan un *cluster* de delitos que oscila entre 6 a 13 crímenes por mes en el sitio denominado como la Plaza Foch, lugar donde se concentra la mayor actividad comercial-económica del sector. En todas las otras áreas de la zona de estudio, el número de delitos varía conforme transcurren los meses y se muestra una dinámica del crimen que cambia con el espacio y tiempo.

**Mapa 3.7. Predicción de delitos en enero del 2019**



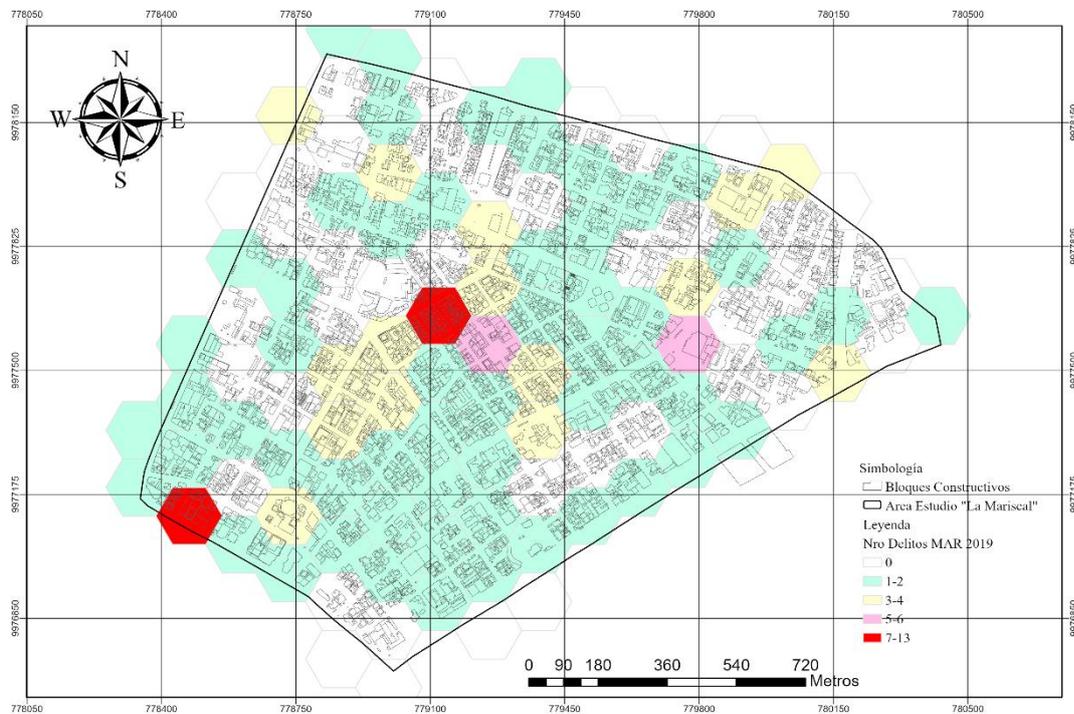
Elaborado por el autor

**Mapa 3.8. Predicción de delitos en febrero del 2019**



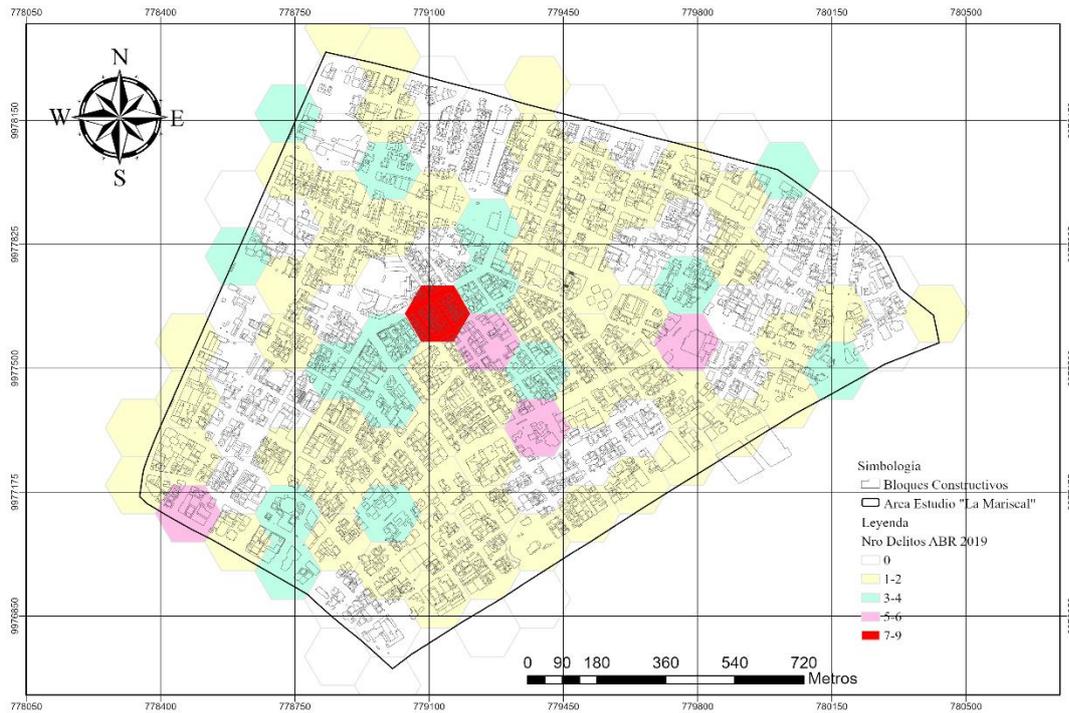
Elaborado por el autor

**Mapa 3.9. Predicción de delitos en marzo del 2019**



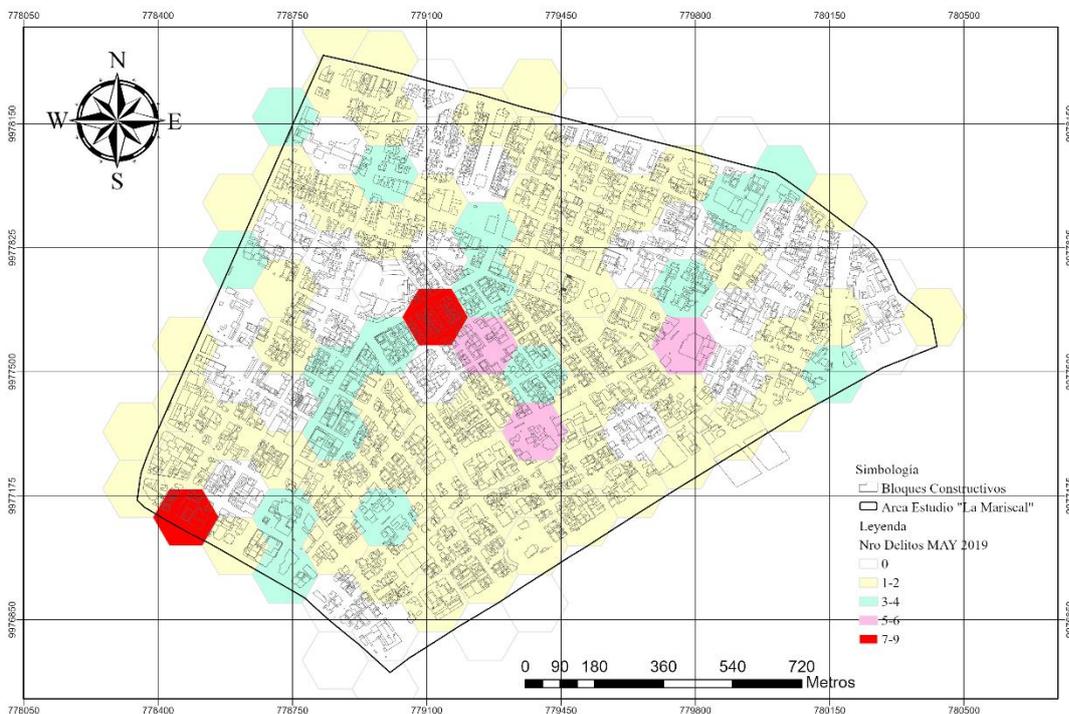
Elaborado por el autor

**Mapa 3.10. Predicción de delitos en abril del 2019**



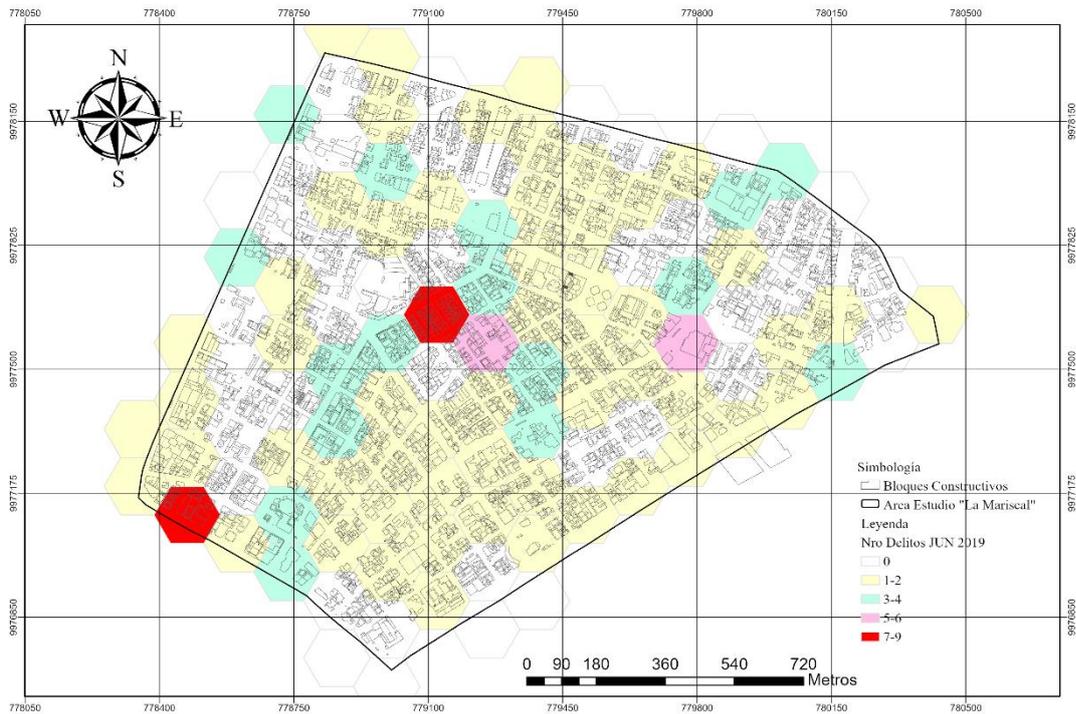
Elaborado por el autor

**Mapa 3.11. Predicción de delitos en mayo del 2019**



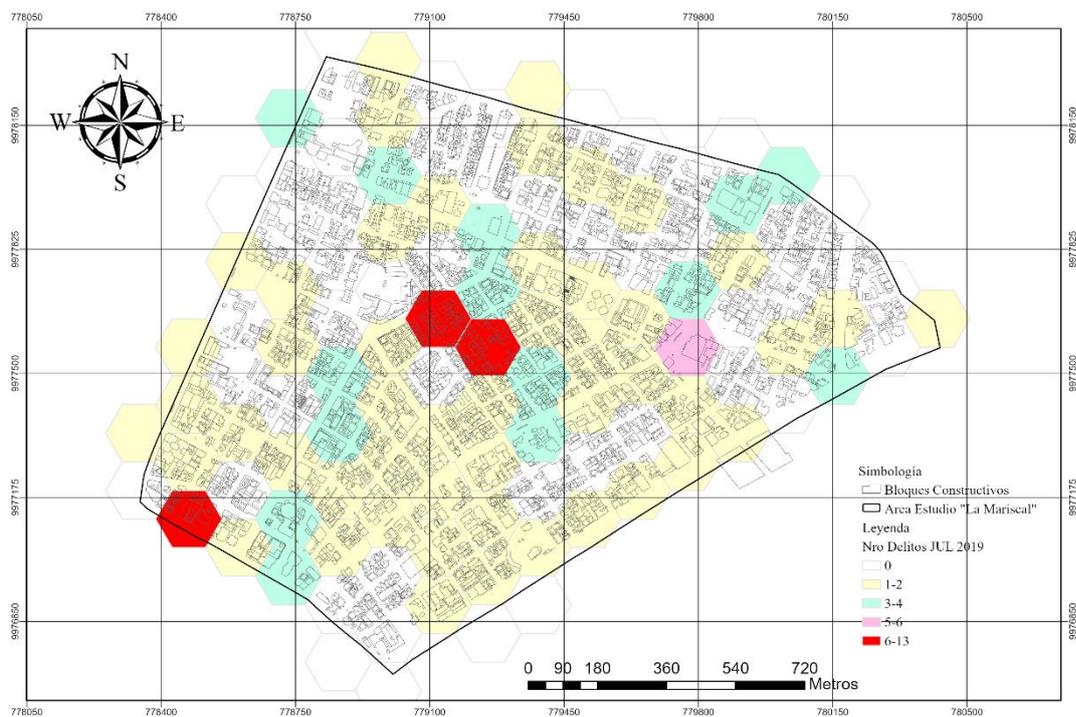
Elaborado por el autor

**Mapa 3.12. Predicción de delitos en junio del 2019**



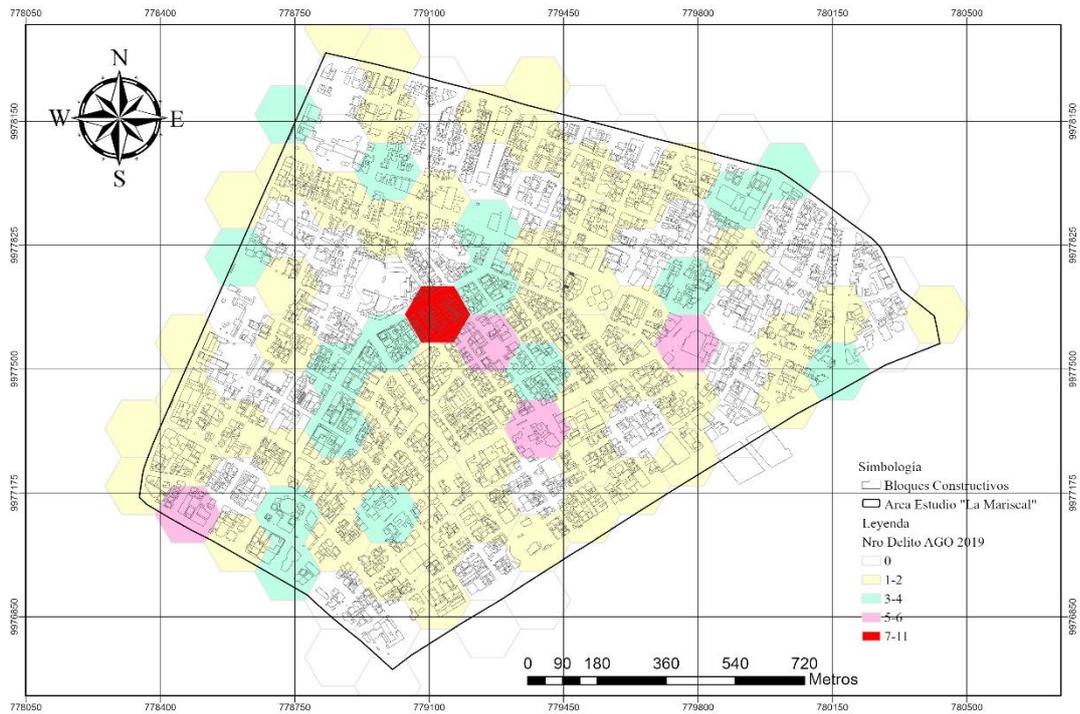
Elaborado por el autor

**Mapa 3.13. Predicción de delitos en julio del 2019**



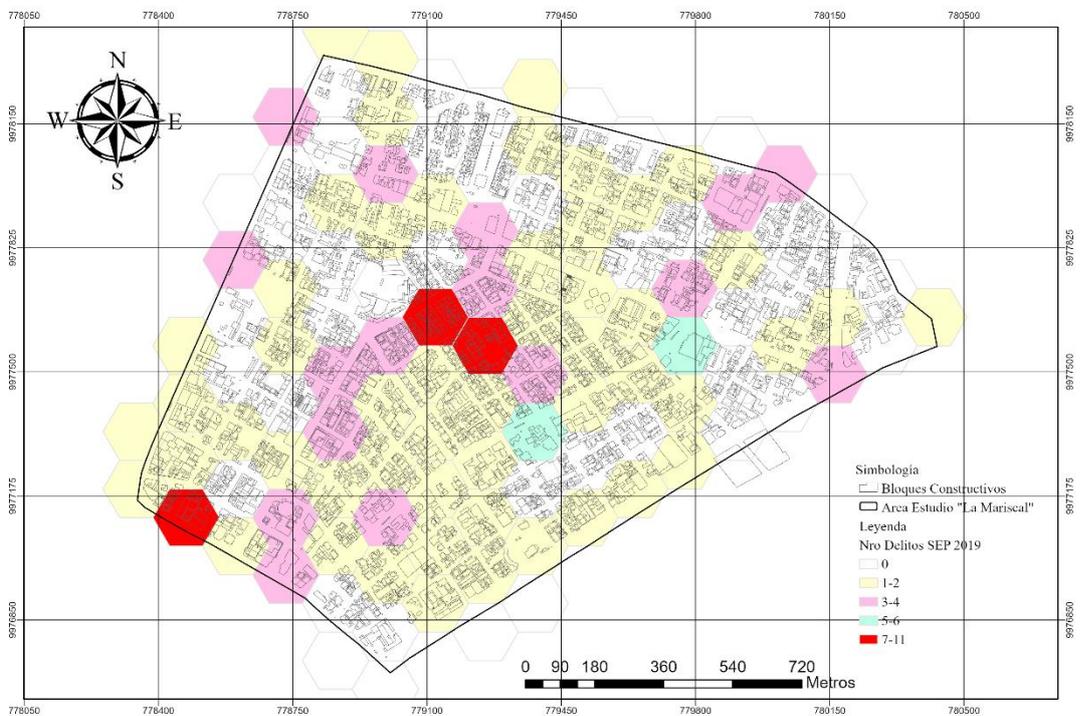
Elaborado por el autor

**Mapa 3.14. Predicción de delitos en agosto del 2019**



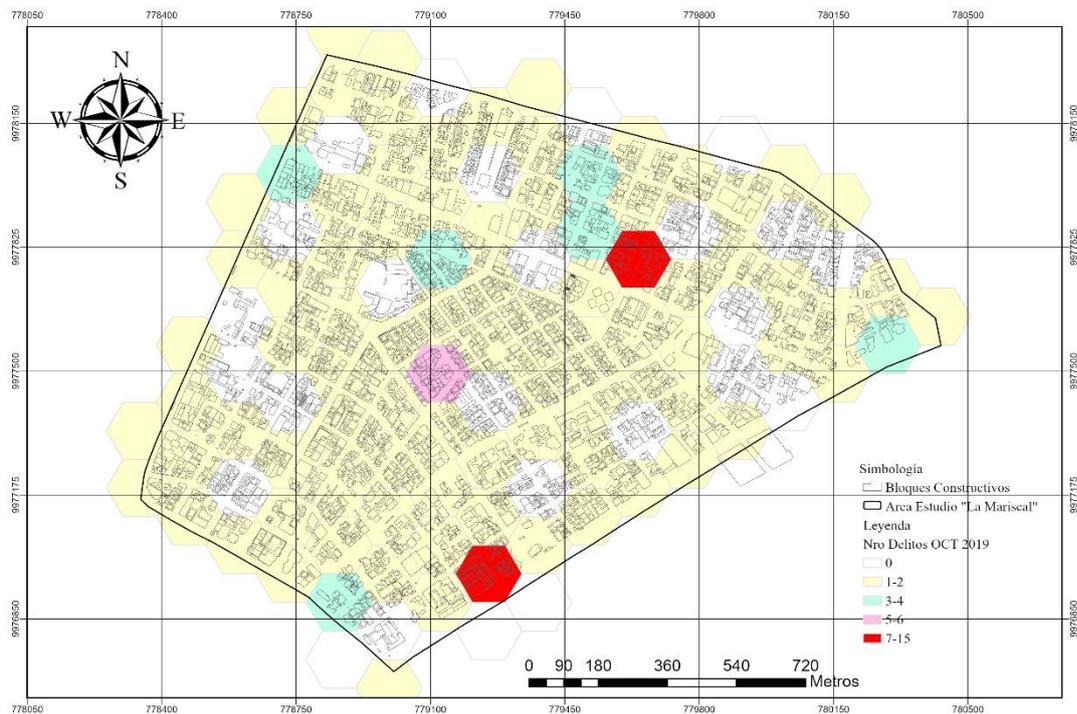
Elaborado por el autor

**Mapa 3.15. Predicción de delitos en septiembre del 2019**



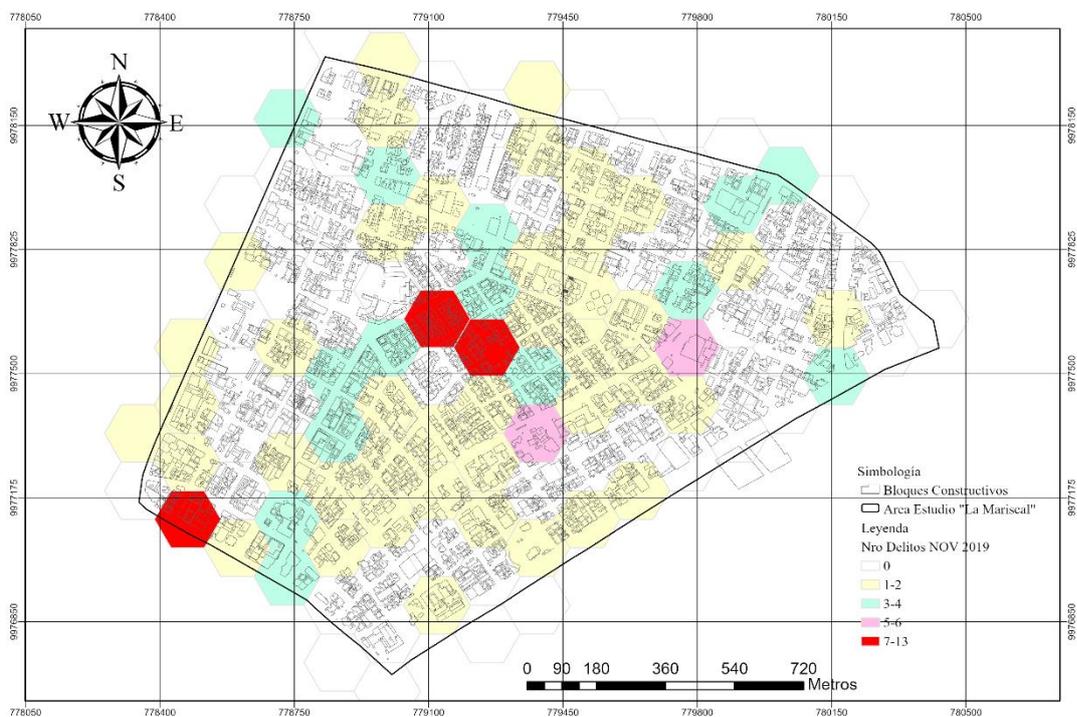
Elaborado por el autor

**Mapa 3.16. Predicción de delitos en octubre del 2019**



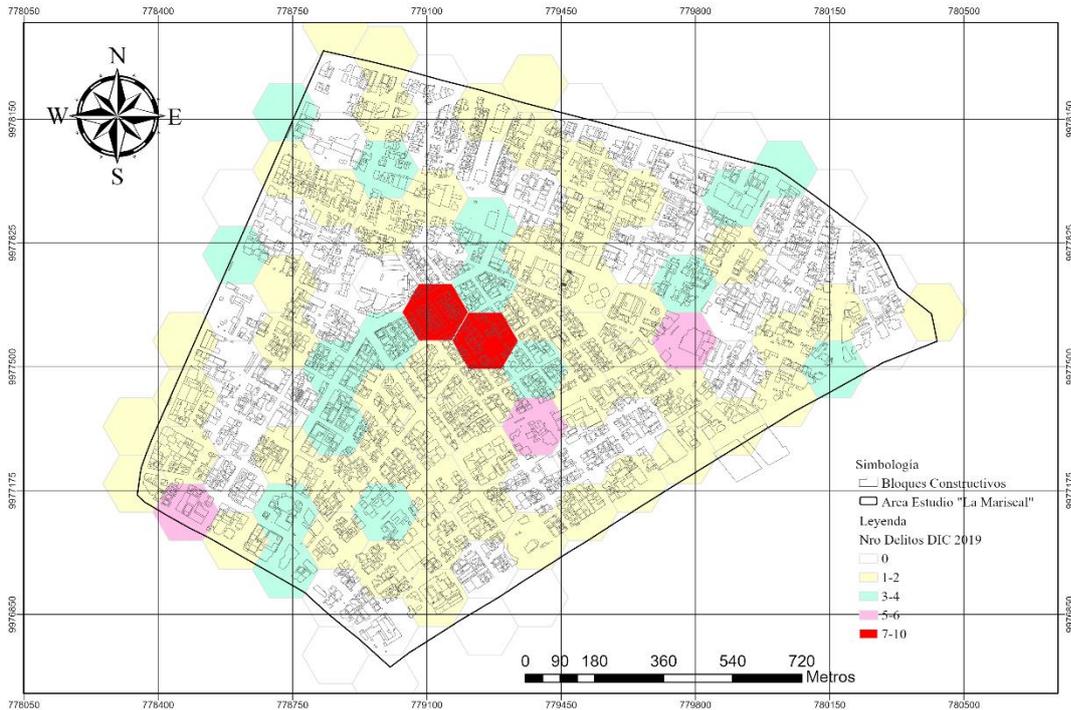
Elaborado por el autor

**Mapa 3.17. Predicción de delitos en noviembre del 2019**



Elaborado por el autor

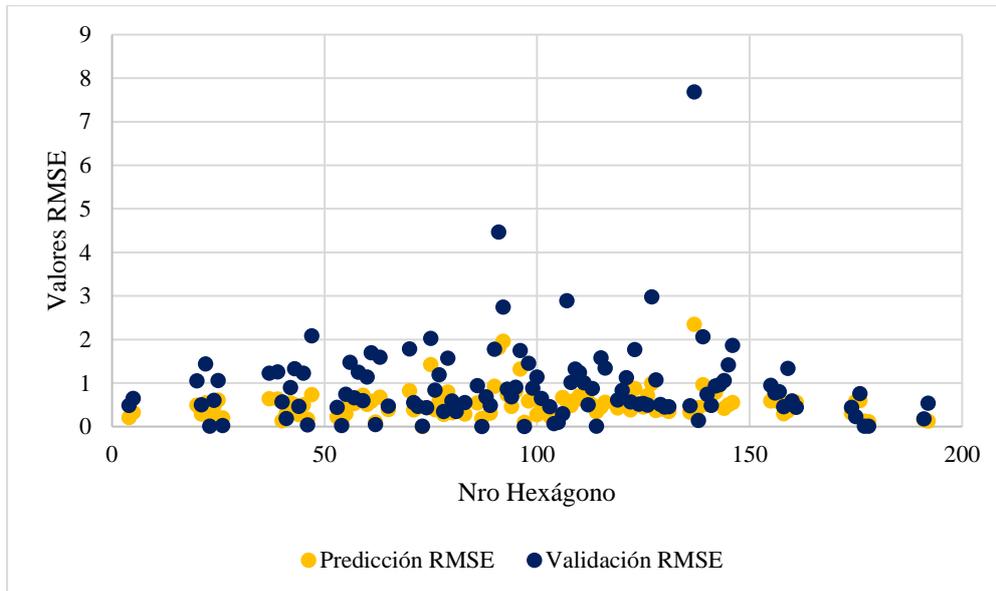
**Mapa 3.18. Predicción de delitos en diciembre del 2019**



Elaborado por el autor

Se reporta que los valores de RMSE de predicción oscilan entre 0 y 2, por lo que, el modelo de *Random Forest* se ajusta con una buena precisión a los datos brutos de delitos con los cuales se entrenó al algoritmo. Mientras que los datos RMSE de validación varían entre 0 y 2, lo que quiere decir que el número de delitos predichos podrían fluctuar con respecto a los valores reales en aproximadamente 1 a 2 delitos, a excepción de un sitio en específico dónde el modelo puede variar hasta 7 delitos. Es decir, en líneas generales el modelo de RF presenta una buena precisión al momento de realizar la predicción de delitos futuros.

**Gráfico 3.24. Valores de RMSE de predicción y validación del modelamiento de delitos en el sector La Mariscal**



Elaborado por el autor

### 3.8. *Dashboard* de delitos del sector La Mariscal

El tablero de control de delitos fue desarrollado con la aplicación de *Dashboard* de *ArcGIS Online* que es un software de mapeo SIG basado en la nube. Para ello, fue fundamental crear mapas web con técnicas de *smart mapping* que contengan la información gráfica y alfanumérica de los registros georreferenciados de delitos del año 2016, 2017 y 2018.

El *Dashboard* de delitos presenta las siguientes funcionalidades:

1. Contador del número total de delitos.
2. Una lista que detalla más información de cada delito.
3. Gráfico dinámico de una serie temporal de delitos por año, mes y día.
4. Gráfico dinámico de una serie temporal de delitos por horas del día.
5. Cartografía web de los delitos georreferenciados.
6. Filtro de información, para que los usuarios puedan acceder a métricas de delitos dependiendo: a) tipo de delito, b) año, c) mes, d) día y e) hora del día.

Figura 3.1. Dashboard de delitos del sector La Mariscal



Elaborado por el autor

[4]

[3]

Cabe recalcar que todas las funcionalidades mencionadas anteriormente están interconectadas entre sí. Es decir, cualquier acción que realice el usuario dentro del *Dashboard* para consultar o visualizar alguna información en particular, modificará las métricas de todo tablero.

## Capítulo 4. Discusión

En América Latina uno de cuatro ciudadanos afirma que la inseguridad es uno de los principales problemas de su vida (Jaitman y Ajzenman 2016). Este panorama trasladado a La Mariscal, que es la zona rosa más grande de la ciudad de Quito, donde aproximadamente llegan de manera mensual más de 200.000 visitantes (La Hora 2019) es preocupante, ya que dicha zona se ha convertido en un *cluster* para la delincuencia porque las personas que visitan y habitan el sector en su mayoría pertenecen a una clase económica de media a alta. Ante este panorama, desde el año 2013 administradores de negocios y policía nacional han intentado implementar un sistema de seguridad integral que permita a los turistas y residentes disfrutar de todas las opciones culturales, gastronómicas y centros de entrenamiento que ofrece el centro norte de la ciudad (Romero 2017). Sin embargo, en la presente investigación se reportó que tan solo 14 días del 2016, 7 días del 2017 y 10 días del 2018 no hubo presencia de delitos. Además, en el 2017 se registró un mayor número de delitos que en el 2016 y el número de delitos del 2018 es menor a los reportados en el 2017 pero sigue siendo mayor que los reportados en el 2016. Es decir, las acciones implementadas en contra de la criminalidad desde años anteriores hasta el 2018, han sido insuficientes. Estos resultados por una parte, podrían estar sustentados con el Plan Especial ‘La Mariscal’ (2017), donde se menciona que en el sector La Mariscal existe una tendencia de decrecimiento poblacional que está directamente relacionado con la inseguridad ciudadana.

La Mariscal es el epicentro de la vida nocturna de la capital ecuatoriana y debido a su uso de suelo tan característico y diverso, los 5 delitos más representativos que se han suscitado en el año 2016, 2017 y 2018 son: robos, hurto, violencia contra la mujer o núcleo familiar, secuestro y comercialización de sustancias sujetas a fiscalización, siendo los dos primeros los más significativos. Estos resultados se asemejan al estudio realizado por Suquillo (2015), el cual entrevistó a 300 habitantes del sector La Mariscal y obtuvo como resultado que el 20% y 80% habían sufrido hurtos y robos respectivamente. Lo ideal es comparar entre diferentes ciudades de la región los delitos más comunes en espacios urbanos con características similares, con el objetivo de encontrar patrones en común, pero es un gran ausente de la literatura científica información sobre la actividad delictiva según su tipología en lugares de ocio (Cooper 2007).

Los resultados revelan que, en el año 2016, 2017 y 2018 no existieron diferencias significativas en la ocurrencia de delitos por su nivel de importancia entre las diferentes manzanas de La Mariscal. Este reporte difiere a los hallazgos de diversos trabajos de

investigación donde mencionan que las actividades delictivas solo pueden ocurrir en un número finito de lugares y solo si los entornos sociales y físicos son los propicios para los infractores (Newton y Felson 2015), lo cual es entendible ya que la escala de análisis es diferente. En este contexto, también se determinó que existen diferencias significativas en la ocurrencia de delitos por su nivel de importancia entre las 06h00-14h00, 14h00-22h00 y 22h00 a 06h00 horas, estos resultados concuerdan con los datos recabados de Quito del departamento de análisis de la información de la policía nacional del Ecuador, donde se ha determinado que en los horarios de 5:30 a 8:30 y de 16:30 a 20:30 presentan el mayor índice de delitos al día (La Hora 2022). Además, se reportó en el presente estudio, que no existen diferencias significativas en la ocurrencia de delitos por su nivel de importancia entre los diferentes meses del año. En este sentido, difiere a los resultados de Yuki et al. (2019) y el estudio realizado en Ecuador por consultora CID Gallup. Con base a este contexto, se corrobora que las dinámicas espaciales y temporales de delitos son propias de cada territorio, por lo que, se vuelve necesario analizar el crimen en micro-lugares.

Referente a la causalidad de delitos, los resultados demuestran que el número de los lugares de ocio podrían explicar la ocurrencia de delitos y son varios los autores que han encontrado una relación entre las dos variables (Savard et al. 2019; Cueva 2022; Trangenstein et al. 2018) aduciendo que los bares y cualquier lugar de diversión crean escenarios propicios para la ocurrencia de crímenes; esto podría deberse a que las personas disminuyen sus capacidades cognitivas y son más vulnerables ante situaciones adversas cuando consumen elevadas cantidades alcohol. Por otra parte, se reportó que el número de cámaras de videovigilancia podrían explicar en un 95% la ocurrencia de delitos, lo cual se contrapone a los hallazgos de Piza et al. (2019) y Priks (2015) que encontraron una asociación entre unidades de videovigilancia y reducción de delitos, lo cual no significa que las cámaras de monitoreo son atractores del crimen, sino que probablemente sea necesario combinar el sistema de videovigilancia actual con señalización, iluminación mejorada, control policial, botones de pánico y diversas acciones que permitan mejorar la eficacia del sistema como se menciona en la literatura.

En el caso de la variable tamaño de la población, se encontró que no existe evidencia significativa que pueda influir en la ocurrencia de delitos en el sector La Mariscal, lo cual difiere a los hallazgos de Hashim et al. (2019) sobre un incremento de 0,556 en la tasa de delincuencia por el aumento de cada unidad de población. En lo que respecta al arbolado urbano, los resultados demuestran que no existe ninguna causalidad de la variable en la

ocurrencia de delitos, por lo que, se contrapone al hallazgo de Michael, Hull, y Zahm (2001), los cuales reportaron que los criminales al momento de cometer actos delictivos, buscan una fuente posible de ocultación post-delito para minimizar el riesgo de ser atrapados. Por tal motivo, optan por delinquir en áreas cercanas a una densa vegetación para facilitar su escape. Referente a la densificación espacial de delitos, diversos autores reportan que la distribución del crimen no es aleatoria en el espacio y está regulado por los entornos urbanos con los que interactúan los delincuentes (Cohen y Felson 1979; Brantingham y Brantingham 2013). En este sentido, los resultados obtenidos apoyan dichas premisas, ya que el *cluster* principal de delitos se localiza en el epicentro de La Mariscal dónde se concentra el mayor número de bares, discotecas y restaurantes de toda zona de estudio, por lo que, estos lugares contribuyen a la ocurrencia de crímenes y se convierten en atractores de delitos. Además, se corroboró que los patrones de delitos son dinámicos en el espacio-tiempo (Brantingham y Brantingham 2013; Newton y Felson 2015) aduciendo que en el año 2016 el *cluster* principal de delitos se localizaba al Nor-Oeste y Sur-Oeste de la Plaza Foch, para el año 2017 el patrón del crimen se desplazó en sentido Este desde epicentro de La Mariscal y en el año 2018 además de mantener la misma dinámica del año anterior se generó un nuevo *cluster* de delitos al Este de la Plaza Foch.

En línea con lo mencionado en el apartado anterior, se reportó que los resultados obtenidos mediante el análisis de puntos calientes emergentes del 2016, 2017 y 2018 varían en el espacio-tiempo, por lo que se corrobora lo planteado por Brantingham y Brantingham (2013). Pero las ventajas de trabajar con cubos espacio-temporales es que brindan una visión diferente a los resultados provenientes de la densificación de delitos, por ejemplo, el 94% de los patrones de delitos detectados corresponden a *clusters* relacionados a *HotSpot* y dichos lugares se consideran zonas donde se concentran los delitos con un patrón estadísticamente significativo y no aleatorio en el espacio-tiempo (Hart y Zandbergen 2014), y tan solo el 6% se atribuyen a *clusters* relacionados a *ColdSpot*. Newton y Felson (2015) argumentaron que la ocurrencia de delitos requiere de la yuxtaposición de delincuentes motivados y objetivos adecuados en una situación determinada en el espacio-tiempo y según los hallazgos La Mariscal presenta esta composición físico-social requerida para la actividad delictiva. Establecer una discusión teórica de la presente metodología con otras investigaciones, tiene sus limitaciones ya que existe una literatura limitada sobre el análisis de patrones delictivos en el espacio y tiempo (Brunsdon, Corcoran, y Higgs 2007; Newton y Felson 2015).

La metodología de análisis predictivo de delitos con cubos espacio-temporales y técnicas de *machine learning* están alineadas a lo expuesto por LeBeau y Leitner (2011), Bunting et al. (2017) y Saraiva et al. (2022), los cuales mencionan que es esencial el análisis de patrones delictivos con técnicas espaciales y estadísticas, pero es necesario implementar métodos de aprendizaje automático para obtener un enfoque más amplio de las dinámicas de los crímenes y con ello optimizar las políticas de planificación, cohesión y prevención de delitos (Weisburd et al. 2021). El algoritmo de *Random Forest* (RF) se ha utilizado para extraer patrones de crímenes y predecir eventos futuros en diversos estudios de Wheeler y Steenbeek (2020), Saraiva et al. (2022) y Deshmukh et al. (2020) y han obtenido que los modelos de inteligencia artificial pueden usarse de manera efectiva pero se requiere más investigación y discusión en la literatura científica. Dicha premisa respalda los resultados obtenidos, ya que el modelo de RF presentó valores bajos del error cuadrático medio de predicción y validación, en otras palabras, el algoritmo se ajustó con una buena precisión a los datos brutos de delitos y el número de crímenes predichos podría variar entre 1 a 2 de los valores reales. Es decir, en el 2019 la ocurrencia de delitos sigue siendo significativa, es dinámica en el espacio-tiempo y se caracteriza por presentar un *cluster* de crímenes recurrente en la Plaza Foch. Esto coincide con un reporte del diario La Hora realizado en La Mariscal en el 2019 dónde menciona que los crímenes se mantienen y sus calles están marcadas por robos, arranque de carteras y venta de droga.

El campo de investigación de delitos es amplio, lo que brinda la oportunidad de plantear diversas propuestas metodológicas para contrarrestar esta problemática urbana, una de ellas es la aplicación de técnicas de *smart mapping*. Según Loo and Tang (2019) el mapeo inteligente empodera la participación ciudadana en el desarrollo de *smart cities* y facilitan la comunicación entre los ciudadanos y entes gubernamentales; y Blanco y Tudela (2010) reconocen que el análisis de delitos es un fenómeno multidimensional y los actores llamados a dar respuesta a esta problemática son diversos y es fundamental un trabajo articulado entre la población y el estado. Esto proporciona una base teórica de la importancia del *Dashboard* de delitos de La Mariscal que se desarrolló con base a los pilares de *smart mapping* y puede ser empleado para generar una comunidad informada y resiliente, mejorar la gobernanza y toma de decisiones al disponer de datos de delitos en tiempo real y sobre todo involucrar a la ciudadanía para un trabajo en conjunto en contra de la delincuencia.

## Conclusiones

El presente trabajo de investigación generó una evidencia empírica con respecto al análisis de diferencias significativas en la ocurrencia de delitos entre manzanas, horas del día y meses en una zona donde el uso de suelo es tan diverso y se caracteriza por ser un punto de encuentro para la diversión nocturna y turismo nacional e internacional. Los resultados revelan que, en cualquier lugar de La Mariscal y mes del 2016, 2017 y 2018 se reportó una similar frecuencia de delitos mientras que en determinados períodos de tiempo ocurrieron delitos con mayor frecuencia que en otras horas del día según su nivel de importancia. En líneas generales, toda la zona de estudio presenta un panorama de inseguridad que es prácticamente homogéneo en el transcurso de los meses del año, pero en ciertas horas del día se comenten delitos con una mayor frecuencia, por lo que, se vuelve una prioridad plantear operativos de seguridad permanentes.

Los principales hallazgos obtenidos al realizar el análisis de correlación y causalidad de delitos mediante modelos de regresión lineal por mínimos cuadrados, es que las variables cámaras de videovigilancia y lugares de ocio podrían explicar en un 95% la ocurrencia de delitos en La Mariscal. En consecuencia, es imprescindible ejecutar diversas estrategias de seguridad en lugares cercanos a bares, discotecas, karaokes y cualquier otro centro de diversión que opera en la zona de estudio, además es prioritario mejorar el sistema de videovigilancia con la implementación de botones de pánico, señalización y acciones que conviertan al sistema de monitoreo actual como un elemento disuasorio de delitos. Por otro lado, se reportó que no existe evidencia significativa que las variables de arbolado urbano, número de bloques constructivos y número de personas puedan influir en el cometimiento de delitos, mientras que otros autores han encontrado que dichas variables pueden ser consideradas como atractores de delitos. Por lo que, es necesario profundizar en el espacio urbano de la zona de estudio y buscar más variables cuantificables que pueden influir en la ocurrencia de delitos.

La ocurrencia de delitos en La Mariscal es dinámica en el espacio y tiempo, la evidencia más clara es que desde el año 2016 hasta el 2018, el *cluster* de delitos que se localizaba al Oeste del epicentro de la zona de estudio creció en sentido oriental hasta cubrir totalmente la Plaza Foch y generar otro *cluster* al Este de dicho lugar. Además, la zona rosa más grande de la ciudad de Quito brinda las condiciones requeridas para la actividad delictiva ya que la mayoría de los patrones detectados con minería de datos están relacionados con *clusters* de tipo *HotSpot*. A este panorama se añade que, la predicción de delitos para el año 2019 revela

que la actividad delictiva muy probablemente se mantendrá en lugares específicos y en otros sitios se intensificará según la temporalidad. Todos estos hallazgos, refuerzan la importancia de contar con modelos explicativos y predictivos de delitos para apoyar la toma de decisiones y plantear políticas efectivas contra el crimen. Sin embargo, el conocimiento estadístico, espacial y aprendizaje automático no poseen todas las instituciones responsables de la seguridad ciudadana, por lo que es prioritario realizar un trabajo interinstitucional entre la academia y entes gubernamental para potenciar la inteligencia y vigilancia policial.

Finalmente, el *Dashboard* de delitos es una herramienta simple y fácil de usar que podría convertirse en la piedra angular para promover la participación ciudadana en la lucha contra la inseguridad y mejorar la toma de decisiones en materia de prevención y gestión de la ciudad. Además, agregando más información y establecimiento las medidas y políticas de seguridad adecuadas, los tomadores de decisiones y policía nacional podrían incorporar en sus instituciones un tablero de control similar ya que necesitan de una plataforma común donde toda la información espacio-temporal de delitos pueda ser compartida y analizada en tiempo real por expertos para calcular indicadores, ejecutar acciones de pronta de respuesta y elaborar de planes de seguridad que contribuyan de manera efectiva en la reducción de delitos.

## Referencias

- Albino, Vito, Umberto Berardi, and Rosa Maria Dangelico. 2015. "Smart Cities: Definitions, Dimensions, Performance, and Initiatives." *Https://Doi.Org/10.1080/10630732.2014.942092* 22 (1): 3–21.
- Andresen, Martin A. 2006. "A Spatial Analysis of Crime in Vancouver, British Columbia: A Synthesis of Social Disorganization and Routine Activity Theory." *The Canadian Geographer / Le Géographe Canadien* 50 (4): 487–502. <https://doi.org/10.1111/J.1541-0064.2006.00159.X>.
- Babakura, Abba, Md Nasir Sulaiman, and Mahmud A. Yusuf. 2014. "Improved Method of Classification Algorithms for Crime Prediction." *Proceedings - 2014 International Symposium on Biometrics and Security Technologies, ISBAST*. <https://doi.org/10.1109/ISBAST.2014.7013130>.
- Badurek, C. 2007. "Facilitating Sociological Inquiry into Spatial Displacement with GIS." *Sociation Today* 5, no. 1.
- Bandekar, Shraddha Ramdas, and C. Vijayalakshmi. 2020. "Design and Analysis of Machine Learning Algorithms for the Reduction of Crime Rates in India." *Procedia Computer Science* 172 (January): 122–27. <https://doi.org/10.1016/J.PROCS.2020.05.018>.
- Berk, Richard A., and Justin Bleich. 2013. "Statistical Procedures for Forecasting Criminal Behavior." *Criminology & Public Policy* 12 (3): 513–44. <https://doi.org/10.1111/1745-9133.12047>.
- Bivand, Roger S, and David W S Wong. 2018. "Comparing Implementations of Global and Local Indicators of Spatial Association."
- Blanco, J, and P Tudela. 2010. "Retos de La Política Pública Para La Participación Ciudadana En La Coproducción de La Seguridad." *Concepto*, no. 19.
- Blumstein, Alfred, and Elizabeth Graddy. 1981. "Prevalence and Recidivism in Index Arrests: A Feedback Model." *Law & Society Review* 16 (2): 265. <https://doi.org/10.2307/3053360>.
- Bouskela, M, M Casseb, S Bassi, C De Luca, and M Facchina. 2016. *La Ruta Hacia Las Smart Cities: Migrando de Una Gestión Tradicional a La Ciudad Inteligente*. Banco Interamericano de Desarrollo (BID).
- Braga, A. 2006. "The Crime Prevention Value of Hot Spots Policing." *Psicothema* 18 (3): 630–37.
- Braga, Anthony A., Andrew V. Papachristos, and David M. Hureau. 2010. "The Concentration and Stability of Gun Violence at Micro Places in Boston, 1980-2008." *Journal of Quantitative Criminology* 26 (1): 33–53. <https://doi.org/10.1007/S10940-009-9082-X/TABLES/5>.
- Brantingham, P, and L Brantingham. 2013. "The Theory of Target Search." In *The Oxford Handbook of Criminological Theory*, edited by F Cullen and P Wilcox, 535–53. New York, NY: Oxford University Press. <https://doi.org/10.1093/OXFORDHB/9780199747238.001.0001>.
- Brantingham, Paul, and Patricia Brantingham. 2013. "Crime Pattern Theory." *Environmental Criminology and Crime Analysis*, May, 100–116. <https://doi.org/10.4324/9780203118214-13>.

- Brantingham, Paul J., and Patricia L. Brantingham. 1984. *Patterns in Crime*. New York : Macmillan.
- Breiman, Leo. 2001. “Random Forests.” *Machine Learning* 45 (1): 5–32. <https://doi.org/10.1023/A:1010933404324/METRICS>.
- Brunsdon, Chris, Jonathan Corcoran, and Gary Higgs. 2007. “Visualising Space and Time in Crime Patterns: A Comparison of Methods.” *Computers, Environment and Urban Systems* 31 (1): 52–75. <https://doi.org/10.1016/J.COMPENVURBSYS.2005.07.009>.
- Bunge, W. 2017. *Las Expediciones Geográficas Urbanas*. Edited by Núria. Benach. 1era ed. Barcelona: Icaria.
- Bunting, Ryan J., Oliver Yang Chang, Christopher Cowen, Richard Hankins, Staci Langston, Alexander Warner, Xi Xia Yang, Eric R. Louderback, and Shouraseni Sen Roy. 2017. “Spatial Patterns of Larceny and Aggravated Assault in Miami–Dade County, 2007–2015.” *The Professional Geographer* 70 (1): 34–46. <https://doi.org/10.1080/00330124.2017.1310622>.
- Cabrera-Barona, Pablo, and Helena Merschdorf. 2018. “A Conceptual Urban Quality Space-Place Framework: Linking Geo-Information and Quality of Life.” *Urban Science* 2 (3): 73. <https://doi.org/10.3390/URBANSCI2030073>.
- Campedelli, Gian Maria, Alberto Serena, and Alex R. Piquero. 2020. “Disentangling Community-Level Changes in Crime Trends during the COVID-19 Pandemic in Chicago.” *Crime Science* 9 (1): 1–18. <https://doi.org/10.1186/S40163-020-00131-8/TABLES/6>.
- Caragliu, Andrea, Chiara Bo, and Peter Nijkamp. 2011. “Smart Cities in Europe.” *Journal of Urban Technology* 18 (2): 65–82. <https://doi.org/10.1080/10630732.2011.601117>.
- CEPAL. 2018. “Barómetro de Las Américas.” 2018. [https://www.cepal.org/sites/default/files/presentations/presentacion-el-barometro-de-las-americas-noam\\_lupu-lapop.pdf](https://www.cepal.org/sites/default/files/presentations/presentacion-el-barometro-de-las-americas-noam_lupu-lapop.pdf).
- Chainey, S, Lisa Tompson, and Sebastian Uhlig. 2008. “The Utility of Hotspot Mapping for Predicting Spatial Patterns of Crime.” *Security Journal* 21 (1): 4–28. <https://doi.org/10.1057/PALGRAVE.SJ.8350066>.
- Chainey, Spencer P., and Dennis L. Lazarus. 2021. “More Offenders, More Crime: Estimating the Size of the Offender Population in a Latin American Setting.” *Social Sciences 2021, Vol. 10, Page 348* 10 (9): 348. <https://doi.org/10.3390/SOCSCI10090348>.
- Changoluisa, Silvana. 2021. “Optimización Del Tiempo de Asignación de Los Recursos Del Sistema Integrado ECU-911 Mediante El Uso de Herramientas Geoinformáticas: Zona Piloto Del DMQ.” Quito: Universidad de las Fuerzas Armadas ESPE.
- Ching, Tuan Yee, and Joseph Ferreira. 2015. “Smart Cities: Concepts, Perceptions and Lessons for Planners.” *Lecture Notes in Geoinformation and Cartography* 213: 145–68. [https://doi.org/10.1007/978-3-319-18368-8\\_8/COVER](https://doi.org/10.1007/978-3-319-18368-8_8/COVER).
- Cocchia, Annalisa. 2014. “Smart and Digital City: A Systematic Literature Review.” *Smart City*, 13–43. [https://doi.org/10.1007/978-3-319-06160-3\\_2](https://doi.org/10.1007/978-3-319-06160-3_2).
- Cohen, B. 2013. “The Smart Cities in the World: Methodology.” 2013. <https://www.fastcompany.com/3038818/the-smartestcities-in-the-world-2015-methodology>.

- Cohen, Lawrence, and Marcus Felson. 1979. "Social Change and Crime Rate Trends: A Routine Activity Approach." *American Sociological Review* 44 (4): 608. <https://doi.org/10.2307/2094589>.
- Colado, S, A Gutiérrez, C Vives, and e Valencia. 2014. *SMART CITY Hacia La Gestion Inteligente*. MARCOMBO.
- Cooper, Gwen. 2007. "Diary of a South Beach Party Girl : A Novel," 323.
- Crawford, Sybil L. 2006. "Correlation and Regression." *Circulation* 114 (19): 2083–88. <https://doi.org/10.1161/CIRCULATIONAHA.105.586495/FORMAT/EPUB>.
- Cueva, Daniela. 2022. "Análisis Del Crimen Urbano En Quito: Un Enfoque Cuantitativo y Espacial." Quito: Facultad Latinoamericana de Ciencias Sociales, FLACSO Ecuador. <https://repositorio.flacsoandes.edu.ec/bitstream/10469/18164/2/TFLACSO-2022DFCC.pdf>.
- Dahiru, Tukur. 2008. "P – Value, A True Test Of Statistical Significance? A Cautionary Note." *Annals of Ibadan Postgraduate Medicine* 6 (1): 21. <https://doi.org/10.4314/AIPM.V6I1.64038>.
- Dakalbab, Fatima, Manar Abu Talib, Omnia Abu Waraga, Ali Bou Nassif, Sohail Abbas, and Qassim Nasir. 2022. "Artificial Intelligence & Crime Prediction: A Systematic Literature Review." *Social Sciences & Humanities Open* 6 (1): 100342. <https://doi.org/10.1016/J.SSAHO.2022.100342>.
- Dammert, Lucía. 2015. *Violencia Criminal y Seguridad Ciudadana En Chile*. CEPAL. Naciones Unidas. Santiago de Chile.
- Deloitte. 2015. "Smart Cities: How Rapid Advances in Technology Are Reshaping Our Economy and Society." 2015. [www.deloitte.nl/govlab](http://www.deloitte.nl/govlab).
- Deshmukh, Atharva, Sourab Banka, Sean Bruno Dcruz, Sana Shaikh, and Amiya Kumar Tripathy. 2020. "Safety App: Crime Prediction Using GIS." In *International Conference on Communication Systems, Computing and IT Applications*, 120–24. <https://doi.org/10.1109/CSCITA47329.2020.9137772>.
- Drawve, Grant. 2014. "A Metric Comparison of Predictive Hot Spot Techniques and RTM." *Justice Quarterly* 33 (3): 369–97. <https://doi.org/10.1080/07418825.2014.904393>.
- Eck, J, E Chainey, J Cameron, M Leitner, and R Wilson. 2005. "Mapping Crime: Understanding Hot Spots." *National Institute of Justice*.
- Eck, J, S Chainey, and R Wilson. 2005. *Mapping Crime: Understanding Hotspots*. Washington, D.C.: National Institute of Justice.
- Elliott, D. 1997. "Environmental Factors Contribute to Juvenile Crime and Violence ." Office of Justice Programs. 1997. <https://www.ojp.gov/ncjrs/virtual-library/abstracts/environmental-factors-contribute-juvenile-crime-and-violence>.
- Eremia, Mircea, Lucian Toma, and Mihai Sanduleac. 2017. "The Smart City Concept in the 21st Century." *Procedia Engineering* 181 (January): 12–19. <https://doi.org/10.1016/J.PROENG.2017.02.357>.
- Escobedo, Francisco J., Nicola Clerici, Christina L. Staudhammer, Alejandro Feged-Rivadeneira, Juan Camilo Bohorquez, and German Tovar. 2018. "Trees and Crime in Bogota, Colombia: Is the Link an Ecosystem Disservice or Service?" *Land Use Policy* 78 (November): 583–92. <https://doi.org/10.1016/J.LANDUSEPOL.2018.07.029>.

- Esri. 2005. "Cómo Funciona Análisis de Puntos Calientes (Gi\* de Getis-Ord)." 2005. <https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-statistics/h-how-hot-spot-analysis-getis-ord-gi-spatial-stati.htm>.
- . 2022a. "Análisis de Puntos Calientes Emergentes (Minería de Patrones En Espacio-Tiempo)—ArcGIS Pro | Documentación." 2022. <https://pro.arcgis.com/es/pro-app/latest/tool-reference/space-time-pattern-mining/emerginghotspots.htm>.
- . 2022b. "Cómo Funciona Predicción Basada En Bosque—ArcGIS Pro | Documentación." 2022. <https://pro.arcgis.com/es/pro-app/latest/tool-reference/space-time-pattern-mining/learnmoreforestbasedforecast.htm>.
- . 2022c. "Cómo Funciona La Densidad Kernel." 2022. <https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-analyst/how-kernel-density-works.htm>.
- . 2022d. "Cómo Funciona La Herramienta Análisis de Puntos Calientes Emergentes—ArcGIS Pro | Documentación." 2022. <https://pro.arcgis.com/es/pro-app/latest/tool-reference/space-time-pattern-mining/learnmoreemerging.htm>.
- . 2022e. "Previsión Basada En Bosque (Minería de Patrones En Espacio-Tiempo)—ArcGIS Pro | Documentación." 2022. <https://pro.arcgis.com/es/pro-app/latest/tool-reference/space-time-pattern-mining/forestbasedforecast.htm>.
- Falconer, Gordon, and Shane Mitchell. 2012. "Smart City Framework. A Systematic Process for Enabling Smart+Connected Communities." *Cisco Internet Business Solutions Group (IBSG)*.
- Felson, Marcus. 2006. *Crime and Nature*. Sage Publications.
- Feng, Mingchen, Jiangbin Zheng, Jinchang Ren, Amir Hussain, Xiuxiu Li, Yue Xi, and Qiaoyuan Liu. 2019. "Big Data Analytics and Mining for Effective Visualization and Trends Forecasting of Crime Data." *IEEE Access* 7: 106111–23. <https://doi.org/10.1109/ACCESS.2019.2930410>.
- Fernández, D. 2017. "Factores de Desarrollo de Las Ciudades Inteligentes." *Revista Universitaria de Geografía* 26 (1).
- Getis, Arthur, Pat Drummy, John Gartin, Wilpen Gorr, Keith Harries, Peter Rogerson, Debra Stoe, and Richard Wright. 2000. "Geographic Information Science and Crime Analysis." *URISA Journal* 12 (2): 7–14.
- Gómez, S., M. Vivo, and E. Soria. 2001. "Pruebas de Significación En Bioestadística." *Revista de Diagnóstico Biológico* 50 (4): 207–18.
- Hägerstrand, Torsten. 1970. "What about People in Regional Science?" *Papers in Regional Science* 24 (1): 7–24. <https://doi.org/10.1111/J.1435-5597.1970.TB01464.X>.
- Han, Jiawei, Micheline Kamber, and Jian Pei. 2012. *Data Mining. Concepts and Techniques*. Tercera. Waltham, MA: Elsevier.
- Hart, Timothy C, and Paul A Zandbergen. 2014. "Kernel Density Estimation and Hotspot Mapping Examining the Influence of Interpolation Method, Grid Cell Size, and Bandwidth on Crime Forecasting." *Journal of Police Strategies and Management* 37 (2): 305–23. <https://doi.org/10.1108/PIJPSM-04-2013-0039>.
- Hashim, H., W. M.N. Wan Mohd, E. S.S.M. Sadek, and K. M. Dimiyati. 2019. "Modeling Urban Crime Patterns Using Spatial Space Time and Regression Analysis." *International Archives of the Photogrammetry, Remote Sensing and Spatial*

- Information Sciences - ISPRS Archives* 42 (October): 247–54.  
<https://doi.org/10.5194/ISPRS-ARCHIVES-XLII-4-W16-247-2019>.
- Hipp, John R., Kevin Kane, and Jae Hong Kim. 2017. “Recipes for Neighborhood Development: A Machine Learning Approach toward Understanding the Impact of Mixing in Neighborhoods.” *Landscape and Urban Planning* 164 (August): 1–12.  
<https://doi.org/10.1016/J.LANDURBPLAN.2017.03.006>.
- Hirschfield, A., K. J. Bowers, and P. J.B. Brown. 1995. “Exploring Relations between Crime and Disadvantage on Merseyside.” *European Journal on Criminal Policy and Research* 1995 3:3 3 (3): 93–112. <https://doi.org/10.1007/BF02242931>.
- Hora, La. 2019. “La ‘Zona’ de Quito La Mariscal Se Organiza En Contra de La Delincuencia – Diario La Hora.” June 16, 2019. <https://www.lahora.com.ec/noticias/la-zona-de-quito-la-mariscal-se-organiza-en-contra-de-la-delincuencia/>.
- . 2022. “Estas Son Las Horas Con Más Asaltos En Quito.” La Hora,. March 20, 2022. <https://www.lahora.com.ec/pais/horarios-zonas-asaltos-delincuencia-quito/>.
- Hu, Yujie, Fahui Wang, Cecile Guin, and Haojie Zhu. 2018. “A Spatio-Temporal Kernel Density Estimation Framework for Predictive Crime Hotspot Mapping and Evaluation.” *Applied Geography* 99 (October): 89–97.  
<https://doi.org/10.1016/J.APGEOG.2018.08.001>.
- Hwang, J, and J Lin. 2016. “What Have We Learned About the Causes of Recent Gentrification? On JSTOR.” *Cityscape* 18 (3): 9–26.
- Imbusch, Peter, Michel Misse, and Fernando Carrión. 2011. “Violence Research in Latin America and the Caribbean: A Literature Review.” *International Journal of Conflict and Violence (IJCV)* 5 (1): 87–154. <https://doi.org/10.4119/IJCV-2851>.
- Inlow, Alana R. 2021. “A Comprehensive Review of Quantitative Research on Crime, the Built Environment, Land Use, and Physical Geography.” *Sociology Compass* 15 (7): e12889. <https://doi.org/10.1111/SOC4.12889>.
- Iqbal, Rizwan, Masrah Azrifah Azmi Murad, Aida Mustapha, Payam Hassany Shariat Panahy, and Nasim Khanahmadliravi. 2013. “An Experimental Study of Classification Algorithms for Crime Prediction.” *Indian Journal of Science and Technology* 6 (3): 1–7. <https://doi.org/10.17485/IJST/2013/V6I3.6>.
- Jácome, Evelyn. 2019. “Quito: La Mariscal Tiene Cuatro Problemas de Seguridad Por Resolver.” *El Comercio*. April 29, 2019.  
<https://www.elcomercio.com/actualidad/quito-mariscal-problemas-seguridad-yunda.html>.
- Jaitman, Laura, and Nicolas Ajzenman. 2016. “Crime Concentration and Hot Spot Dynamics in Latin America Institutions for Development Sector Inter-American Development Bank.” *IDB Working Paper Series*, no. No. IDB-WP-699.
- Jing, Yankang, Ziheng Hu, Peihao Fan, Ying Xue, Lirong Wang, Ralph E. Tarter, Levent Kirisci, Junmei Wang, Michael Vanyukov, and Xiang Qun Xie. 2020. “Analysis of Substance Use and Its Outcomes by Machine Learning I. Childhood Evaluation of Liability to Substance Use Disorder.” *Drug and Alcohol Dependence* 206 (January): 107605. <https://doi.org/10.1016/J.DRUGALCDEP.2019.107605>.
- Kadhim, B., and Al-Janabi Swadi. 2011. “A Proposed Framework for Analyzing Crime Data Set Using Decision Tree and Simple K-Means Mining Algorithms.” *Journal of Kufa*

- for Mathematics and Computer* 1 (3): 8–24.
- Kieu, H, L Borrello, KC Samiran, J Martin, K Watts, and S Jones. 2019. “Are Smart Cities Smart?” *IEEE Future Directions*. March 2019.  
<https://cmte.ieee.org/futuredirections/tech-policy-ethics/2019articles/are-smart-cities-smart/>.
- Kinney, J. Bryan, Patricia L. Brantingham, Kathryn Wuschke, Michael G. Kirk, and Paul J. Brantingham. 2008. “Crime Attractors, Generators and Detractors: Land Use and Urban Crime Opportunities.” *Built Environment* 34 (1): 62–74.  
<https://doi.org/10.2148/BENV.34.1.62>.
- Kumar, Harish, Manoj Kumar Singh, M. P. Gupta, and Jitendra Madaan. 2020. “Moving towards Smart Cities: Solutions That Lead to the Smart City Transformation Framework.” *Technological Forecasting and Social Change* 153 (April): 119281.  
<https://doi.org/10.1016/J.TECHFORE.2018.04.024>.
- Lacoste, Yves. 1990. *La Geografía : Un Arma Para La Guerra*. Edited by Anagrama. Barcelona.
- Lal, Preet, Ankit Shekhar, Mana Gharun, and Narendra N. Das. 2023. “Spatiotemporal Evolution of Global Long-Term Patterns of Soil Moisture.” *Science of The Total Environment* 867 (April): 161470.  
<https://doi.org/10.1016/J.SCITOTENV.2023.161470>.
- LeBeau, James, and Michael Leitner. 2011. “Introduction: Progress in Research on the Geography of Crime.” *The Professional Geographer* 63 (2): 161–73.  
<https://doi.org/10.1080/00330124.2010.547147>.
- Llobell, Juan Pascual, José Fernando, García Pérez, María Dolores, and Frías Navarro. 2000. “Significación Estadística, Importancia Del Efecto y Replicabilidad de Los Datos.” *Psicothema, ISSN 0214-9915, ISSN-e 1886-144X, Vol. 12, Nº. Extra 2, 2000, Págs. 408-412* 12 (2): 408–12.
- Loo, Becky P.Y., and Winnie S.M. Tang. 2019. “‘Mapping’ Smart Cities.” *Journal of Urban Technology* 26 (2): 129–46. <https://doi.org/10.1080/10630732.2019.1576467>.
- Maestre Góngora, Gina Paola. 2015. “Literature Review on Smart Cities: An ICT-Centered Perspective.” *INGENIARE*, no. 19 (July): 137–49. <https://doi.org/10.18041/1909-2458/INGENIARE.19.531>.
- Mayhew, Henry. 1851. *London Labour and the London Poor*. Griffin-Bohn. London.  
<https://www.bl.uk/collection-items/london-labour-and-the-london-poor-by-henry-mayhew>.
- McCarthy, J, and E Feigenbaum. 1990. “In Memoriam: Arthur Samuel - Pioneer in Machine Learning.” *AI Magazine* 11 (3).
- Mcclendon, Lawrence, and Natarajan Meghanathan. 2015. “Using Machine Learning Algorithms to Analyze Crime Data.” *Machine Learning and Applications: An International Journal (MLAIJ)* 2 (1). <https://doi.org/10.5121/mlaij.2015.2101>.
- Michael, Sean E., R. Bruce Hull, and Diane L. Zahm. 2001. “Environmental Factors Influencing Auto Burglary: A Case Study.” <Http://Dx.Doi.Org/10.1177/00139160121973034> 33 (3): 368–88.  
<https://doi.org/10.1177/00139160121973034>.
- Mohler, George, and Michael D. Porter. 2018. “Rotational Grid, PAI-Maximizing Crime

- Forecasts.” *Statistical Analysis and Data Mining: The ASA Data Science Journal* 11 (5): 227–36. <https://doi.org/10.1002/SAM.11389>.
- Moreira, Julio Solís. 2016. “Incidencia de La Seguridad Comunitaria y El Capital Social En Barrios Urbanos de San José, Costa Rica.” *URVIO. Revista Latinoamericana de Estudios de Seguridad*, no. 19 (December): 90–110. <https://doi.org/10.17141/URVIO.19.2016.2409>.
- Muggah, Roberto, and Katherine Aguirre. 2017. “Targeting ‘Hot Spots’ Could Drastically Reduce Latin America’s Murder Rate.” 2017. <https://www.americasquarterly.org/article/targeting-hot-spots-could-dramatically-reduce-latin-americas-murder-rate/>.
- Nam, Taewoo, and Theresa A. Pardo. 2011. “Conceptualizing Smart City with Dimensions of Technology, People, and Institutions.” *ACM International Conference Proceeding Series*, 282–91. <https://doi.org/10.1145/2037556.2037602>.
- Newton, Andrew, and Marcus Felson. 2015. “Crime Patterns in Time and Space: The Dynamics of Crime Opportunities in Urban Areas.” *Crime Science* 4 (1): 1–5. <https://doi.org/10.1186/S40163-015-0025-6/TABLES/1>.
- Owusu, George, and Louis Kusi Frimpong. 2020. “Crime Geography.” *International Encyclopedia of Human Geography*, January, 5–10. <https://doi.org/10.1016/B978-0-08-102295-5.10248-3>.
- Panigrahi, S, R Barik, and P Sahu. 2021. “Design of Mathematical Model for Analysis of Smart City and GIS-Based Crime Mapping.” *Advances in Machine Learning and Computational Intelligence*, 457–65. <http://www.springer.com/series/16171>.
- Peet, Richard. 1975. “The Geography Of Crime: A Political Critique\*.” *The Professional Geographer* 27 (3): 277–80. <https://doi.org/10.1111/J.0033-0124.1975.00277.X>.
- Perry, Walter, Brian McInnis, Carter Price, Susan Smith, and John Hollywood. 2018. *Predictive Policing: The Role of Crime Forecasting in Law Enforcement Operations*. Santa Monica, CA: RAND Corporation. <https://doi.org/10.7249/RR233>.
- Piza, E, B Welsh, D Farrington, and A Thomas. 2019. “CCTV Surveillance Found to Be a Key Tool in Crime Prevention.” *Criminology & Public Policy* 18 (1): 135–59.
- “Plan Especial ‘La Mariscal.’” 2017. Gobierno Abierto de Quito. 2017. <https://gobiernoabierto.quito.gob.ec/wp-content/uploads/documentos/documentos/BORRADOR DIAGNOSTICO PELM.pdf>.
- Premalatha, M, and C Vijayalakshmi. 2015. “SVM Approach for Classification and Regression with Absolute Value Combination Method for Controlling Complexity.” *International Journal of Pure and Applied Mathematics* 101 (5): 811–20.
- Priks, Mikael. 2015. “The Effects Of Surveillance Cameras On Crime: Evidence From The Stockholm Subway.” *The Economic Journal* 125: 289–305. <https://doi.org/10.1111/eoj.12327>.
- Quetelet, L. A. 1994. “A Treatise on Man and the Development of His Faculties.” *Obesity Research* 2 (1): 72–85. <https://doi.org/10.1002/J.1550-8528.1994.TB00047.X>.
- Ramaprasad, Arkalgud, Aurora Sánchez-Ortiz, and Thant Syn. 2017. “A Unified Definition of a Smart City.” *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 10428 LNCS: 13–24.

- [https://doi.org/10.1007/978-3-319-64677-0\\_2/FIGURES/1](https://doi.org/10.1007/978-3-319-64677-0_2/FIGURES/1).
- Reyna, Carlos, and Eduardo Toche. 1999. "La Inseguridad En El Perú." *Serie de Políticas Sociales* 29.
- Ritchie, H, and M Roser. 2018. "Urbanization - Our World in Data." Our World in Data. 2018. <https://ourworldindata.org/urbanization>.
- Romero, Daniel. 2017. "En La Mariscal, En Quito, Se Busca Un Plan Integral Para Seguridad." *El Comercio*. August 15, 2017. <https://www.elcomercio.com/actualidad/lamariscal-quito-plan-seguridad-alcaldia.html>.
- Rummens, Anneleen, Wim Hardyns, and Lieven Pauwels. 2017. "The Use of Predictive Analysis in Spatiotemporal Crime Forecasting: Building and Testing a Model in an Urban Context." *Applied Geography* 86 (September): 255–61. <https://doi.org/10.1016/J.APGEOG.2017.06.011>.
- Sánchez, Víctor Manuel. 2016. "¿Son Efectivas Las Cámaras de Video Vigilancia Para Reducirlos Delitos?" *URVIO - Revista Latinoamericana de Estudios de Seguridad*, no. 19 (December): 162. <https://doi.org/10.17141/URVIO.19.2016.2406>.
- Saraiva, Miguel, Irina Matijošaitienė, Saloni Mishra, and Ana Amante. 2022. "Crime Prediction and Monitoring in Porto, Portugal, Using Machine Learning, Spatial and Text Analytics." *ISPRS International Journal of Geo-Information* 2022, Vol. 11, Page 400 11 (7): 400. <https://doi.org/10.3390/IJGI11070400>.
- Savard, Dennis M., Thomas M. Kelley, Joseph J. Jaksa, and Daniel B. Kennedy. 2019. "Violent Crime in Bars: A Quantitative Analysis." *Journal of Applied Security Research* 14 (4): 369–89. <https://doi.org/10.1080/19361610.2019.1654331>.
- Scarlascini, Carlos. 2019. "¿Pueden Los Gobiernos Recuperar La Confianza de Los Ciudadanos En América Latina? - Ideas Que Cuentan." March 20, 2019. <https://blogs.iadb.org/ideas-que-cuentan/es/pueden-los-gobiernos-recuperar-la-confianza-de-los-ciudadanos-en-america-latina/>.
- Schnake-Mahl, Alina S., Jaquelyn L. Jahn, S. V. Subramanian, Mary C. Waters, and Mariana Arcaya. 2020. "Gentrification, Neighborhood Change, and Population Health: A Systematic Review." *Journal of Urban Health : Bulletin of the New York Academy of Medicine* 97 (1). <https://doi.org/10.1007/S11524-019-00400-1>.
- Schultze-Kraft, Markus, Fernando A Chinchilla, and Marcelo Moriconi. 2018. "New Perspectives on Crime, Violence and Insecurity in Latin America." *Crime, Law and Social Change* 69 (4): 465–73. <https://doi.org/10.1007/s10611-017-9758-3>.
- Shaw, Clifford, and Henry McKay. 1942. *Delinquency and Urban Areas*. Chicago: University of Chicago Press. [https://books.google.com.ec/books/about/Juvenile\\_Delinquency\\_and\\_Urban\\_Areas.html?id=GKRkMQEACAAJ&redir\\_esc=y](https://books.google.com.ec/books/about/Juvenile_Delinquency_and_Urban_Areas.html?id=GKRkMQEACAAJ&redir_esc=y).
- Sherman, L., P. Gartin, and M. Buerger. 1989. "Hot Spots of Predatory Crime: Routine Activities and the Criminology of Place." *Criminology* 27 (1): 27–56. <https://doi.org/10.1111/J.1745-9125.1989.TB00862.X>.
- Singh, Amar. 2005. "The Rise of Crime in Malaysia. An Academic and Statistical Analysis." *Journal of the Kuala Lumpur Royal Malaysia Police College*, no. 4: 1–28.
- Sivaranjani, S., S. Sivakumari, and M. Aasha. 2017. "Crime Prediction and Forecasting in Tamilnadu Using Clustering Approaches." *Proceedings of IEEE International*

- Conference on Emerging Technological Trends in Computing, Communications and Electrical Engineering*. <https://doi.org/10.1109/ICETT.2016.7873764>.
- Sterne, Jonathan A.C., and George Davey Smith. 2001. "Sifting the Evidence—What's Wrong with Significance Tests? Another Comment on the Role of Statistical Methods." *BMJ* 322 (7280): 226–31. <https://doi.org/10.1136/BMJ.322.7280.226>.
- Suhong, Kim, Param Joshi, Pooya Taheri, Suhong Kim, and Singh Kalsi. 2018. "Crime Analysis Through Machine Learning." In *2018 IEEE 9th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*. Vancouver, BC: IEEE. <https://doi.org/10.1109/IEMCON.2018.8614828>.
- Suquillo, Luis. 2015. "Plan de Seguridad Integral Para El Sector de La Mariscal Del Distrito Metropolitano de Quito a Fin de Minimizar Los Riesgos Existentes. Propuesta." Sangolquí: Universidad de las Fuerzas Armadas ESPE.
- Toppireddy, Hitesh Kumar Reddy, Bhavna Saini, and Ginika Mahajan. 2018. "Crime Prediction & Monitoring Framework Based on Spatial Analysis." *Procedia Computer Science* 132 (January): 696–705. <https://doi.org/10.1016/J.PROCS.2018.05.075>.
- Trangenstein, Pamela J., Frank C. Curriero, Daniel Webster, Jacky M. Jennings, Carl Latkin, Raimee Eck, and David H. Jernigan. 2018. "Outlet Type, Access to Alcohol, and Violent Crime." *Alcoholism, Clinical and Experimental Research* 42 (11): 2245. <https://doi.org/10.1111/ACER.13880>.
- Truntsevsky, Y V, I I Lukiny, A V Sumachev, and A V Kopytova. 2018. "A Smart City Is a Safe City: The Current Status of Street Crime and Its Victim Prevention Using a Digital Application." In *MATEC Web of Conferences 170*. <https://doi.org/10.1051/mateconf/201817001067>.
- Umar, Faisal. 2017. "Understanding Spatial Patterns of Urban Crime in a Developing Country." *University College London*. London: University College London.
- Vallejo Gutierrez, J. Refugio, and Norma Isela Villegas Barrientos. 2018. "Índice Delictivo y Su Relación Con Densidad Poblacional y El Índice de Desarrollo Humano En El Estado de Guanajuato." *Acta Universitaria* 28 (December): 50–58. <https://doi.org/10.15174/AU.2018.1909>.
- Vidal Tejedor, Narcís. 2015. *La Smart City : Las Ciudades Inteligentes Del Futuro*. Editorial UOC, S.L.
- Vinuesa, Ricardo, and Beril Sirmacek. 2021. "Interpretable Deep-Learning Models to Help Achieve the Sustainable Development Goals." *Nature Machine Intelligence* 3 (11). <https://doi.org/10.1038/s42256-021-00414-y>.
- Weisburd, David, Gerben J.N. Bruinsma, and Wim Bernasco. 2009. "Units of Analysis in Geographic Criminology: Historical Development, Critical Issues, and Open Questions." *Putting Crime in Its Place: Units of Analysis in Geographic Criminology*, 3–31. [https://doi.org/10.1007/978-0-387-09688-9\\_1/COVER/](https://doi.org/10.1007/978-0-387-09688-9_1/COVER/).
- Weisburd, David, Clair White, Sean Wire, and David B. Wilson. 2021. "Enhancing Informal Social Controls to Reduce Crime: Evidence from a Study of Crime Hot Spots." *Prev. Sci* 22 (4): 509–22. <https://doi.org/10.1007/S11121-020-01194-4>.
- Welsem, Johan Van, Karin Wittebrood, and Nan Dirk De Graaf. 2006. "Socioeconomic Dynamics of Neighborhoods and the Risk of Crime Victimization: A Multilevel Study of Improving, Declining, and Stable Areas in the Netherlands." *Social Problems* 53

- (2): 226–47. <https://doi.org/10.1525/SP.2006.53.2.226>.
- Wheeler, Andrew P., and Wouter Steenbeek. 2020. “Mapping the Risk Terrain for Crime Using Machine Learning.” *Journal of Quantitative Criminology* 2020 37:2 37 (2): 445–80. <https://doi.org/10.1007/S10940-020-09457-7>.
- White, Veronica, Joel Hunt, and Brannon Green. 2022. “A Discussion of Current Crime Forecasting Indices and an Improvement to the Prediction Efficiency Index for Applications,” 1–18. <https://doi.org/10.31235/OSF.IO/PF8HY>.
- Wuschke, Kathryn, Kris Henning, and Gregory Stewart. 2022. “Dots versus Density: The Impact of Crime Mapping Techniques on Perception of Safety, Police Performance and Neighbourhood Quality.” *Policing and Society* 32 (1): 1–17. <https://doi.org/10.1080/10439463.2021.1874950>.
- Xia, Zhiyue, Kathleen Stewart, and Junchuan Fan. 2021. “Incorporating Space and Time into Random Forest Models for Analyzing Geospatial Patterns of Drug-Related Crime Incidents in a Major U.S. Metropolitan Area.” *Computers, Environment and Urban Systems* 87 (May): 101599. <https://doi.org/10.1016/J.COMPENVURBSYS.2021.101599>.
- Yuki, Jesia Quader, Md Mahfil Quader Sakib, Zaisha Zamal, Khan Mohammad Habibullah, and Amit Kumar Das. 2019. “Predicting Crime Using Time and Location Data.” *ACM International Conference Proceeding Series*, July, 124–28. <https://doi.org/10.1145/3348445.3348483>.
- Zahnow, Renee, and Jonathan Corcoran. 2019. “Crime and Bus Stops: An Examination Using Transit Smart Card and Crime Data.” *Https://Doi.Org/10.1177/2399808319890614* 48 (4): 706–23.