



Geomática

y procesos urbanos.

Planeación urbana

con inteligencia artificial

COORDINADORES

Ma. de los Ángeles Martínez Ortega - Ricardo Gómez Maturano - Luz de Lourdes Cordero Gómez del Campo - J. Guadalupe Martínez Granados

EDITORIAL RESTAURO COMÁS Y CANTO



Geomática y procesos urbanos.

Planeación urbana con inteligencia artificial

Coordinadores:

**Ma. de los Ángeles Martínez Ortega
Ricardo Gómez Maturano
Luz de Lourdes Cordero Gómez del Campo
J. Guadalupe Martínez Granados**

Autores:

**Ricardo Gómez Maturano
María Fernanda Islas Monroy
Rogelio Contreras González
Álvaro Flores Miranda
Perla María Sánchez Uriarte
Margarita Ruiz Camacho
Raquel Andrea Delgadillo Díaz
Víctor Raúl Quintero Barba
Ma. de los Ángeles Martínez Ortega
Luis Armando Soto Martínez
Cristy Monserratt Sánchez Ramos
Marielena Medina Ruiz
J. Guadalupe Martínez Granados
Luz de Lourdes Cordero Gómez del Campo
Víctor Manuel Sánchez Vega
Ana Laura Castillo Hernández**



EDITORIAL RESTAURO COMPÁS Y CANTO

Geomática y procesos urbanos. Planeación urbana con inteligencia artificial

Primera edición: Enero 2026

Fecha de publicación: 7 de enero del 2026

© 2026. Coordinadores: Ma. de los Ángeles Martínez Ortega, Ricardo Gómez Maturano, Luz de Lourdes Cordero Gómez del Campo y J. Guadalupe Martínez Granados

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA), Unidad Tecamachalco. Naucalpan, Estado de México.

© 2026. Editorial Restauro Compás y Canto

ISBN digital: 978-607-99572-8-5

Hecho en México

Disponible en: www.editorialrestauro.org.mx

Correo electrónico: contacto@editorialrestauro.org.mx

Dirección editorial: Héctor César Escudero Castro

Supervisión de producción: Diana Guadalupe González Oriani

Corrección de Estilo Ulises Paniagua Olivares y Diana Guadalupe González Oriani

Maquetación y diseño: David Odín Vargas López

Libro arbitrado por pares académicos en la modalidad doble ciego

Reservados todos los derechos. No se permite la reproducción total o parcial de esta obra con fines lucrativos, ni su incorporación a un sistema informático, ni su transmisión en cualquier forma o por cualquier medio sin autorización previa y por escrito de los autores y editores. La infracción de dichos derechos puede constituir un delito contra la propiedad intelectual.



ÍNDICE

Resumen del libro	7
 Introducción. GeoInteligencia Artificial y Geoplaneación: ejes teóricos, desafíos y tensiones epistemológicas	
<i>Ricardo Gómez Maturano, Ma. De los Ángeles Martínez Ortega, Luz de Lourdes Cordero Gómez del Campo, J. Guadalupe Martínez Granados</i>	8
 Línea Temática 1: “Planeación urbana. Geomática e IA aplicada a los análisis urbanos”	
 Capítulo I. Geoplaneación urbana. Métodos y modelos computacionales desde lo urbano	
<i>Ricardo Gómez Maturano, Marielena Medina Ruiz, Ma. de los Ángeles Martínez Ortega</i>	36
 Capítulo II. Monocentrismo o policentrismo en la Ciudad de México. Análisis espacial con IA y SIG’s	
<i>Ricardo Gómez Maturano</i>	59
 Capítulo III. Planeación urbana: proyección de la densificación urbana al 2030. Caso de estudio Polanco, México	
<i>María Fernanda Islas Monroy</i>	84
 Capítulo IV. Percepción remota en el análisis de la dispersión urbana en zonas costeras. Clasificación supervisada de imágenes satelitales	
<i>Rogelio Contreras González</i>	103
 Capítulo V. Evaluación de políticas públicas urbanas: una herramienta estratégica para la planificación integral del territorio.	
<i>Álvaro Flores Miranda</i>	120
 Capítulo VI. Micro-segregación residencial en Managua: entre la conciliación espacial y la fractura social.	
<i>Perla María Sánchez Uriarte</i>	138

Línea Temática 2: “Procesos urbanos, habitabilidad y transformación socioespacial”

Capítulo VII. Desigualdad socioespacial del tiempo empleado en la movilidad cotidiana de la Zona Metropolitana de Valle de México	
<i>Margarita Ruiz Camacho, Ricardo Gómez Maturano</i>	156

Capítulo VIII. La seguridad vial de los motociclistas en la Ciudad de México en el año 2022	
<i>Raquel Andrea Delgadillo Díaz</i>	175

Capítulo IX. Análisis espacial de los delitos de alto impacto en Panamá (2017-2023). Un enfoque geoespacial para la comprensión de la violencia urbana	
<i>Víctor Raúl Quintero Barba</i>	190

Capítulo X. Importancia de la planeación urbana en la habitabilidad urbana: la vivienda saludable.	
<i>Ma. de los Ángeles Martínez Ortega</i>	208

Capítulo XI. Regeneración urbana y análisis territorial: propuesta para la zona Roma, Condesa y Doctores.	
<i>Luis Armando Soto Martínez</i>	228

Línea Temática 3: “Transformaciones ambientales urbanas y tecnologías espaciales para el análisis territorial”

Capítulo XII. Geografías del impacto urbano en el Bosque de Agua. Diagnóstico territorial basado en SIG y Teledetección	
<i>Cristy Monserratt Sánchez Ramos</i>	251

Capítulo XIII. Gentrificación de los climas urbanos y su impacto socioambiental en Bogotá y Barranquilla. Análisis desde la geomática y la percepción remota	
<i>Marielena Medina Ruiz, J. Guadalupe Martínez Granados</i>	269

**Capítulo XIV. Identificación del avance de la cobertura de
suelo urbano utilizando supervisión clasificada en Google
Earth Engine**

Luz de Lourdes Cordero Gómez del Campo, Víctor Manuel Sánchez Vega.....**289**

**Capítulo XV. Detección de fugas en la red primaria de
la Ciudad de México a través de puntos de presión.**

Procesamiento de datos hidráulicos mediante análisis con
Python

Ana Laura Castillo Hernández.....**312**

Conclusiones.....**331**

Semblanza de los autores.....**333**

Resumen del libro

Este libro reúne una serie de investigaciones académicas orientadas al análisis y a la comprensión de los procesos urbanos contemporáneos mediante el uso de herramientas geomáticas, inteligencia artificial y análisis espacial. Está dirigido a estudiantes de posgrado, investigadores, urbanistas, ingenieros territoriales y tomadores de decisiones que busquen enfoques metodológicos, basados en datos, para enfrentar los desafíos urbanos actuales. Su propuesta integra conocimientos técnicos, científicos y teórico-conceptuales que permiten modelar, interpretar y transformar el territorio desde una perspectiva crítica y propositiva.

El libro se estructura en tres líneas temáticas. La primera, “Planeación urbana, geomática e IA aplicada a los análisis urbanos”, aborda estudios sobre monocentrismo, dispersión, densificación, regeneración urbana y análisis funcional de ciudades mediante modelos geoespaciales e inteligencia artificial. La segunda línea, “Procesos urbanos, habitabilidad y transformación socioespacial”, se enfoca en la movilidad cotidiana, la seguridad vial, la accesibilidad a servicios urbanos, la vivienda saludable y el análisis de criminalidad, manteniendo un enfoque en la justicia espacial. La tercera línea, “Transformaciones ambientales urbanas y tecnologías geoespaciales para el análisis territorial”, aborda la gentrificación climática, el impacto urbano sobre el ambiente, el monitoreo de islas de calor y el uso de SIG para el análisis de fugas hidráulicas y estrés hídrico.

Como trabajo colectivo, esta compilación de investigaciones ofrece herramientas conceptuales y operativas para la planificación urbana sostenible, promoviendo una toma de decisiones informada, sustentada en evidencia empírica y nuevas tecnologías.

Se agradece el apoyo del Instituto Politécnico Nacional (IPN), a través del Proyecto 20240362 “Infraestructura y servicios, elementos importantes en la Planeación Urbana”, que hizo posible el desarrollo de esta edición del libro.

Introducción.

GeoInteligencia Artificial y Geoplaneación: ejes teóricos, desafíos y tensiones epistemológicas

Ricardo Gómez Maturano¹

Ma. De los Ángeles Martínez Ortega²

Luz de Lourdes Cordero Gómez del Campo³

José Guadalupe Martínez Granados⁴

*Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),
Unidad Tecamachalco. Naucalpan, Estado de México.*

El mundo, en general, se ha enfrentado constantemente a desafíos en materia de calidad ambiental, frecuencia de desastres naturales, nuevas enfermedades, cuestiones sociales, fenómenos y procesos urbanos, entre otros. Esto como consecuencia del crecimiento acelerado poblacional y económico de nuestras ciudades, el consumo desmedido de nuestros recursos naturales y los crecientes niveles de desigualdad social (Li, 2020); lo que refleja una importante problemática global que evidentemente responde a una naturaleza geoespacial, ya que estos desafíos ocurren en “un lugar específico de la superficie terrestre o cerca de ella y presentan patrones espacio temporales distintivos debido a diferentes procesos geográficos o mecanismos de interacción entre seres humanos y la naturaleza” (Li, 2020, p. 72). Por ello, la ciencia de los Sistemas de Información Geográfica (SIG) se encarga de recolectar, almacenar, analizar y visualizar datos geoespaciales para llevar un seguimiento cartográfico de diferentes problemas a distintas escalas, proyectando así su evolución, formulando y contrastando teorías tales como de factores y procesos determinantes, así como el establecimiento de políticas de prevención ante problemáticas emergentes. Por lo que los recientes avances tecnológicos preparan a los SIG para mejorar los estudios de dichas problemáticas.

1 Profesor e investigador en el Instituto Politécnico Nacional, ESIA, Unidad Tecamachalco, SEPI. Doctor en Urbanismo, UNAM. Maestro en Ciencias en la Especialidad de Arquitectura e Ingeniero Arquitecto, IPN. Correo: rgomezma@ipn.mx, ORCID: <https://orcid.org/0000-0002-8027-8648>

2 Doctora en Educación, Universidad CUGS. Maestra en Ciencias en Administración y Desarrollo de la Educación, Instituto Politécnico Nacional, ESCA Sto. Tomás. Correo: mmartinezo@ipn.mx, ORCID: <https://orcid.org/0000-0002-8483-9844>

3 Doctora en Geografía por la Universidad Nacional Autónoma de México. Actualmente en Estancia Posdoctoral en la Sección de Estudios de Posgrado de la Escuela Superior de Ingeniería y Arquitectura, Unidad Tecamachalco, del Instituto Politécnico Nacional. Correo: lcorderog@ipn.mx, ORCID: <https://orcid.org/0000-0003-3045-7629>

4 PhD en el Instituto Politécnico Nacional, sección de posgrado. Doctor en Urbanismo Facultad de Arquitectura, UNAM. Maestro en Urbanismo, UNAM. Licenciado en Sociología, Facultad de Estudios Superiores Acatlán-UNAM. Correo: jogugra@hotmail.com, ORCID: <https://orcid.org/0000-0001-6345-5166>

El reciente avance de la Inteligencia Artificial (IA) desde el aprendizaje profundo, tiene una importante capacidad de integrar grandes volúmenes de datos, incluso de operar en tiempo real, generando además modelos territoriales complejos, lo que ha derivado en cuestionamientos y debates en torno a la manera de comprender, planear y gobernar de manera eficiente nuestras ciudades.

Esto posibilita un nuevo paradigma de la investigación sobre la ciencia que se basa en datos, donde es posible analizar, extraer, y observar grandes bancos de información de manera masiva; datos que son bastante complejos de manejar desde los métodos tradicionales de un análisis espacial. El resultado de esto es revelar patrones ocultos en nuestras ciudades, generar preguntas, responder otras, y descubrir nuevos conocimientos.

Desde los últimos diez años, la Geoplaneación ha surgido como un paradigma territorial y tecnológico, donde se articulan procesos a nivel multiescalar con herramientas que tienen un avance significativo de inteligencia artificial (IA) y sistemas de información geográfica (SIG).

Sin embargo, en la actualidad la Geoplaneación se encuentra en un punto de inflexión, debido a la integración creciente de no solo la IA sino también del big data geoespacial y el aprendizaje automático.

Esta sinergia se conoce como GeoInteligencia Artificial (GeoAI), que no solo está redefiniendo aquellos instrumentos técnicos de la planeación urbana, sino que al mismo tiempo está reconfigurando marcos epistemológicos a partir de los cuales se piensan nuestros territorios (Mai, et al., 2025; McKenzie, et al., 2023). Adicionalmente, uno de los impulsores y aceleradores clave de dicha integración, por supuesto, ha sido ChatGPT (desarrollado por OpenAI en el año 2022). A pesar de que fue creado inicialmente como herramienta de conversación, el ChatGPT representa un cambio importante entre la producción de conocimiento y el aprendizaje (OpenAI, 2022). En efecto, la capacidad que tiene de procesar lenguajes, razonar bases de datos no estructurados y crear textos con un marco contextual real y actual, lo convierten en una base de carácter cognitivo, inspirando a nuevas generaciones de herramientas de la GeoAI a que sean capaces de identificar, analizar, diagnosticar, clasificar y proyectar información espacial compleja (Hu, et al., 2024).

Breve historia de la IA

En noviembre de 2022, la empresa estadounidense ubicada en California, *OpenAI*, anunciaba la introducción de un modelo llamado ChatGPT, entrenado para interactuar con el usuario en forma de una conversación, explicando que, a través de este formato, ChatGPT era capaz de dar respuesta a preguntas de seguimiento, admitir sus errores, desafiar preguntas incorrectas y rechazar solicitudes inapropiadas. Este modelo, entrenado usando *Reinforced Learning from Humans Feedback* (RLHF), se puso a disposición de los usuarios de manera

gratuita, para que *OpenAi* pudiera obtener retroalimentación y aprender sobre sus fortalezas y debilidades (OpenAI, 2022).

Desde entonces ChatGPT y otros modelos conversacionales más recientes han recibido, por parte de miles de usuarios, las más diversas y variadas solicitudes. Los modelos y programas que utilizan Inteligencia Artificial (IA) como es el caso de ChatGPT, se han convertido en herramientas esenciales en los avances tecnológicos de los últimos años.

El desarrollo del campo de la IA ha recorrido un largo camino. Alan Turing Institute (s.f.), en su trabajo titulado *Computing Machinery and Intelligence* publicado en 1950, presenta uno de los cuestionamientos fundacionales de la IA, al preguntarse por primera vez si las máquinas pueden pensar. En trabajos posteriores, y en lo que ahora se conoce como el Turing Test, Alan Turing se replantea operacionalmente esta pregunta original, cuestionando si una máquina es capaz de exhibir comportamiento inteligente indistinguible del humano. El *Turing Test* es un concepto central en IA, y se utiliza como una forma de medir la inteligencia de una máquina, evaluando su habilidad de imitar convincentemente la conversación y el comportamiento humano (IBM, s.f.).

Posteriormente, con trabajos de otros autores como Minsk y Edmons, con el desarrollo de la primera Red Neural Artificial en 1951 o las investigaciones de Newell y Simon en 1952, se dieron grandes avances en estos estudios. Fue con el taller: *A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence*, organizado por McCarthy, Minsk, Rochester y Shannon, que se utiliza por primera vez ese término al presentar la propuesta en 1955. Sin embargo, se sitúa en julio y agosto de 1956 el nacimiento oficial del campo de la IA, que es la fecha en la que se realizó dicho taller.

En 1958, con la invención de LISP (McCarthy, 1979) por John McCarthy, considerado por sus múltiples aportaciones el fundador de la IA, se tuvo el primer lenguaje funcional de programación que sirvió de base para múltiples transformaciones en el desarrollo de la tecnología actual. Sus artículos, blogs y contribuciones al campo de la IA, pueden consultarse en el sitio de John McCarthy de la Universidad de Stanford (McCarthy, et al., 1955).

- Machine Learning, Neural Network y Deep Learning

Rathore, et al. (2021) definen a la IA como la réplica digital de tres funciones cognitivas humanas: aprendizaje, razonamiento y auto-corrección. Para ellos, el aprendizaje digital es el conjunto de reglas expresadas en un algoritmo computacional, que convierten los datos reales históricos en información procesable. El razonamiento digital se refiere a escoger las reglas adecuadas para alcanzar la meta deseada; mientras la auto-corrección digital, por su parte, es el proceso iterativo de adoptar los resultados del aprendizaje y el razonamiento digitales. Rathore, et al., explican que todos los modelos de IA

siguen este proceso para construir un sistema inteligente que puede desarrollar una tarea que normalmente requiere de la inteligencia humana.

Los modelos de IA están impulsados por modelos o programas de *Machine Learning* (ML), *Deep Learning* (DL), *Data Mining* (DM), *Rules Base Algorithms*, entre otros. ML es el programa o modelo que toma decisiones de una manera similar al cerebro humano, utilizando procesos que imitan la forma en la que trabajan las neuronas biológicas en conjunto para identificar fenómenos, valorar opciones y llegar a conclusiones. Cada *Neural Network* (NN) contiene capas de nodos o neuronas artificiales, donde cada nodo está integrado por una capa de entrada, una o más capas escondidas, y una capa de salida. Si el valor de salida no rebasa el valor especificado en el umbral, no se pasan datos a la siguiente capa de la red.

Estas redes se entrenan con datos para aprender y mejorar su precisión con el tiempo. Pueden clasificar y agrupar datos a alta velocidad. Cuando una NN consiste en más de tres capas, se considera DL. ML realiza la búsqueda de patrones específicos en datos históricos para ayudar a la toma de decisiones, considerando que, a mayor recopilación de datos, más preciso es el proceso de aprendizaje. El proceso de entrenamiento utilizando ML puede ser: de aprendizaje supervisado, empleando datos etiquetados para clasificación o futuras predicciones; de aprendizaje sin supervisión, utilizando datos no etiquetados para agrupar; o de aprendizaje por refuerzo, donde los registros de datos no están etiquetados, pero que (después de efectuar ciertas acciones) proporciona retroalimentación al sistema de IA.

El desarrollo de la inteligencia artificial (IA) ha logrado transformar de manera radical procesos de análisis y modelado en disciplinas geoespaciales. De forma particular, la geomática, logra integrar herramientas basadas en el aprendizaje automático, en las redes neuronales, los algoritmos evolutivos, además de modelos predictivos para amplificar las capacidades analíticas de los mismos y mejorar la precisión de sus resultados cartográficos. Todo ello con el fin de reducir el tiempo de procesamiento de grandes volúmenes de datos.

Esta sinergia favorece una renovación metodológica profunda con implicaciones operativas, técnicas y éticas. Por las consideraciones anteriores, hoy en día la relación entre la Geoplaeación y la Inteligencia Artificial, no se puede entender desde su sola instrumentalización, sino que también necesita entenderse como un ecosistema inteligente donde se deben diluir las fronteras de la decisión técnica, el conocimiento urbano y las agencias territoriales (Goodchild, 2018).

Geo AI, paradigma emergente a nivel multiescalar

Los antecedentes de la sinergia entre la IA y el campo geoespacial se documentan a inicios de los años 80s, y en los 90s, desde los trabajos de Smith (1984), Estes, et al. (1986), Couclelis (1986), Openshaw y Openshaw

(1997); donde el hito más significativo en la historia de la GeoAI fue, en 2017, la conferencia SIGSPATIAL, de la *Association for Computing Machinery* (ACM), evento que determinó la importancia de esta nueva forma de estudio geoespacial eficiente.

La Inteligencia Artificial Geoespacial (GeoAI), se originó como un “dominio de investigación de vanguardia y en rápida evolución dentro de la Ciencia de Datos Espaciales, así como en los campos [...] de la geografía y geociencia de los últimos años” (Janowicz, et al., 2020, como se cita en Mai et al., 2025. p. 2). Se encuentra en un empalme entre “la IA, el big data geoespacial y la computación de alto rendimiento (HPC); todo ello para proporcionar una tecnología de solución de problemas geoespaciales intensivos en datos o computación” (Li, 2020, p. 72). A nivel geoespacial, este tipo de inteligencia tiende a impactar en la cotidianidad de los seres humanos, ya que facilita la navegación en zonas urbanas y rurales, así como la localización de equipamientos y, en general, la rápida localización de los lugares.

En efecto, de esta interacción, al integrarse con los Sistemas de Información Geográfica (SIG), dado que dichos sistemas ofrecen una base estructurada para la organización, análisis y visualización de datos espaciales de manera eficiente y estandarizada (Li y Castro, 2021), la IA no solo permite el procesamiento masivo de datos, sino que también apertura nuevas maneras de representación espacial.

De hecho, el manejo de grandes volúmenes de datos espaciales, lo que hoy se denomina *big geodata*, ha abierto un campo fértil para el diseño de modelos algorítmicos capaces de abordar múltiples fuentes, formatos y escalas, permitiendo así la automatización de tareas analíticas que anteriormente dependían de la intervención humana especializada (Gao, et al., 2020). Como se observa en la Figura 1, los SIG son un aliado estratégico para la IA, en gran medida gracias a su eficiencia y estandarización.




Figura 1. Esquema SIG y GeoAI. Fuente: elaboración propia a partir de Boutayeb, A., Lahsen-cherif, I., y Khadimi, A. E. (2024).

La GeoAI no solo representa una convergencia tecnológica entre inteligencia artificial, big data geoespacial y sistemas de cómputo avanzados, sino que inaugura un nuevo paradigma epistemológico para entender, modelar y actuar sobre el territorio en múltiples escalas. Su capacidad para procesar información compleja y heterogénea en tiempo casi real, así como para traducirla en decisiones espaciales estratégicas, convierte a la GeoAI en una herramienta clave frente a los desafíos urbanos, ambientales y sociales del siglo XXI.

Más allá de su dimensión técnica, la GeoAI redefine la forma en que se produce conocimiento geográfico, y al integrarse con infraestructuras como los SIG no solo automatiza procesos, sino que transforma profundamente los marcos desde los cuales se interpreta el espacio y se planifica su transformación. Este campo emergente, por tanto, no puede entenderse únicamente como una tecnología, sino como una arquitectura cognitiva orientada a reconfigurar nuestras capacidades de observación y gestión territorial en la era de la inteligencia computacional.

Según (Boutayeb, et al., 2024) los campos de vanguardia donde la GeoAI suele ser fundamental, son: agricultura (Mitran et al., 2020; Raju, et al., 2019), ambiente (Rai, et al., 2022), defensa, planificación urbana (Jian y Yao, 2010) entre otras. Con esto, se abre una dimensión de análisis y reflexión. Adicionalmente, con la IA se ejecutan tareas de precisión alta, como por ejemplo el procesamiento de imágenes de la teledetección para crear mapas de uso de suelo (Alqadhi, et al., 2024), el análisis de cambios de seres tiempo espacio temporales (Moranduzzo y Melgani, 2012) y los pronósticos meteorológicos.

En esta lógica, Wenwen Li (2020) plantea el siguiente esquema conceptual sobre los principales pilares de la GeoAI, destacando una expansión interdisciplinaria de la IA, donde el objetivo es que la máquina tenga la inteligencia de hacer razonamientos como los seres humanos (Figura 2).

El desarrollo de la GeoAI ha avanzado paralelamente con la evolución general de la IA, y puede comprenderse a través de dos aproximaciones metodológicas fundamentales. Por un lado, el enfoque basado en conocimiento entendido como enfoque descendente o *top-down*, y parte de reglas formales y estructuras ontológicas predefinidas para representar el conocimiento geográfico (Coullelis, 1986; Smith, 1984). Por otro lado, el enfoque centrado en los datos llamado ascendente o *bottom-up*, que ha ganado una presencia significativa, en especial a través del uso de algoritmos de aprendizaje automático que permiten extraer patrones y formular predicciones a partir de conjuntos masivos de datos sin requerir una codificación explícita de reglas (Estes, et al., 1986; Kalinicheva, et al., 2020). El segundo enfoque ha consolidado su protagonismo en el ámbito de la GeoAI contemporánea, no solo por su eficiencia técnica, sino por su capacidad de adaptarse a contextos espaciales dinámicos y heterogéneos (Boutayeb, et al., 2024).




Figura 2. Esquema conceptual sobre los tres pilares de GeoAI. Fuente: elaboración propia a partir de Wenwen Li (2020).

El aprendizaje profundo, como evolución reciente dentro del campo del aprendizaje automático, ha reconfigurado profundamente los métodos de análisis de datos espaciales, en especial aquellos vinculados al procesamiento masivo de información.

Una de sus principales contribuciones tiene que ver con la capacidad de sus arquitecturas, como las redes neuronales convolucionales (CNN), para identificar automáticamente atributos relevantes en los datos sin necesidad de una programación manual previa, lo que permite distinguir con alta precisión entre diferentes clases de objetos (LeCun, et al., 2015; Gallo, et al., 2023). Esta automatización en la extracción de características representa una mejora sustancial respecto a los enfoques espaciales tradicionales, especialmente

en contextos donde el conocimiento previo sobre los patrones subyacentes es escaso o incierto, como suele suceder en entornos de big data.

Además, los modelos de aprendizaje profundo introducen operaciones locales como la convolución, que descomponen las dependencias complejas propias de modelos neuronales clásicos. Este diseño no solo mejora la eficiencia computacional del entrenamiento, sino que también permite escalar estos modelos en sistemas paralelos o distribuidos, manteniendo un alto nivel de precisión incluso en estructuras con millones de parámetros (Geng, et al., 2023; Moranduzzo y Melgani, 2012). Gracias a estas propiedades, el aprendizaje profundo se consolida como una herramienta clave para el análisis geoespacial avanzado y la toma de decisiones fundamentada en grandes volúmenes de datos heterogéneos.

Perspectivas críticas sobre el rol de la IA en la planificación urbana

La incorporación progresiva de la Inteligencia Artificial (IA) en el ámbito de la planificación urbana, no ha transformado únicamente las herramientas de análisis, sino también los marcos desde los cuales se produce y valida el conocimiento sobre la ciudad. Aunque esta evolución suele presentarse como un avance incuestionable, es necesario abordarla con una mirada crítica que contemple sus implicaciones epistemológicas, políticas y territoriales.

Desde un enfoque sociotécnico, Latour (2005) señala que las tecnologías no son instrumentos neutrales, sino actores dentro de redes que reflejan y reproducen relaciones de poder. En el contexto urbano, esto implica que los sistemas de IA no solo procesan información espacial, sino que codifican visiones particulares del territorio. Las decisiones automatizadas, por tanto, no están exentas de sesgos, sino que responden a criterios determinados por quienes diseñan los algoritmos.

A esta reflexión, Jessop (2007) agrega que interpreta el uso de IA en la planificación como parte de una transformación más amplia en las formas de gobernanza urbana. Según su análisis, la lógica algorítmica tiende a desplazar procesos participativos, favoreciendo esquemas tecnificados de toma de decisiones, donde la ciudadanía queda relegada y el control del territorio se concentra en manos de actores técnicos o corporativos.

Desde otra perspectiva, Roy (2009) plantea que la adopción de marcos analíticos provenientes del Norte Global, sin mediación local, puede derivar en lo que denomina violencia epistémica. En su visión, la planificación basada en IA corre el riesgo de invisibilizar saberes locales, conocimientos informales o prácticas comunitarias, reforzando una mirada tecnocrática que margina otras formas de habitar y comprender la ciudad.

Estas perspectivas coinciden en la necesidad de revisar críticamente los supuestos que subyacen al uso de tecnologías inteligentes en el urbanismo. Más allá de su aparente eficiencia, la IA redefine las jerarquías del conocimiento,

los modos de intervención y las estructuras de poder que operan en el espacio urbano. En consecuencia, el debate sobre su implementación no puede desligarse de cuestiones como la justicia territorial, la soberanía del dato y la equidad en la producción de saberes espaciales.

Crítica a la dependencia tecnológica y sesgos algorítmicos en la planificación con GeoAI

El entusiasmo por incorporar IA en la gestión territorial ha oscurecido una serie de riesgos asociados a su uso. Entre los más relevantes se encuentran la dependencia de plataformas tecnológicas externas, la opacidad de los modelos algorítmicos y la posibilidad de reproducir desigualdades mediante decisiones automatizadas. Estos aspectos deben considerarse desde el inicio, especialmente en contextos como América Latina, donde las condiciones técnicas, políticas y sociales requieren soluciones contextualizadas.

El concepto de “colonialismo de datos” (Couldry y Mejias, 2019) ilustra cómo las corporaciones tecnológicas globales extraen, procesan y utilizan datos sin responder a las realidades específicas de los territorios. Este fenómeno, al trasladarse al campo de la planificación, puede provocar la imposición de criterios externos sobre necesidades locales, generando escenarios de exclusión, desplazamiento o distorsión del diagnóstico territorial (Crawford, 2021).

La falta de transparencia en el funcionamiento de muchos algoritmos impide que sus resultados sean auditables o cuestionables, lo cual refuerza desigualdades preexistentes. Eubanks (2018) advierte que los sistemas diseñados con datos históricos sesgados tienden a reproducir patrones de discriminación, mientras que Pereira y Ziccardi (2022) señalan que, en ausencia de datos actualizados y completos, los modelos tienden a ser inexactos o ineficaces.

Además, hay territorios que por su escasa presencia en registros digitales quedan fuera del análisis, generando una forma de “invisibilidad algorítmica” (Taylor, 2017). Entre tanto, Birhane (2020) añade que esta exclusión técnica va de la mano con la pérdida de soberanía sobre los sistemas de información, al depender de software y servidores controlados por corporaciones transnacionales.

Bajo esta perspectiva, es fundamental incorporar criterios de ética algorítmica desde el diseño metodológico. Iniciativas como las auditorías de sistemas (Sandvig, et al., 2014), el desarrollo de algoritmos explicables y los marcos de IA responsable, representan alternativas para mitigar estos riesgos. Tales herramientas pueden ayudar a asegurar que la inteligencia artificial no solo consolide las brechas existentes, sino que contribuya a una planificación más justa, democrática y territorialmente situada.

Casos de integración interdisciplinaria

Bases de datos como Inspec, GEOBASE y Compendex, tienen publicadas investigaciones recientes que están indexadas, y reflejan el estado actual de dicha integración interdisciplinaria agrupada en cinco grandes ejes.

En el primer eje destacan los modelos híbridos para predicción geoespacial y gestión del riesgo, como los desarrollados por Pham, et al. (2024), ya que integran redes neuronales profundas y algoritmos de optimización para generar mapas de susceptibilidad con el objetivo de aplicarlos a la infraestructura y prevención de desastres. Por otro lado, Murtaza, et al. (2025) revisan los enfoques híbridos para poder pronosticar la profundidad de socavación en estribos de puentes, combinando datos geotécnicos e hidrológicos junto con técnicas de aprendizaje profundo.

Entre tanto, Elshewy, et al. (2024) proponen modelos que son mejorados para el ajuste del geode (superficie equipotencial del cambio gravitatorio de la tierra que coincide con el nivel medio del mar y se usa como referencia para medir alturas, es decir, altitudes ortométricas) mediante una IA adaptativa, resolviendo con mayor precisión diferencias altimétricas sobre terrenos irregulares.

El segundo eje, aborda la automatización de cartografías en escenarios críticos. Aquí, Liu, et al., (2025) muestran un sistema inteligente para cartografías de emergencia, pero basados en el análisis de imágenes satelitales, aplicando clasificadores automatizados para detectar daños estructurales. No obstante, otros autores utilizan GeoAI para hacer clasificaciones de uso de suelo y detección de cambios, con criterios sostenibles (Sharifi y Mahdipour, 2024). Por último, y en contraste con el aspecto medioambiental, Iban y Aksu (2024), por su parte, utilizan mapas activos de incendios y modelos explicables basados en SHAP, para identificar factores clave de susceptibilidad en zonas de alto riesgo.

Un tercer eje se encuentra vinculado con la transparencia algorítmica y la ética espacial. Autores como Petrocchi, et al. (2024) hacen una propuesta del marco *GeomEthics* para guiar un uso justo de la IA en la geomática. Esto, desde el tratamiento de los datos espaciales que son sensibles, los sesgos algorítmicos, la privacidad, la rendición de cuentas y las transparencias.

Por lo tanto, su foco se localiza en el establecer principios de equidad, explicabilidad y neutralidad, para proponer buenas prácticas operativas tales como auditorías algorítmicas, trazabilidad de decisiones a nivel espacial, así como mecanismos de revisión humana. No solamente es usar la IA, sino asumir los riesgos de manipulación territorial o algunos sesgos en su clasificación geoespacial.

Por otro lado, Atik, et al. (2024) desarrollan técnicas de IA explicable, aplicadas a la segmentación de nubes de puntos, mientras que Kavzoglu, et al. (2025) proponen modelos que exploran parámetros climáticos vinculados a deslizamientos.

Côté, et al. (2024), a su vez, aplican marcos de riesgo para evaluar la vulnerabilidad frente a olas de calor, integrando variables climáticas con algoritmos de predicción basados en IA.

Un cuarto eje, acota al campo educación a nivel superior con Retscher (2025) quien analiza el impacto de la IA en la formación geomática, o estudios que evalúan el uso de modelos generativos como ChatGPT en procesos de enseñanza, con implicaciones metodológicas y éticas. De hecho, Retscher discute los desafíos y oportunidades del uso de IA en la enseñanza de la geomática, destacando el potencial de los modelos generativos para apoyar procesos de aprendizaje personalizado.

En efecto, Jonas (2024), a nivel crítico hace un planteamiento de preguntas sobre el futuro que tienen las actividades hidrológicas humanas ante esta automatización en ascenso, generando un espacio de debate sobre esta relación entre el trabajo técnico especializado y la IA.

Finalmente, el quinto eje acota aquellas aplicaciones emergentes. Un ejemplo de ello es el trabajo de Pham, et al. (2024), donde se explora la predicción de lluvias a partir de modelos neuro-difusos y algoritmos metaheurísticos. Otro ejemplo es el de Peizoto, et al. (2024), donde se estima la contaminación por cafeína en aguas superficiales, pero combinándolo con IA y estadística clásica. Oyebisi, et al. (2024) utilizan modelos de aprendizaje automático para predecir aquellos niveles de radiactividad en residuos reciclados. Por último, Vallejo Molina, et al. (2024) traen un sistema basado en IA para poder alertar explosiones en minas subterráneas; y Elshewy, et al. (2024) proponen variantes en la generación de geoides en lugares de montañas a partir de la IA evolutiva.

Bajo las descripciones anteriores, la sinergia entre la inteligencia artificial en la geomática está avanzando de manera rápida y con una fuerte diversidad metodológica. Estos textos y sus propuestas son un ejemplo de ello, lo que permite abordar con mayor precisión, velocidad y profundidad, problemas territoriales complejos. No obstante, el avance también exige un fortalecimiento; en primer lugar, con marcos éticos, normativos y pedagógicos que den garantía sobre un uso transparente y responsable en términos de las tecnologías emergentes; por otro lado, no se debe dejar de lado el discurso y debate teórico a nivel de los estudios urbanos y de comprensión de las ciudades.

Así que la IA no debe remplazar el conocimiento de la geomática, sino que lo debe potenciar configurando nuevas maneras de entendimiento y transformación del territorio desde una lógica adaptativa e inteligente.

- Aplicaciones recientes y análisis de clústeres: IA y Geomática.

Como parte complementaria, bases de datos académicas, como Scopus, muestran de igual manera la publicación de documentos científicos entre el 2010 y 2025, que vinculan esta sinergia entre geomática e inteligencia artificial.

La Figura 3 muestra una co-ocurrencia de palabras clave, donde se deja claro una estructura temática densa y que está articulada en torno al clúster de IA. De hecho, se observa un eje central que entrelaza a conceptos metodológicos como *machine learning*, *algorithm*, *learning systems* y *decision support systems*, así como a dominios aplicados, como *geomatic*, *remote sensing*, *urban planning* y *earth sciences*.

Los clústeres menos grandes se centran en indicadores de frecuencia y centralidad, donde la IA se convierte en un componente estructural de los estudios geomáticos. El clúster de geomática se localiza en una zona intermedia con alta conexión, lo que demuestra una transversalidad entre esta disciplina en la era digital. Alrededor suyo, aparecen clústeres como *remote sensing*, *software engineering*, *internet of things* e *information systems*.

Lo anterior permite observar una evolución en las líneas de investigación. Los términos más antiguos (tonalidades azules), como *decision theory*, *ecology* o *earth sciences*, fueron en su momento los motores iniciales del diálogo entre geomática e IA. En contraste, conceptos recientes (verde-limón a amarillo), como *urban planning*, *well trajectory* y *brownfields*, evidencian un giro hacia aplicaciones específicas, muchas de ellas orientadas a la sostenibilidad urbana y el monitoreo ambiental de precisión.

Un clúster particular de interés es el que vincula *urban planning* con *well trajectory* y *brownfields*. Aunque de menor tamaño, esta agrupación se encuentra densamente conectada, lo que sugiere la consolidación de una línea emergente que integra inteligencia artificial para el análisis de suelos contaminados y la gestión de trayectorias de perforación, temas relevantes en el contexto de la regeneración urbana y la gestión de recursos.

Por otro lado, el clúster de *students* y *education* está conectado a conceptos como *learning systems*, lo que muestra una creciente preocupación por los procesos formativos y pedagógicos. Por lo tanto, los clústeres revelan que la intersección entre inteligencia artificial y geomática no solo está madurando, sino diversificándose en múltiples direcciones. La evolución temporal de los términos y la densidad de conexiones entre nodos, apuntan a una consolidación del campo como espacio híbrido, donde la innovación tecnológica se combina con problemas espaciales complejos y demandas sociales urgentes. En cuanto a la evolución temporal, la Figura 4 representa la evolución de publicaciones de documentos relacionados con inteligencia artificial y geomática entre los años 1992 y 2025. Aquí, se observa un comportamiento estable y bajo hasta 2018, con un punto de inflexión en 2020, año a partir del cual las publicaciones se incrementan de manera significativa.

El pico máximo ocurre en 2023, con más de 20 publicaciones, lo que indica un crecimiento exponencial reciente del interés académico en esta convergencia temática. Posteriormente, en 2025 se nota una ligera disminución, aunque el volumen sigue siendo considerable en comparación con las décadas anteriores.




Figura 3. Análisis de clústeres. Fuente: elaboración propia.




Figura 4. Años de publicaciones. Fuente: elaboración propia con base en el análisis bibliométrico generado mediante la plataforma Scopus (Elsevier, 2024).

La Tabla 1, por otra parte, presenta una distribución, por país, del número de documentos científicos publicados sobre el tema. Italia encabeza la lista con 20 publicaciones, posicionándose como el líder en producción académica en esta área. Le siguen India y el Reino Unido, con 8 documentos cada uno, y Canadá, con 7. Otros países como China, Francia, España y Estados Unidos muestran una participación equilibrada, con 5 publicaciones cada uno, mientras que los Países Bajos y Austria tienen una menor representación, con 3 y 2 documentos respectivamente. Estos datos reflejan una presencia dominante de países europeos y asiáticos en la investigación sobre esta temática.

Tabla 1. Número de documentos publicados por país.

País	Documentos
Italy	20
India	8
United Kingdom	8
Canada	7
China	6
France	5
Spain	5
United States	5
Netherlands	3
Austria	2

Fuente: elaboración propia con base en el análisis bibliométrico generado mediante la plataforma Scopus (Elsevier, 2024).

Aportación del libro

En este orden de ideas, el presente volumen del libro “Geomática y procesos urbanos: planeación urbana”, integra investigaciones académicas de carácter tecnológico más avanzadas en el uso de herramientas de la geomática, inteligencia artificial (IA) y tecnologías de planificación geoespacial para el análisis y comprensión de procesos urbanos desde una perspectiva crítica y multiescalar, aplicados para diferentes casos de estudios latinoamericanos.

Se trata de una edición que no solo recopila aspectos técnicos, sino que convierte a la IA en un elemento central del proceso de análisis urbano, lo que permite tener una lectura más integral de aquellas transformaciones que ha tenido el territorio contemporáneo, incluyendo estudios empíricos sobre centralidad, expansión, desigualdad socioespacial, gentrificación climática, seguridad vial, violencia urbana, degradación ambiental, y cambios de cobertura de suelo, entre otros.

Por lo tanto, se sitúa dentro de una sinergia entre las tecnologías geoespaciales y la planeación territorial, de manera que pueda responder a

necesidades urgentes, como la comprensión de procesos de reconfiguración urbana a partir de contextos de expansión desigual, fragmentación socioespacial y presiones ambientales.

Adicionalmente, el libro se desarrolla dentro de una línea de continuidad crítica con investigaciones previas que han aplicado estudios urbanos a partir de los sistemas de información geográfica. Así que dialoga con trabajos que han planteado la necesidad de modernizar en gran medida los instrumentos de planeación urbana a partir del uso de datos geoespaciales, modelamientos tridimensionales, percepción remota y análisis territorial. Sin embargo, este libro profundiza en la problemática, pues integra algoritmos de inteligencia artificial y metodologías automatizadas en Python, Google Earth Engine y clasificación satelital, que son herramientas poco exploradas de manera aplicada y sistemática en publicaciones similares en el contexto latinoamericano. Por lo tanto, el libro toma una postura metodológicamente innovadora pero epistemológicamente situada.

Como obras que han precedido este enfoque, están los aportes hechos por Buzai y Montes (2021) a partir de la estadística espacial, junto con las aplicaciones urbanas con SIG en la revista EURE. Autores como García, (2016) han trabajado temas de modelos de densidad, cobertura de suelo y centralidad. No obstante, estas publicaciones han centrado su aplicación en contextos anglosajones y aislados, sin una articulación temática.

Entre las obras más recientes y relevantes, se destaca el libro “Geomática y Procesos Urbanos. Métodos y Conceptos” (2023), que generó un aporte significativo desde la consolidación de un enfoque metodológico común para el uso de algunas herramientas de la geomática aplicada a los estudios urbanos, puntualmente en la representación cartográfica y el modelamiento territorial en contextos latinoamericanos. Este libro presentó fundamentos y procesos técnicos aplicando SIG, percepción remota, e instrumentos y geo procesos en el análisis territorial.

Sin embargo, a pesar de que marca de manera introductoria los métodos y conceptos, esta nueva edición “Geomática y procesos urbanos. Planeación urbana”, hace una propuesta de avance en dos caminos sustantivos. El primero es que profundiza en la aplicación empírica de las herramientas en territorios urbanos concretos: en México, en Ciudad de México, (CDMX, Zona Metropolitana de Valle de México, Colonia Polanco, Colonia Condesa, Colonia Roma, Estado de Morelos, Cuajimalpa, entre otros); en Colombia, en ciudades como Bogotá y Barranquilla; en Nicaragua, en la ciudad de Managua, y en Panamá; a través del análisis de fenómenos específicos como densificación vertical, monocentrismo, gentrificación climática, fragmentación funcional o conflictos ambientales. Por otro lado, incorpora un enfoque integrado a partir de las teorías urbanas y herramientas técnicas, permitiendo que la geomática no sea solo un recurso instrumental, sino también una vía para construir lectura crítica territorial.

En 2023, el libro cumplía la función de dar una introducción enfocada en el cómo se hace. En cambio, el libro actual responde al para qué sirve y qué se puede interpretar a partir de los datos espaciales en la planificación urbana contemporánea. Bajo esta perspectiva, las dos ediciones se leen como complementos: el primero suministra aquellos fundamentos técnicos y conceptuales, mientras que el segundo desarrolla casos de estudio avanzados que demuestran que los métodos pueden aplicarse para transformar la comprensión, y de forma eventual, la gestión de procesos urbanos. Así, este libro propone una maduración temática aplicada respecto al anterior.

Nuestro libro está escrito y dirigido, de manera principal, hacia estudiantes de posgrado en urbanismo, geografía, arquitectura, ingeniería ambiental, planificación territorial y otras disciplinas afines. También está dirigido a investigadores y profesionistas vinculados a temas de gestión del desarrollo urbano y formulación de políticas públicas; además, también podrían consultarlo funcionarios técnicos de gobiernos locales, desarrolladores urbanos y organizaciones sociales interesadas en comprender, a partir de estos datos, aspectos puntuales de las ciudades acá analizadas.

El enfoque aplicado y técnico de los capítulos permite su uso como manual de consulta para docentes y estudiantes en cursos de SIG, análisis territorial, planeación y políticas urbanas. Además, parte del contenido tiene valor divulgativo para pobladores locales y colectivos urbanos que busquen comprender los impactos territoriales de fenómenos como la densificación, la fragmentación o la segregación.

Por lo tanto, esta edición tiene como objetivo aportar una base metodológica, empírica y conceptual para el análisis de procesos urbanos contemporáneos mediante el uso de tecnologías geoespaciales avanzadas. A través de los 15 capítulos se busca demostrar cómo la geomática y la inteligencia artificial pueden no solo describir, sino también explicar y anticipar dinámicas territoriales clave, como la expansión desigual, la gentrificación climática, la densificación vertical, los patrones de movilidad o los riesgos ambientales. En síntesis, el libro busca contribuir a una planificación urbana más informada, inclusiva y adaptada a los desafíos socioespaciales de las ciudades latinoamericanas en el siglo XXI.

Asimismo, como antecedentes sobre el tema de estudio en este libro, en los últimos 20 años la forma de observar, analizar, interpretar y representar el territorio ha estado estrechamente ligada al desarrollo de nuevas herramientas geoespaciales. El acceso masivo a imágenes satelitales, la disponibilidad de software libre de análisis espacial y la generación continua de datos urbanos en múltiples escalas, han modificado radicalmente el horizonte técnico y conceptual de las ciencias urbanas. Este viraje ha sido descrito como una auténtica “revolución geoespacial” (Goodchild, 2018), no solo por la magnitud del volumen de datos disponible, sino por el giro metodológico que implica: pasar de una lógica analógica a una inteligencia computacional que permite

modelar procesos dinámicos, anticipar transformaciones espaciales y construir escenarios de planificación en tiempo real.

Autores como Batty (2013) y Jiang (2020) han argumentado que este giro no es únicamente técnico, sino epistemológico. El urbanismo ya no se basa exclusivamente en planos, cartografías estáticas o censos quinquenales, sino en flujos, redes, sensores, imágenes multispectrales y sistemas inteligentes de aprendizaje. Bajo esta perspectiva, la geomática deja de ser un auxiliar cartográfico y se convierte en una arquitectura de conocimiento que opera sobre grandes bases de datos espaciales y multivariados. Se trata de una forma distinta de leer lo urbano: más precisa, pero también más abierta a la incertidumbre y a la complejidad de los procesos territoriales contemporáneos.

En América Latina, sin embargo, este proceso de actualización técnica y metodológica ha avanzado de forma desigual. Si bien se han desarrollado infraestructuras de datos espaciales, programas de SIG libres y protocolos de interoperabilidad, su incorporación sistemática en el análisis urbano y la toma de decisiones sigue siendo limitada. Las razones son múltiples: escasez de formación técnica especializada, ausencia de cultura institucional en el uso de datos espaciales, fragmentación entre disciplinas, y una débil articulación entre investigación académica y política pública (Pérez Campuzano y Esponda, 2021; Buzai, 2022).

Bajo esta perspectiva, el libro busca contribuir en la reducción de esta brecha. Reúne investigaciones aplicadas donde la geomática, la inteligencia artificial y la modelación urbana no son únicamente herramientas técnicas, sino formas de reconfigurar la lectura crítica del territorio y de ampliar las capacidades analíticas de la planificación urbana en escenarios latinoamericanos complejos.

En este contexto, el libro se estructura a partir de 15 capítulos, desarrollados al interior de tres grandes líneas temáticas que muestran las distintas dimensiones del análisis urbano contemporáneo:

- Línea temática uno: “Planeación urbana. Geomática e IA aplicada a los análisis urbanos” (Capítulos 1 al 6).

Esta línea se sitúa en la intersección entre el análisis espacial avanzado y la planificación urbana contemporánea. En ella se reúnen investigaciones que abordan la estructura funcional de las ciudades desde categorías como monocentrismo, policentrismo, dispersión y densificación, reconociendo el carácter dinámico y jerárquico del sistema urbano. Autores como Bertaud (2003) y Muñiz, et al. (2008) quienes han planteado que la forma urbana influye directamente en la eficiencia del transporte, el acceso a oportunidades y la sustentabilidad territorial.

Desde el ámbito técnico, la incorporación de modelos de inteligencia artificial, aprendizaje supervisado y redes neuronales en estudios de

microsegregación, detección de nodos funcionales y simulación de densidades, han sido trabajadas por investigadores como Batty (2018) y Li, et al. (2020), quienes proponen que los entornos urbanos pueden ser modelados como sistemas complejos adaptativos mediante algoritmos geoespaciales. Este conjunto de capítulos plantea una transición metodológica de los métodos cartográficos tradicionales hasta un urbanismo de datos orientado a la modelación predictiva y la simulación espacial.

- Línea temática dos: “Procesos urbanos, habitabilidad y transformación socioespacial” (Capítulos 7 al 11).

Esta línea profundiza en los procesos sociales que configuran la experiencia cotidiana del habitar urbano, con especial atención en las condiciones de movilidad, seguridad, salud y acceso al espacio público. A través de análisis empíricos sobre violencia urbana, criminalidad, transporte y vivienda, esta sección se inscribe en el debate sobre la justicia espacial y la habitación digna, aportando evidencia para el diseño de políticas públicas centradas en la equidad territorial.

Autores como Harvey (2012) y Davis (2006) han enfatizado que el diseño del entorno urbano no es neutral, sino que reproduce desigualdades. En América Latina, estudios como los de Rodríguez y Arriagada (2004) o Borsdorf e Hidalgo (2010) han demostrado que la segregación residencial, la violencia cotidiana y el deterioro de la habitabilidad urbana son fenómenos interconectados que afectan desproporcionadamente a sectores populares. La aplicación de análisis geoespaciales a esta problemática, como lo son el mapeo de delitos, la correlación entre condiciones ambientales y vivienda o la identificación de patrones de exclusión, constituye una herramienta crítica para hacer visibles desigualdades históricas que antes eran ignoradas por la planificación convencional.

- Línea temática tres: “Transformaciones ambientales urbanas y tecnologías geoespaciales para el análisis territorial” (Capítulos 12 al 15).

La tercera línea se orienta hacia los vínculos entre urbanización y medio ambiente, examinando los impactos territoriales derivados del cambio climático, la presión sobre recursos hídricos, la modificación de la cobertura del suelo, y los procesos emergentes como la gentrificación climática. Esta sección articula un enfoque ambiental con capacidades técnicas de teledetección, NDVI, imágenes multitemporales y algoritmos de cambio de uso del suelo, situando a la geomática como una herramienta clave para el monitoreo ambiental urbano.

Investigaciones recientes de Seto, et al. (2012), Grimmond (2007) y Solecki, et al. (2017) han argumentado que el análisis ambiental en

ciudades requiere cada vez más de datos de alta resolución, multiescalares y temporales, especialmente en regiones del Sur global. En ese marco, la noción de gentrificación climática desarrollada por autores como Immergluck (2018) y Anguelovski, et al. (2019), permite entender cómo las inversiones en infraestructura verde o resiliencia pueden detonar procesos de expulsión indirecta de población vulnerable. Finalmente, el uso de geomática para la detección de fugas hidráulicas y el monitoreo de estrés hídrico urbano, ha sido promovido por autores como Shahzad, et al. (2020) y Tavares, et al. (2021), mostrando el potencial de las tecnologías geoespaciales para enfrentar crisis urbanas con base técnica y territorial.

Es así como el capítulo 1, titulado “Geoplaneación urbana. Métodos y modelos computacionales desde lo urbano”, escrito por Ricardo Gómez Maturano, Marielena Medina Ruiz y Ma. de los Ángeles Martínez Ortega, aborda la Geoplaneación urbana como enfoque innovador que integra tecnologías geoespaciales, inteligencia artificial, big data y SIG para analizar, modelar y gestionar el territorio. Propone métodos computacionales aplicados a contextos urbanos latinoamericanos, con énfasis en sostenibilidad, justicia espacial y toma de decisiones informadas en planificación urbana y regional.

El capítulo 2, titulado “Monocentrismo o policentrismo en la Ciudad de México. Análisis espacial con IA y SIG’s”, escrito por Ricardo Gómez Maturano, analiza la evolución de la centralidad urbana en la Ciudad de México entre 2010 y 2020. Mediante un análisis de densidad de empleo por AGEB, regresiones en Python y el cálculo del Índice de Atracción, se determina la transición parcial, desde una estructura urbana monocéntrica hasta una configuración policéntrica funcional. Se propone una lectura crítica del modelo tradicional, integrando herramientas de geomática y análisis espacial multiescalar.

En el capítulo 3, titulado “Planeación urbana: proyección de la densificación urbana al 2030. Caso estudio Polanco, México”, escrito por María Fernanda Islas Monroy, se evalúan los procesos de verticalización urbana en Polanco, CDMX, entre 2008 y 2022, con una proyección prospectiva al año 2030. Utilizando SIG y modelaciones tridimensionales, se identifican predios con cambios de niveles y sus impactos sobre infraestructura, movilidad y servicios. El estudio enfatiza la necesidad de revisar normativas de desarrollo urbano para evitar efectos colaterales derivados de la densificación acelerada.

El capítulo 4, titulado “Percepción remota en el análisis de la dispersión urbana en zonas costeras. Clasificación supervisada de imágenes satelitales”, escrito por Rogelio Contreras González, propone una metodología de análisis de dispersión urbana en zonas costeras mediante percepción remota. En él, se aplican técnicas de clasificación supervisada de imágenes satelitales para identificar patrones de crecimiento urbano fragmentado. Los resultados ofrecen una lectura espacial precisa sobre los impactos territoriales de la expansión informal en franjas litorales vulnerables.

El capítulo 5, titulado “Evaluación de políticas públicas urbanas: una herramienta estratégica para la planificación integral del territorio” escrito por Álvaro Flores Miranda, subraya la importancia de la evaluación como herramienta estratégica para mejorar la planificación urbana. En contextos donde la urbanización ocurre sin planificación adecuada, la evaluación permite identificar brechas, ajustar políticas y orientar decisiones más justas e integrales. Lejos de ser solo un control de resultados, evaluar se propone como un proceso clave para el aprendizaje institucional y la mejora continua del territorio.

Por su parte, en el capítulo 6, titulado “Micro-segregación residencial en Managua: entre la conciliación espacial y la fractura social”, Perla María Sánchez Uriarte aborda el fenómeno de la micro-segregación en Managua, Nicaragua, mediante un análisis espacial de variables socioeconómicas, accesibilidad y densidad habitacional. El estudio evidencia cómo los procesos de fragmentación territorial afectan la cohesión social y el acceso a oportunidades urbanas. Se propone, dentro de este apartado, un enfoque analítico que integra justicia espacial y diseño urbano inclusivo.

El capítulo 7, titulado “Desigualdad socioespacial del tiempo empleado en la movilidad cotidiana de la Zona Metropolitana del Valle de México”, de la autoría de Margarita Ruiz Camacho y Ricardo Gómez Maturano, explora cómo las desigualdades espaciales se reflejan en el tiempo de traslado diario. A partir de datos de movilidad y análisis estadístico, se construyen mapas que revelan las diferencias entre zonas céntricas y periféricas. El estudio demuestra la relación directa entre ubicación territorial, acceso al transporte, y tiempo invertido en movilidad urbana.

El capítulo 8, titulado “La seguridad vial de los motociclistas en la Ciudad de México en el año 2022”, de Raquel Andrea Delgadillo Díaz, describe que, a partir del análisis geoespacial de siniestros viales, se identifican zonas de mayor riesgo para motociclistas en la CDMX. Se propone una tipología de puntos críticos, y se sugiere una reconfiguración del espacio vial para reducir accidentes. La investigación aporta evidencia territorial para el diseño de políticas de seguridad vial más efectivas.

El capítulo 9, titulado “Análisis espacial de los delitos de alto impacto en Panamá (2017-2023). Un enfoque geoespacial para la comprensión de la violencia urbana”, escrito por Víctor Raúl Quintero Barba, analiza la distribución de delitos de alto impacto en Panamá. Se aplican en él modelos de densidad kernel y mapas de calor para evidenciar patrones territoriales de violencia. El estudio permite identificar correlaciones entre crimen, segregación urbana y debilidad institucional.

En el capítulo 10, titulado “Importancia de la planeación urbana en la habitabilidad humana: la vivienda saludable”, de Ma. de los Ángeles Martínez Ortega, discute cómo la planeación urbana incide en la calidad de la vivienda y la salud de sus habitantes. Se evalúan las condiciones físicas, ambientales

y sociales en diferentes sectores urbanos, proponiendo lineamientos para fomentar viviendas saludables en contextos vulnerables.

Luis Armando Soto Martínez, en el capítulo 11 titulado, “Regeneración urbana y análisis territorial: propuesta para la zona Roma, Condesa y Doctores”, presenta una propuesta de intervención urbana en la zona Roma-Condesa-Doctores basada en el análisis territorial. Se identifican indicadores clave para regeneración como accesibilidad, conectividad y valor del suelo. El capítulo destaca la importancia de políticas integrales que equilibren conservación patrimonial y renovación urbana.

El capítulo 12, titulado “Geografías del impacto urbano en el Bosque de Agua. Diagnóstico territorial basado en SIG y Teledetección”, escrito por Cristy Monserratt Sánchez Ramos, aplica técnicas de SIG y teledetección para evaluar los impactos urbanos sobre el Bosque de Agua. Se identifican procesos de deforestación, expansión urbana y vulnerabilidad hídrica. El análisis subraya la necesidad de una gestión ambiental territorial más rigurosa en zonas de recarga.

El capítulo 13, titulado “Gentrificación de los climas urbanos y su impacto socioambiental en Bogotá y Barranquilla. Análisis desde la geomática y la percepción remota”, de la autoría de Marielena Medina Ruiz y J. Guadalupe Martínez Granados, analiza el fenómeno de gentrificación climática mediante el cruce entre NDVI, LST y mapas socioeconómicos. Se evidencia cómo el acceso a vegetación y condiciones térmicas favorables se concentra en áreas de estratos altos, generando desplazamientos indirectos. Se propone una lectura crítica de la justicia climática.

Luz de Lourdes Cordero Gómez del Campo y Víctor Manuel Sánchez Vega, en el capítulo 14 titulado “Identificación del avance de la cobertura de suelo urbano utilizando supervisión clasificada en Google Earth Engine”, aplican algoritmos en Google Earth Engine, y monitorean la expansión urbana a través de clasificación supervisada. El análisis temporal permite identificar zonas críticas de crecimiento desordenado y pérdida de cobertura vegetal. El capítulo evidencia el potencial de la tecnología para un seguimiento urbano de bajo costo.

Por último, el capítulo 15 titulado “Detección de fugas en la red primaria de la Ciudad de México a través de puntos de presión. Procesamiento de datos hidráulicos mediante análisis con Python”, escrito por Ana Laura Castillo Hernández, desarrolla una metodología automatizada para la detección de fugas de agua en redes primarias. A través de sensores de presión y programación en Python, se identifican anomalías en el sistema hidráulico de la CDMX. El estudio plantea alternativas para la gestión eficiente del recurso hídrico urbano.

Referencias

- Alqadhi, S., Aldabbas, H., Alshamrani, A., y Alharkan, I. (2024). Applying deep learning to manage urban ecosystems in arid Abha, Saudi Arabia: Remote sensing-based modelling for ecological condition assessment and decision-making. *Heliyon*, 10(4), e25731. <https://doi.org/10.1016/j.heliyon.2024.e25731>
- Angelovski, I., Connolly, J. J. T., Garcia Lamarca, M., Cole, H., y Pearsall, H. (2019). New scholarly pathways on green gentrification: What does the urban 'green turn' mean and where is it going? *Progress in Human Geography*, 43(6), 1061–1086. <https://doi.org/10.1177/0309132518803799>
- Atik, M. E., Duran, Z., y Seker, D. Z. (2024). Explainable artificial intelligence for semantic segmentation of point clouds. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. <https://doi.org/10.1109/JSTARS.2024.1005802>
- Batty, M. (2013). *The new science of cities*. MIT Press.
- Batty, M. (2018). *Inventing future cities*. MIT Press.
- Bertaud, A. (2003). Clearing the air in Atlanta: Transit and smart growth or conventional economics? *Journal of Urban Economics*, 54(3), 379–400. [https://doi.org/10.1016/S0094-1190\(03\)00080-2](https://doi.org/10.1016/S0094-1190(03)00080-2)
- Birhane, A. (2020). Algorithmic injustice: A relational ethics approach. *Patterns*, 2(2), 100205. <https://doi.org/10.1016/j.patter.2020.100205>
- Borsdorf, A., y Hidalgo, R. (2010). From Polarization to Fragmentation. Recent Changes in Latin American Urbanization. In D. L. Drakakis Smith (Ed.), *Urban Fragmentation in Latin America: Social and Spatial Transformation in Cities* (pp. 47–66). Springer.
- Boutayeb, A., Lahsen-cherif, I., y Khadimi, A. E. (2024). A comprehensive GeoAI review: Progress, Challenges and Outlooks. arXiv preprint arXiv:2412.11643.
- Buzai, G. D. (2022). El análisis geoespacial como base del conocimiento urbano-territorial. *Revista EURE*, 48(145), 1–23. <https://doi.org/10.7764/EURE.48.145.01>
- Buzai, G. D., y Montes Galbán, E. (2021). *Estadística espacial: Fundamentos y aplicación con sistemas de información geográfica*. Universidad Nacional de Luján, Instituto de Investigaciones Geográficas. ISBN 978-987-48369-3-9
- Côté, J. N., Germain, M., Levac, E., y Lavigne, E. (2024). Vulnerability assessment of heat waves within a risk framework using artificial intelligence. *Sustainable Cities and Society*, 96, 105612. <https://doi.org/10.1016/j.scs.2023.105612>
- Couclelis, H. (1986). Artificial intelligence in geography: Conjectures on the shape of things to come. *The Professional Geographer*, 38(1), 1–11. <https://doi.org/10.1111/j.0033-0124.1986.00001.x>
- Couldry, N., y Mejias, U. A. (2019). *The costs of connection: How data is colonizing human life and appropriating it for capitalism*. Stanford University Press.

- Crawford, K. (2021). *Atlas of AI: Power, politics, and the planetary costs of artificial intelligence*. Yale University Press.
- Davis, M. (2006). *Planet of slums*. Verso Books.
- Elsheawy, M. A., Trung Thanh, P., Elsheshtawy, A. M., Refaat, M., y Freeshah, M. (2024). A novel approach for optimizing regional geoid modeling using hybrid AI-based techniques. *Egyptian Journal of Remote Sensing and Space Sciences*, 27(1), 155–166. <https://doi.org/10.1016/j.ejrs.2023.06.002>
- Elsevier. (2024). Scopus [Base de datos]. <https://www.scopus.com>
- Estes, J. E., Sailer, C., y Tinney, L. R. (1986). Applications of artificial intelligence techniques to remote sensing. *The Professional Geographer*, 38(2), 133–141. <https://doi.org/10.1111/j.0033-0124.1986.00133.x>
- Eubanks, V. (2018). *Automating inequality: How high-tech tools profile, police, and punish the poor*. St. Martin's Press.
- Gallo, I., Gallo, D., Lillo, M., y Teti, R. (2023). In-season and dynamic crop mapping using 3D convolution neural networks and Sentinel-2 time series. *ISPRS Journal of Photogrammetry and Remote Sensing*, 195, 335–352. <https://doi.org/10.1016/j.isprsjprs.2022.12.005>
- Gao, S., Janowicz, K., Montello, D. R., Hu, Y., Yang, J. A., McKenzie, G., Ju, Y., Adams, B., y Yan, B. (2020). A comprehensive synthesis of GeoAI: Definitions, methodologies, and applications. *ISPRS International Journal of Geo-Information*, 9(4), 213. <https://doi.org/10.3390/ijgi9040213>
- García, F. (2016). Compacidad y densidad de las ciudades españolas. *Revista EURE - Revista de Estudios Urbano Regionales*, 42(127), 5–27. <https://doi.org/10.4067/S0250-71612016000300001>
- Geng, L., Qiao, J., Shi, Y., y Chen, Y. (2023). Machine learning approaches to improve North American precipitation forecasts. *IEEE Access*, 11, 330905–330921. <https://doi.org/10.1109/ACCESS.2023.3309054>
- Goodchild, M. F. (2018). Reimagining the history of GIS. *Annals of GIS*, 24(1), 1–8. <https://doi.org/10.1080/19475683.2018.1424734>
- Grimmond, S. (2007). Urbanization and global environmental change: Local effects of urban warming. *The Geographical Journal*, 173(1), 83–88. https://doi.org/10.1111/j.1475-4959.2007.232_3.x
- Harvey, D. (2012). *Rebel cities: From the right to the city to the urban revolution*. Verso Books.
- Hu, Y., Goodchild, M., Zhu, A. X., Yuan, M., Aydin, O., Bhaduri, B., ... y Newsam, S. (2024). A five-year milestone: reflections on advances and limitations in GeoAI research. *Annals of GIS*, 30(1), 1–14.
- Iban, M. C., y Aksu, O. (2024). SHAP-driven explainable artificial intelligence framework for wildfire susceptibility mapping: A case study in Turkey. *Environmental Modelling & Software*, 170, 105670. <https://doi.org/10.1016/j.envsoft.2023.105670>

- IBM. (s.f.). *History of artificial intelligence*. Recuperado el 30 de julio de 2025, de <https://www.ibm.com/think/topics/history-of-artificial-intelligence>
- Immergluck, D. (2018). Old wine in private equity bottles? The resurgence of contract-for-deed home sales in U.S. urban neighborhoods. *International Journal of Urban and Regional Research*, 42(4), 651–665. <https://doi.org/10.1111/1468-2427.12605>
- Janowicz, K., Gao, S., McKenzie, G., Hu, Y., Bhaduri, B., y Adams, B. (2020). GeoAI: Spatially explicit artificial intelligence techniques for geographic knowledge discovery and beyond. *International Journal of Geographical Information Science*, 34(4), 625–636. <https://doi.org/10.1080/13658816.2019.1684500>
- Jessop, B. (2007). *State Power*. Polity Press.
- Jiang, B. (2020). Urban structure from the perspective of head/tail breaks: A new classification scheme for cities. *Environment and Planning B: Urban Analytics and City Science*, 47(1), 155–168. <https://doi.org/10.1177/2399808319857072>
- Jiang, B., y Yao, X. (2010). Geospatial analysis and modeling of urban structure and dynamics: An overview. *Geospatial analysis and modelling of urban structure and dynamics*, 3–11.
- Jonas, M. (2024). When will human hydrographic activities be substituted by artificial intelligence? *Journal of Marine Science and Engineering*, 12(1), 83. <https://doi.org/10.3390/jmse12010083>
- Kalinicheva, E., Kang, Y., y Shekhovtsov, A. (2020). Unsupervised change detection analysis in satellite image time series using deep learning combined with graph-based approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 1450–1466. <https://doi.org/10.1109/JSTARS.2020.2982631>
- Kavzoglu, T., Teke, A., y Celik, N. (2025). Explainable AI for landslide susceptibility mapping: Opening the black box. *Landslides*. <https://doi.org/10.1007/s10346-024-02260-4>
- Latour, B. (2005). *Reassembling the social: An introduction to actor-network-theory*. Oxford University Press.
- LeCun, Y., Bengio, Y., y Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Li, W. (2020). GeoAI: Where machine learning and big data converge in GIScience. *Journal of Spatial Information Science*, 20, 71–77. <https://doi.org/10.5311/JOSIS.2020.20.658>
- Li, W., Dragicevic, S., y Castro, F. A. (2021). A review of machine learning methods for processing geospatial big data in urban studies. *Urban Informatics*, 1(1), 1–20. <https://doi.org/10.1007/s44212-021-00001-7>
- Li, X., Zhou, W., Ouyang, Z., y Zeng, Y. (2020). Monitoring and simulating urban expansion using cellular automata and artificial intelligence approaches.

- Computers, Environment and Urban Systems, 82, 101505. <https://doi.org/10.1016/j.compenvurbsys.2020.101505>
- Liu, J., Wang, Z., Xu, S., Ren, F., Wang, Y., Tang, Q., y Zhou, T. (2025). Emergency surveying and mapping in the era of artificial intelligence: A comprehensive review. *Geomatics and Information Science of Wuhan University*, 50(3), 318–336. <https://doi.org/10.13203/j.whugis20230076>
- Mai, G., Xie, Y., Jia, X., Lao, N., Rao, J., Zhu, Q., ... y Jiao, J. (2025). Towards the next generation of Geospatial Artificial Intelligence. *International Journal of Applied Earth Observation and Geoinformation*, 136, 104368.
- McCarthy, J. (1979, 12 de febrero). *History of Lisp* [Documento web]. Stanford University. <http://jmc.stanford.edu/articles/lisp.html>
- McCarthy, J., Minsky, M., Rochester, N., y Shannon, C. E. (1955). *A proposal for the Dartmouth Summer Research Project on Artificial Intelligence* [PDF]. Stanford University. <http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>
- McKenzie, G., Zhang, H., y Gambs, S. (2023). *Privacy and ethics in GeoAI*. In *Handbook of Geospatial Artificial Intelligence* (pp. 388–405). CRC Press.
- Mitran, T., Meena, R. S., y Chakraborty, A. (2020). Geospatial technologies for crops and soils: an overview. *Geospatial technologies for crops and soils*, 1–48.
- Moranduzzo, T., y Melgani, F. (2012). A SIFT-SVM method for detecting cars in UAV images. In *2012 IEEE International Geoscience and Remote Sensing Symposium* (pp. 6868–6871). IEEE. <https://doi.org/10.1109/IGARSS.2012.6352585>
- Muñiz, I., Galindo, A., y García López, M. À. (2008). La medida de la compacidad urbana: El caso de Barcelona. *EURE (Santiago)*, 34(103), 37–61.
- Murtaza, N., Khan, D., Rezzoug, A., Benzougagh, B., y Khedher, K. M. (2025). Scour depth prediction around bridge abutments using hybrid AI models. *Physics of Fluids*, 37(2), 023614. <https://doi.org/10.1063/5.0175572>
- OpenAI. (2022, 30 de noviembre). Introducing ChatGPT. <https://openai.com/blog/chatgpt/>
- Openshaw, S., y Openshaw, C. (1997). *Artificial intelligence in geography*. John Wiley and Sons, Inc.
- Oyebisi, S., Shammass, M. I., Jagadesh, P., Owamah, H., y Oyewola, M. O. (2024). Modelling radium activity concentration in recycled industrial waste using machine learning algorithms. *Journal of Environmental Radioactivity*, 267, 106994. <https://doi.org/10.1016/j.jenvrad.2023.106994>
- Peixoto, L. O. M., da Costa Pereira, J. L. G. F. S., Fernandes, C. V. S., Centeno, J. A. S., y de Azevedo, J. C. R. (2024). Modeling caffeine contamination in surface waters using artificial intelligence and classical statistics. *Science of the Total Environment*, 911, 168996. <https://doi.org/10.1016/j.scitotenv.2023.168996>

- Pereira, R., y Ziccardi, J. (2022). Ética digital y gobernanza de datos en América Latina: retos para una inteligencia artificial inclusiva. *Revista Iberoamericana de Ciencia, Tecnología y Sociedad*, 17(50), 13–29. <https://doi.org/10.58210/ctys.v17i50.2592>
- Pérez Campuzano, A., y Esponda, I. (2021). Geotecnologías y planificación territorial en América Latina: Avances, limitaciones y desafíos. *Cuadernos Geográficos*, 60(2), 99–116. <https://doi.org/10.30827/cuadgeo.v60i2.16474>
- Petrocchi, E., Tiribelli, S., Paolanti, M., Giovanola, B., Frontoni, E., y Pierdicca, R. (2024). GeomEthics: Ethical considerations for the integration of artificial intelligence in geomatics. In *Image Analysis and Processing – ICIAP 2023 Workshops* (pp. 32–43). Springer. https://doi.org/10.1007/978-3-031-52848-4_4
- Pham, B. T., Bui, K. T. T., Prakash, I., y Ly, H. B. (2024). Hybrid artificial intelligence models for rainfall prediction: A case study in Vietnam. *Hydrology Research*, 55(1), 23–35. <https://doi.org/10.2166/nh.2023.100>
- Rai, P. K., Mishra, V. N., y Singh, P. (Eds.). (2022). *Geospatial technology for landscape and environmental management: sustainable assessment and planning*. Springer Nature.
- Raju, K. V., Hegde, V. R., y Hegde, S. A. (2019). *Geospatial Technologies for Agriculture: Case Studies from India*. Springer International Publishing.
- Rathore, M. M., Shah, S. A., Shukla, N., Bentafat, E., y Bakiras, S. (2021). The role of AI, machine learning, and big data in smart cities. *Future Generation Computer Systems*, 132, 395–411. <https://doi.org/10.1016/j.future.2021.03.037>
- Retscher, G. (2025). Artificial intelligence in geomatics education: Opportunities and challenges. *Applied Geomatics*. <https://doi.org/10.1007/s12518-024-00510-7>
- Rodríguez, J., y Arriagada, C. (2004). Segregación residencial en las principales ciudades chilenas: Tendencias de las tres últimas décadas y posibles cursos de acción. *EURE (Santiago)*, 30(91), 21–42.
- Roy, A. (2009). Why India cannot plan its cities: Informality, insurgence and the idiom of urbanization. *Planning Theory*, 8(1), 76–87. <https://doi.org/10.1177/1473095208099299>
- Sandvig, C., Hamilton, K., Karahalios, K., y Langbort, C. (2014). Auditing algorithms: Research methods for detecting discrimination on internet platforms. In *Data and discrimination: Collected essays* (pp. 1–23). Open Technology Institute.
- Seto, K. C., Güneralp, B., y Hutyrá, L. R. (2012). Global forecasts of urban expansion to 2030 and direct impacts on biodiversity and carbon pools. *Proceedings of the National Academy of Sciences*, 109(40), 16083–16088. <https://doi.org/10.1073/pnas.1211658109>

- Shahzad, M. K., ur Rehman, Z., y Akram, A. (2020). Detection and localization of water leakages in urban water distribution networks using data-driven models. *Water*, 12(2), 357. <https://doi.org/10.3390/w12020357>
- Sharifi, A., y Mahdipour, H. (2024). Geospatial artificial intelligence (GeoAI) for land use classification and change detection. *Environmental Earth Sciences*, 83(5), 456. <https://doi.org/10.1007/s12665-024-11569-5>
- Smith, T. R. (1984). Artificial intelligence and its applicability to geographical problem solving. *The Professional Geographer*, 36(2), 147–158. <https://doi.org/10.1111/j.0033-0124.1984.00147.x>
- Solecki, W., Leichenko, R., y O'Brien, K. (2017). Climate change adaptation strategies and disaster risk reduction in cities: Connections, contentions, and synergies. *Current Opinion in Environmental Sustainability*, 27, 89–95. <https://doi.org/10.1016/j.cosust.2017.08.006>
- Tavares, W. dos S., Cunha, M. C., y Veras, J. G. S. (2021). A GIS-based model for assessing water stress in urban areas: The case of Brasília, Brazil. *Sustainability*, 13(11), 6170. <https://doi.org/10.3390/su13116170>
- Taylor, L. (2017). What is data justice? The case for connecting digital rights and freedoms globally. *Big Data & Society*, 4(2), 1–14. <https://doi.org/10.1177/2053951717736335>
- The Alan Turing Institute. (s.f.). Artificial intelligence – Research programmes. Recuperado el 30 de julio de 2025, de <https://www.turing.ac.uk/research/research-programmes/artificial-intelligence>
- Vallejo Molina, L., Blandon Montes, A., Lopez, S., Molina Escobar, J., Ortiz, A., Soto, D., Torero, J., Toro, A., y Molina, A. (2024). AI-based alert system for explosions in underground mines. *International Journal of Mining Science and Technology*, 34(1), 120–131. <https://doi.org/10.1016/j.ijmst.2023.09.012>

01

Línea temática

Planeación
urbana
Geomática e IA
aplicada a los
análisis urbanos

Capítulo I. Geoplaneación urbana. Métodos y modelos computacionales desde lo urbano

Ricardo Gómez Maturano¹

Este capítulo contó con el apoyo de los proyectos de investigación PRORED “Sistema Autónomo de Monitoreo del Tránsito Urbano para la Investigación Aplicada en Movilidad de Ciudades Intermedias” (Proyecto No. 20254782) y SIP “Monocentrismo o policentrismo en la Zona Metropolitana del Valle de México” (SIP 20250563) del Instituto Politécnico Nacional

Marielena Medina Ruiz²

Ma. De los Ángeles Martínez Ortega³

*Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),
Unidad Tecamachalco. Naucalpan, Estado de México.*

Resumen

En la nueva era digital, con la ruptura de las nuevas tecnologías de la información y comunicación [TIC], el Big Data [BD], el Internet de las Cosas [IoT] y la Inteligencia Artificial [IA], es fundamental proponer nuevas perspectivas para aprovechar estas innovaciones que hacen frente a los crecientes procesos de urbanización y los desafíos ambientales globales, utilizando enfoques avanzados y tecnologías innovadoras para planificar y desarrollar las ciudades de manera sostenible; por lo cual, este capítulo muestra una revisión sistemática de herramientas, métodos y estudios de la denominada Geoplaneación urbana. Esta nueva herramienta se puede definir como un enfoque sistemático que utiliza tecnologías geoespaciales: las TIC, la IA, el BD y el IoT para diseñar, evaluar y gestionar el desarrollo territorial. Su enfoque articula datos espaciales y análisis socioambiental para apoyar la planificación y la gestión territorial.

Palabras clave: geoplaneación urbana, tecnologías espaciales, desarrollo territorial.

Abstract

In the new digital age, with the emergence of new information and communication technologies (ICT), Big Data (BD), the Internet of Things (IoT), and Artificial Intelligence (AI), it is essential to propose new perspectives to take advantage of these innovations that address growing urbanization processes

1 Profesor e investigador en el Instituto Politécnico Nacional, ESIA, Unidad Tecamachalco, SEPI. Doctor en Urbanismo, UNAM. Maestro en Ciencias en la Especialidad de Arquitectura e Ingeniero Arquitecto, IPN. Correo: rgomezma@ipn.mx, ORCID: <https://orcid.org/0000-0002-8027-8648>

2 Maestra y Doctorante en Ciencias en Arquitectura y Urbanismo, Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura, ESIA, Unidad Tecamachalco. Correo: urbmarymed26@gmail.com, ORCID: <https://orcid.org/0000-0001-9366-1956>

3 Doctora en Educación, Universidad CUGS. Maestra en Ciencias en Administración y Desarrollo de la Educación, Instituto Politécnico Nacional, ESCA Sto. Tomás. Correo: mmartinezo@ipn.mx, ORCID: <https://orcid.org/0000-0002-8483-9844>

and global environmental challenges, using advanced approaches and innovative technologies to plan and develop cities in a sustainable manner. This chapter provides a systematic review of tools, methods, and studies in the field of urban geoplanning. This new tool can be defined as a systematic approach that uses geospatial technologies: ICT, AI, BD, and IoT to design, evaluate, and manage territorial development. Its approach integrates spatial data and socio-environmental analysis to support territorial planning and management.

Keywords: urban geoplanning, spatial technologies, territorial development.

Introducción

En los últimos años, la comprensión de las ciudades se ha retroalimentado con la implementación y exploración de herramientas tecnológicas nuevas, que optimizan la interpretación y predicción de procesos urbanos complejos dentro de sus entornos geográficos. En este contexto surge la Geoplaneación territorial, también denominada en el mundo anglosajón por Topchiyev, et al. (2010), como geoplanificación. Se trata de un enfoque metodológico aplicado a la geografía y planificación urbana, centrado en la integración de otras disciplinas, tales como la geografía física, la humana, la economía y la ecología, para planificar el uso que debe tener un espacio geográfico de manera que sea eficiente y sostenible (Lisetskii, et al., 2014). De hecho, la geoplanificación conforma un marco de estrategias y de acciones que son operativas y que conducen a la gestión del suelo mediante la planificación de los recursos e infraestructuras a modo integral (Topchiyev, et al., 2010), tanto en las zonas urbanas como rurales.

Una de sus principales características es el denominado holismo geográfico (Topchiyiv, et al., 2022). Así, la realidad puede ser observada desde la capa de la superficie terrestre hasta la geósfera. Esta transformación está contextualizada, a nivel global, con la última revolución científica (Andrade, et al., 2009), empujando a la comunidad científica —como le denominan Topchiyiv, et al. (2022)—, hacia una “revolución de la información” desde los fundamentos tecnológicos. Así mismo, la investigación contemporánea, para Grigoreva y Buryak (2016), ha estado vinculada en la intersección de la ecología del paisaje, la modelización ambiental y la geo informática, donde se necesita de recursos tecnológicos para su estudio y comprensión.

La Geoplaneación territorial, en la era digital, utiliza la tecnología de la información y comunicación [TIC]; también, combina la geo información y la geo tecnología para hacer análisis de datos a nivel geoespacial y poder visualizarlos, para, posteriormente, tomar decisiones de forma estratégica en áreas como el urbanismo, la gestión ambiental e incluso el rediseño y la evaluación de políticas públicas (Geertman y Stillwell, 2000); por lo que al final esto se convierte en un proceso integral y de participación entre diversos actores.

La Geoplaneación territorial es considerada disruptiva y capaz de conducir el devenir de la transformación digital de las sociedades por medio

de la integración de tecnologías avanzadas como lo son, por un lado, el big data [BD], entendida como “una nueva generación de arquitecturas diseñadas para extraer valor de grandes volúmenes de datos desde diferentes fuentes, [donde] se reconocen por tres características: volumen, variedad y velocidad” (León, 2019, p. 55); por otro lado, tenemos el Internet de las Cosas [IoT], que “posibilita la conexión entre sensores remotos vía internet, haciendo que los datos producidos por cada uno sean complementarios; lo cual facilita una respuesta en tiempo casi real” (León, 2019, p. 60); y, por último, se encuentra la inteligencia artificial [AI], que destaca la “capacidad de las máquinas para usar algoritmos, aprender de los datos y utilizar lo aprendido en la toma de decisiones tal y como lo haría un ser humano” (Rouhiainen, 2018, p. 17), y que prácticamente se entiende como una máquina digital que puede realizar tareas que necesitan de la inteligencia de un ser humano (Ricardo, et al., 2021).

Por lo tanto, dichas tecnologías toman un rol bastante activo en la planeación urbana, lo que genera resultados nuevos en términos de su aplicación, además de la capacidad que tienen dichas tecnologías para estudiar de manera holística los desafíos contemporáneos del desarrollo territorial. Así, el carácter disruptivo y su potencial transformador se observa, en principio, a través de la elaboración de modelos computacionales que simulan escenarios de desarrollo y anticipación de problemas, lo que permite una planificación proactiva y adaptativa, reduciendo riesgos y optimizando recursos.

Por otra parte, la Geoplaneación se beneficia de los sistemas de información geográfica [SIG] como tecnología que permite estudiar el espacio a nivel geográfico y cuantitativo. Este es un sistema que tiene un conjunto de herramientas teóricas y metodológicas (Buzai, et al., 2019) que recolectan, almacenan, recuperan a voluntad, y visualizan datos del mundo real a nivel espacial para diferentes propósitos (Burrough, et al., 2015). Dichas herramientas están geográficamente referenciadas; en otras palabras, permiten el manejo de datos según su ubicación (Heywood, et al., 2011). Por otro lado, este concepto refiere al estudio de aquellos problemas que surgen del manejo de la información espacial, y se conceptualiza a partir de tres elementos clave: el primero, el hardware informático; el segundo, los programas y módulos de aplicación de software; y, el tercero, son los usuarios vinculados entre sí (Burrough, et al., 2015). Así, funciona por medio de bases de datos, y de cómo está diseñada la infraestructura de la red de trabajo.

Ahora bien, no solamente tiene su aplicación en cuestiones tecnológicas, desde una modelización y previsión, sino también desde un recurso de apoyo en términos informativos frente a su implementación en la toma de decisiones de gestión (Buryak, et al., 2014). Adicionalmente, el uso de los SIG favorece la creación de modelos computacionales por medio de aspectos como:

- El análisis espacial (Buzai, et al., 2019): la aplicación de diferentes técnicas matemáticas y estadísticas en datos que se distribuyen de manera particular en un espacio geográfico donde, a partir de los SIG, se pueden emplear procedimientos puntuales de acuerdo con el tipo de estudio. Miraglia (2018), agrega que este proceso estudia el espacio, y su modelo del análisis puede describir la configuración de este, que puede ser estático, de evolución e incluso dinámico.
- El modelado de terreno o modelo digital de elevación (Mena, et al., 2011): este es un proceso geomático que permite ver las características específicas de un lugar, por ejemplo, la superficie que abarca, la pendiente, el nivel de curvatura, y la clasificación de un terreno viendo cuencas, uniones de ríos, canales, colinas, barrancas, características geomorfológicas entre otras.
- Análisis de redes (Buzai, et al., 2019), que se usa para estudiar estructuras y dinámicas de conexión entre diversos elementos tales como infraestructura, flujos de población, relaciones económicas, o bienes y servicios, resiliencia y gestión de riesgos, esto al interior de un territorio para facilitar la visualización y análisis de los patrones de relación o afectación entre ellos. Estos se representan por medio de nodos (puntos de interés en un espacio), enlaces (conexiones entre nodos) o redes (conjunto de nodos y enlaces). Lo anterior se puede realizar por medio de los SIG, modelos matemáticos, y con el análisis de datos (Big Data) (Maté, 2014).
- Percepción remota o también conocida como teledetección (Sánchez, 2018), que es una técnica bastante particular utilizada principalmente en estudios ecológicos del paisaje, índices de vegetación, cuestiones ambientales y climáticas, ya que permite adquirir información a nivel de superficie terrestre por medio de la detección y medición de la radiación electromagnética reflejada o emitida por los objetos que están en dicha superficie. Utiliza sensores que están en aviones o drones o a nivel espacial desde satélites (Romero, 2016). Esta información se adquiere por medio de imágenes de percepción que, al procesarlas por medio del SIG, permiten analizar, según Moizo (2004), heterogeneidades u homogeneidades espaciales a nivel digital, ya que cada imagen está compuesta de píxeles, de los cuales se abstrae, calcula o tabula información donde es posible hacer análisis en distintas escalas territoriales.
- Los Análisis multivariados (García y Humacata, 2019), que captan asimetrías a nivel espacial, y derivan de la unión de tres o más variables, de

manera que permiten llegar a definir agrupamientos por una homogeneidad alta en su interior y también definir, según sea el caso, la heterogeneidad con relación a las otras unidades espaciales. Esto significa que, por medio de este proceso es posible obtener áreas socioeconómicas, por ejemplo, homogéneas, y que dejan en evidencia la heterogeneidad interna en un territorio de estudio. Así pues, el uso de estas tecnologías en la geoplaneación tiene un desempeño importante en diferentes escenarios o escalas, tanto urbanas como regionales, ya que suele ser una tecnología dinámica con un potencial significativo con miras hacia el futuro (Scholten y Stillwell, 2013), al proporcionar herramientas y datos que permiten a los planificadores tomar acciones informadas para el desarrollo de territorios eficientes y habitables.

De lo anterior surge la pregunta: ¿cómo el uso de las tecnologías de la información y comunicación, el big data, el internet de las cosas, la inteligencia artificial y las metodologías de los sistemas de información geográfica, generan los procesos de geoplaneación?

En ese sentido, este capítulo presenta, de manera sistemática, una revisión de los estudios a nivel global que han utilizado la geoplaneación, y, por otro lado, ejemplos de métodos y herramientas que se han aplicado en el Instituto Politécnico Nacional.

¿Qué es la geoplaneación urbana?

La planificación a nivel geoespacial, desde los años 90s hasta la actualidad, experimentó una evolución significativa gracias a los avances tecnológicos y desde los modelos o prácticas que conducen la planeación de ciudades (Geertman y Stillwell, 2000). En este proceso, se han destacado aspectos como la mayor disponibilidad de datos geoespaciales para los SIG y la teledetección; por otro lado, la integración de la geo información sobre las características de la tierra tiene una referencia explícita a ubicaciones geográficas (Goodchild, 1992) en la planificación, y eso permite que los datos influyan en las políticas públicas.

También esto es posible desde el desarrollo de infraestructuras de datos espaciales [IDE] (Nebert, 2004) que son una red información que está conectada de forma tal que permite usarla y analizarla de manera integral, ya que incluye catálogos de metadatos, servicios de datos, herramientas y aplicaciones. En efecto, los IDE según Maguire y Longley (2005), se refieren específicamente a plataformas que suministran marcos de políticas y tecnologías que permiten a diferentes organizaciones compartir, acceder y utilizar dichos datos, pues en cada país existen y están diseñadas bases o plataformas interactivas que contienen capas de información, generando accesibilidad e interoperabilidad.

Como concepto, se ha entendido desde la aplicación de técnicas de planeación a partir de un contexto geoespacial (Lisetskii, et al., 2014). En el mundo anglosajón, se le conoce como geoplanificación (Topchiyev, et al., 2010), pues se trata de un enfoque sistemático que lleva al desarrollo y a la gestión de un territorio, utilizando datos espaciales para evaluar posibles alternativas y decisiones sobre el uso de recursos naturales del suelo (Shen, 2012). De hecho, comprende un modelado geográfico en la planificación urbana y regional (Wilson y Fotheringham, 2008).

También, se entiende como el proceso de utilizar las tecnologías geoespaciales para diseñar y evaluar escenarios de desarrollo, lo que conduce a una planificación más efectiva y con mayor capacidad adaptativa (Steinitz, 2012). Adicionalmente, parte de un enfoque que integra los SIG y el análisis espacial en procesos urbanos y regionales, lo que lleva a la comprensión profunda de las dinámicas temporales y espaciales de una ciudad (Batty, 2013). Así que la geoplanificación es un campo interdisciplinario que articula herramientas analíticas de la planificación, gestión y de análisis espacial para el desarrollo territorial (Goodchild y Janelle, 2010); se centra en el uso de tecnologías en la planeación, pero desde un enfoque más tecnificado y basado en datos.

No obstante, en países anglosajones, tiende a una interacción un poco más formalizada de las técnicas de modelación geoespacial en los procesos urbanos de gestión, junto con los SIG, pero a partir de un énfasis marcado en la precisión, sostenibilidad y eficiencia. Por lo tanto, según Steinitz (2012), está orientada más hacia una tecnología avanzada que incluye el uso de geodiseño, concepto originado en los años 2000 y 2010, que evalúa y diseña escenarios de desarrollo, también hacia el uso de los análisis predictivos y el big data (Kitchin, 2021), y que a partir de la década del año 2010 fueron incorporados a la planificación urbano y regional, pues marcaron una nueva etapa en la geoplanificación precisa.

Por otro lado, el concepto de geoplaneación parte de la necesidad de integrar bancos de información geoespacial en los procesos de gestión (Sili, 2022). No obstante, es un enfoque que se ha desarrollado como respuesta a aquellos retos del acelerado proceso de urbanización, la vulnerabilidad frente a desastres naturales, la informalidad urbana y la imperativa necesidad de lograr un desarrollo sostenible e inclusivo, particularmente en América Latina (Su, 1998). Se destaca por tener un carácter holístico al vincular los SIG con los procesos sociales, económicos, urbanos y ambientales de una región determinada (Tomlinson, 1988) en contextos urbanos y rurales (Rodríguez y Glasson, 2004). Estas, en efecto son herramientas que analizan y planifican como tal el uso del suelo, además del desarrollo territorial (Pietsch, 2012), y a su vez apoyan decisiones de planeación regional (Hopkins, 2001) y la gestión de los recursos naturales (Yeh, 1999).

Desde el urbanismo, toma un carácter importante ya que vincula, por un lado, lo ambiental, social, económico y la planificación de infraestructuras urbanas con datos aplicados a cuestiones como la zonificación y el uso de suelo, identificando áreas adecuadas para cada uno; encontrando fallas o desequilibrios, e incluso desarticulaciones en términos de distribución, capacidad de carga y abastecimiento.

Por otro lado, conduce a la evaluación de riesgos desde la identificación de sectores propensos a inundación, terremotos, huracanes, temperaturas extremas, y eso influye en la ubicación de proyectos o políticas de planificación de emergencias a partir de los datos capturados y analizados. Lisetskii, et al. (2014), plantean que la geoplaneación de un territorio, a nivel urbano, es una actividad concreta de formación ambiental en territorios de determinado tamaño, y tiene por objetivo apoyar la variedad espacial de la tierra y la protección del medio ambiente desde la posibilidad de planificar territorios rurales; de hecho, agrega que los componentes clave para ello son la naturaleza, población y economía.

Podemos concluir que la geoplaneación urbana se puede definir como un enfoque sistemático que utiliza tecnologías geoespaciales, como los Sistemas de Información Geográfica (SIG), las tecnologías de la información y comunicación, el big data, el internet de las cosas, y la inteligencia artificial para diseñar, evaluar y gestionar el desarrollo territorial de una región determinada. Este enfoque integra datos espaciales con procesos sociales, económicos, urbanos y ambientales, permitiendo una planificación más efectiva y adaptativa. Esta se centra en el uso de herramientas analíticas y tecnologías para comprender las dinámicas temporales y espaciales de un territorio, facilitando la toma de decisiones informadas en la gestión del uso del suelo, la planificación urbana y la gestión de recursos naturales.

Geoplaneación urbana en Latinoamérica

Para entender la forma en que se aplica este concepto, se han divulgado diferentes estudios que implementan la geoplaneación a partir de procesos urbanos. Por ejemplo, desde lo social y económico, García y Humacata (2019) hacen una clasificación a nivel espacial mediante un análisis exploratorio de datos y un análisis multivariado. Concretamente, se basan en un enfoque de promedios estandarizados, tomando variables urbanas de costo y de beneficio, donde sus resultados a nivel de cartografía muestran el análisis del estado social y habitacional de la población, por medio de una distribución espacial bajo distintos niveles de favorabilidad.

Otro ejemplo: Rasse, et al. (2019) muestran, desde la expansión urbana y lo económico, hasta las políticas habitacionales en la Ciudad de México y Santiago de Chile como casos latinoamericanos (si bien, este estudio desarrolla una metodología para analizar y comparar procesos que derivan de la expansión, transformación social y espacial de dichas ciudades; tomando

datos demográficos, territoriales y socioeconómicos). Por lo tanto, se aplica la geoplaneación a través de la construcción de cartografía, por medio de modelos computacionales que visualizan y analizan la gentrificación con y sin desplazamiento.

En cuestiones ambientales, autores como Humacata y Buzai (2018), hacen un análisis espacial de cambio de cobertura del suelo, utilizando los SIG que llevan a la construcción de modelos estadísticos y modelos de regresión lineal y múltiple (Chowdhur, 2006), ya que permiten estudiar relaciones de variación en un espacio, puntualmente a nivel social y económico o también temas de deforestación de áreas de bosque (Jaimes, et al., 2010). Lückehe, et al. (2014) por su parte, consideran que el acceso a fuentes de energía que sean renovables cobra importancia en diferentes países industrializados, por lo que plantean un enfoque de optimización para la planeación geográfica de centrales eléctricas, que busca encontrar ubicaciones adecuadas para diferentes tipos de centrales, tomando como base limitaciones ambientales desde estrategias evolutivas en Alemania.

Así que el comportamiento y eficacia de este tipo de sistema de energía depende de su localización, y de la aplicación de estrategias de geoplanificación para que mejore su valor. Melentyev (2022) resalta a la geoplaneación del distrito de Prokhorovsky en la región de Bélgorod, que es una de las principales entidades de Rusia en cuestión de producción y ocupación agrícola. Lo aborda desde la optimización en la forma de conservar tanto el agua como el suelo de los paisajes, de forma sistemática y racional, desde la optimización de la conservación de lugares expuestos a la erosión. De hecho, afirma que en la geoplaneación es relevante elegir enfoques y criterios que aislen las divisiones del territorio en el espacio desde unidades operativas, el diseño y el seguimiento a partir de la inserción de cuencas.

En la ciudad de Zaagreb en Croacia; Mihalić, et al. (2012) utilizan diferentes datos existentes para entender condiciones geológicas, sísmicas e hidrogeológicas del área, principalmente por la presencia de la cuenca de Panonia. Aquí se utilizaron mapas geológicos de composición del suelo, actividad sísmica, e inventarios de deslizamiento de tierra, lo que es fundamental para la planificación urbana y la mitigación. Por último, están los mapas de zonificación de riesgos geológicos. Así que, acceder y procesar este tipo de información permite una evaluación integral para tomar acciones de planeación seguras y sostenibles. Ahora, desde lo ambiental y el riesgo, el estudio de Utami, et al. (2022) por medio de un análisis espacial, correlaciona dos variables; una de crecimiento urbano, junto con otra con los cambios que se dan en la temperatura superficial en la ciudad de Palembang, en Indonesia.

Desde una perspectiva de la arquitectura y el urbanismo, Gambo, et al. (2018) aplican, por su parte, la geoplaneación desde un enfoque sistemático que abarca la selección de un área de estudio, la recopilación de datos por

medio de imágenes satelitales de distintos años y la aplicación de análisis de los mismos, para poder evaluar qué cambios se dan en el uso de la tierra durante los años de 1989, 1994 y 2016. Se optó por el uso de técnicas avanzadas de análisis de imágenes y de análisis basado en objetos, píxeles y con máquinas de vectores soporte. La geoplaneación en este estudio se manifiesta a través de la aplicación de tecnologías geoespaciales avanzadas, la evaluación detallada de cambios en el uso de la tierra a lo largo del tiempo, y la propuesta de medidas de conservación y monitoreo para garantizar la protección de las áreas protegidas y la biodiversidad circundante.

Benavente, et al. (2011) muestran un claro ejemplo de la implementación de las TIC por medio de escenarios y modelos a futuro en la planeación dentro de una escala metropolitana en España, ya que este país no tiene como característica común el uso de escenarios a futuro (Schwartz, 1997), modelos de simulación a nivel espacial (Benenson y Torrens, 2004), e instrumentos que apoyen decisiones de planeación (Geertman y Stillwell, 2004).

Por otro lado, Chermack y Van der Merwe (2003), definen la geoplaneación como este conjunto de métodos que se utilizan para aumentar las opciones y la conciencia de diferentes posibles futuros en un proceso de toma de decisiones; estas, en efecto, se incluyen en una planeación donde se diseñan con instrumentos propios de la planificación, con el uso de los SIG. Esto deriva en imágenes de evolución a futuro, que como bien se le denomina en el mundo anglosajón según Stillwell, et al. (1999), lleva el nombre de “spatial scenario planning”. Benavente, et al. (2011) plantean tres tipos de escenarios: uno es el predictivo del futuro en un plazo cercano, otro es la predicción exploratoria; y por último se tiene la predicción normativa, que imagina escenarios que involucren un mejor diseño, para que este se aproxime a lo deseable en cuanto a los criterios urbanos.

Por tanto, a partir de estos estudios se ve cómo la geoplaneación y la geoplanificación parten de un origen y enfoque distintos, de manera ligera, a causa del contexto regional específico; sin embargo, las dos visiones comparten la base común en el uso de las TIC, a nivel geoespacial, para mejorar la planificación y gestión territorial. De hecho, de Vries (2018) agrega que las prácticas que se dan sobre este proceso, involucran la regulación de instrumentos mediante las agencias de planeación a nivel espacial por medio de organismos gubernamentales y no gubernamentales que al final tienen por objetivo intervenir relaciones a nivel socio-espacial, de carácter biofísico, y artefactos y construcciones que se benefician de la tierra en general y del hábitat, lo cual se observa en los anteriores casos expuestos.

No obstante, las intervenciones de planificación urbana tienen funciones, y de hecho relaciones que dependen de los cambios a nivel gubernamental, las relaciones socioespaciales, la economía y el derecho (de Vries, 2021); así que estas funciones son opciones que se pueden observar desde la manera en

que se ejecutan dentro de las funciones de la gestión, planeación territorial y espacial.

Estos ejemplos muestran cómo la geoplaneación se implementa a través de la construcción de modelos, análisis espaciales, y uso de tecnologías geoespaciales avanzadas para análisis de factores ambientales, sociales y económicos en la planificación territorial y urbana.

Aplicaciones metodológicas de la geoplaneación urbana en el Instituto Politécnico Nacional

Como ejemplo de aplicaciones de la geoplaneación para la toma de decisiones de ordenamiento territorial y planificación urbana regional, es fundamental considerar de base principios metodológicos e igualmente científicos, soportados por una base de información que sea real (Buryak, et al., 2014). En el caso de México hay estudios recientes realizados en el Taller de Geomática y Procesos urbanos, en la Sección de Estudios de Posgrado e Investigación de la Escuela Superior de Ingeniería y Arquitectura, Unidad Tecamachalco del Instituto Politécnico Nacional, sobre la geoplaneación territorial aplicando geotecnologías y geodiseño en la identificación de procesos urbanos que surgen como consecuencia de las decisiones territoriales, a partir de cuestiones de infraestructura, segregación residencial, movilidad urbana, transporte, morfología urbana y variables ambientales.

Estos análisis generaron modelos computacionales partiendo de una metodología de geografía cuantitativa, que se basa en la generalización donde se hacen diagnósticos que buscan explicar de forma deductiva una dimensión espacial. Este método se caracteriza por recopilar datos estadísticos donde se hacen análisis espaciales usando los SIG, las tecnologías de la información y comunicación, el big data, el internet de las cosas, y la inteligencia artificial para crear modelos. Se exponen los procesos en resultados cartográfico.


En primer lugar, se encuentra un estudio de áreas de influencia en los accidentes de motocicleta que se dan en la Ciudad de México [CDMX], puntualmente en el año 2022. Se realizó por medio de geo procesos que identifican las zonas con mayor nivel de exposición a accidentes, cercanos a avenidas principales con límite de velocidad sobre los 50 km/h. Así, se pueden identificar las vialidades que presentan una menor seguridad vial para las personas que se transportan en motocicleta (Figura 1).

Dentro del contexto de la movilidad, se hace también un estudio del ferrocarril suburbano en la Zona Metropolitana del Valle de México [ZMVM] en el año 2017. Para ello, se tomaron datos de encuestas origen y destino [EOD] de dicho año, para así comparar tanto la cantidad como el tiempo que tienen los viajes hechos, particularmente en el área de influencia del tren suburbano. Esto por medio de un análisis de proximidad, trazando un perímetro de ocho kilómetros por medio de buffers en cada estación de la línea de dicho tren.

Luego, en cada EOD se enmarcaron los viajes realizados con propósito distinto de regresar al hogar. Se encontró al final que, de los distritos que rodeaban las nuevas estaciones del tren suburbano, solamente algunos han aumentado su movilidad urbana desde que se inauguró este sistema de transporte. Este tipo de análisis se puede aplicar para evaluar políticas públicas de movilidad urbana (Figura 2).

Por otro lado, existe un estudio del análisis de aquellos patrones que tiene la movilidad cotidiana en la ZMVM desde un enfoque de la justicia espacial. Aquí se ve la geoplaneación desde la construcción de un modelo computacional, que correlaciona el análisis de la movilidad cotidiana por medio de indicadores como número de viajes, y analizarlo por cada estrato socioeconómico. El estudio concluyó que la mayor cantidad de viajes interdistritales hechos por el estrato bajo se dan en la periferia. De hecho, se observa que un porcentaje importante del estrato bajo elige viajar mayoritariamente dentro del mismo distrito donde vive. Este modelo muestra indicios de segregación espacial, por dos características: la primera es que los pobres solo se mueven en la periferia; y segundo, que su movilidad está condicionada al entorno inmediato al que viven; es decir, que no pueden ejercer su derecho a la ciudad como se expone en la Figura 3. El siguiente estudio analiza la segregación urbana en la Zona Metropolitana de Acapulco, utilizando el análisis de agrupamiento. Los resultados indican que la población con menor nivel de estudios está segregada de las partes más turísticas de Acapulco, es decir, el anfiteatro frente a la Bahía de Santa Lucía, donde genera un agrupamiento bajo-bajo, es decir que no hay población de este grupo en este espacio. Por otro lado, las personas sin estudios sí generan cinco clústeres alto-alto en la periferia de la ZMA, evidenciando segregación residencial a una macro escala urbana (Figura 4).

Para el caso del Área Metropolitana de Mérida, Yucatán, México, se hizo un análisis exploratorio para identificar la dispersión urbana desde un punto de vista de la morfología urbana. Para esto se recurrió a la percepción remota con imágenes satelitales en formato vectorial del servicio geológico de los Estados Unidos [USGS]. Luego, por medio de SIG, se obtuvieron imágenes bidimensionales de puntos y píxeles, lo que facilitó el análisis de un marco geoestadístico. Al final, se visualizan los diferentes usos de suelo, en este caso se buscaba identificar la dispersión urbana del suelo urbano, uno de los procesos que más está afectando a la sustentabilidad urbana por el crecimiento disperso de las ciudades (Figura 5).






Figura 2. Costos de viaje individuales en la movilidad cotidiana dentro del área de influencia del tren suburbano 2017. Fuente: reproducido de la tesis de maestría inédita de Vázquez (2021).




Figura 3. Viajes realizados por distrito, y viajes internos del estrato bajo. Fuente: reproducido de la tesis de doctorado inédita de Ruiz (2024).




Figura 4. Segregación urbana en la Zona Metropolitana de Acapulco. Fuente: reproducido de la tesis de doctorado inédita de Carvajal (2023).




Figura 5. Morfología de la dispersión urbana en el Área Metropolitana de Yucatán, México.
Fuente: reproducido de la tesis de maestría inédita de Montalvo (2024).

Discusión y conclusiones

La geoplaneación urbana destaca en las oportunidades que puede ofrecer para los desafíos que enfrentan hoy las ciudades contemporáneas, que requieren importantes elementos de planificación y ordenamiento territorial. Para ello, existen conceptos clave que, al integrarlos con las tecnologías avanzadas, pueden contribuir a la construcción de territorios sostenibles, resilientes, como lo exponen Lisetskii, et al. (2014), Topchiyev, et al. (2010) y Steinitz (2012), pues impulsan la transformación digital, al vincular la tecnología geoespacial en procesos de gobernanza un poco más inclusiva y transparente en la planeación urbana.

El uso de las TIC y los SIG, por medio de estos casos de estudio mexicanos, facilitaron la identificación de fenómenos y procesos urbanos tan diversos y comunes que existen en Latinoamérica. El papel de la geoplaneación en dichos procesos, suministra las herramientas y metodologías necesarias para mejorar el ordenamiento del territorio y la construcción de modelos computacionales que aportan, de hecho, datos precisos y análisis que informan estas decisiones de ordenamiento.

Estos modelos llevan a identificar patrones que requieren de la implementación de normas de ordenamiento, estrategias de planeación urbano regional y, ¿por qué no?, el uso del geodiseño para mejorar la toma de decisiones futuras frente a posibles impactos a corto, mediano y largo plazo, por ejemplo: la morfología de la dispersión urbana en el área metropolitana de Yucatán, la segregación urbana en la Zona Metropolitana de Acapulco, la movilidad urbana en la Zona Metropolitana del Valle de México; la movilidad cotidiana dentro del área de influencia del tren suburbano; y la seguridad vial en la movilidad de los motociclistas en la CDMX, lo que permite entender el nivel de exposición de accidentes en avenidas principales. Así se puede inferir que existe una relación entre la planificación urbana y la geoplaneación territorial, que suele ser un poco más de sinergia y colaboración.

La geoplaneación urbana puede enfrentar los desafíos del desarrollo sostenible, más aun en un mundo que está siendo afectado por el cambio climático y que ha superado los límites de la urbanización, la capacidad de carga del mundo y sus recursos. Por lo tanto, se requiere de planificación urbana efectiva que pueda brindar la integración de herramientas geoespaciales y modelos computacionales de simulación. No obstante, es imperativo aumentar el nivel de beneficios en términos de la superación de desafíos, lo que implica el acceso a los datos, la coordinación interinstitucional y la capacidad técnica desde la formación académica. Por ello, se considera, a partir de los resultados de los casos de estudio (que son investigaciones del posgrado en el Instituto Politécnico Nacional), que se puede innovar en el conocimiento de las ciudades para la planeación urbana. Así que es imperativo incluir las tecnologías geoespaciales en los programas educativos, para enseñar a los estudiantes

cuestiones de planeación y los nuevos avances tecnológicos. De hecho, los programas educativos basados en los SIG, las tecnologías de la información y comunicación, el big data, el internet de las cosas, y la inteligencia artificial, serán herramientas clave para la investigación, suscitando comprensiones más profundas respecto a la geoplaneación.

La transformación digital a través de la geoplaneación territorial ha cobrado relevancia en los Programas Nacionales Estratégicos (PRONACES) en México. Un ejemplo de ellos es a partir de la sostenibilidad ambiental, al integrar datos geoespaciales para la gestión de recursos y conservación medioambiental; de hecho, el uso de las TIC crea plataformas de monitoreo en tiempo real, y el modelamiento de escenarios a futuro. Desde el desarrollo rural y urbano, se hace una planificación del suelo en estos dos contextos, y se implementan soluciones digitales, como lo es por medio del geodiseño para la gestión de infraestructura.

En materia de salud, se pueden identificar áreas de necesidad crítica para planificar la infraestructura sanitaria. Desde la inclusión social y el reducir las desigualdades, es posible analizar la distribución de los recursos, para identificar los niveles de desigualdad en materia de agua, procesos contaminantes, energía y cambio climático, educación, salud, seguridad y vivienda. Así, es posible por medio de la actual transformación digital, con el carácter disruptivo de la geoplaneación, fortalecer los PRONACES en México a través de herramientas de tecnologías avanzadas para recolectar, analizar y visualizar datos a nivel geoespacial. De hecho, se trata de una sinergia que conduce a la planificación y gestión de manera más sostenible, equitativa y eficiente, lo que se puede llevar de la mano con los objetivos que se tienen a nivel global y nacional.

Por lo tanto, México como país al integrar las tecnologías digitales en el proceso de geoplaneación, puede avanzar hacia un desarrollo resiliente e inclusivo. De hecho, este proceso ofrece varios espacios de oportunidad, que abarcan múltiples sectores potenciados con las TIC, la IA, el big data [BD], además del Internet de las Cosas [IoT]. Uno de ellos es el crecimiento urbano sostenible para hacer frente a la expansión urbana descontrolada; así que estas herramientas favorecen la creación de modelos predictivos que proyecten densificaciones inteligentes, por una parte, y por otro lado la conservación de ecosistemas (cambio de cobertura vegetal), gestión del agua (detección temprana de sequías), agricultura y seguridad alimentaria (producción y rendimiento).

El estatus de la geoplaneación en México suele ser un campo que se encuentra en evolución, pero con avances reveladores en sectores y áreas que continúan necesitando más desarrollo. Por ejemplo, a nivel político y dentro del marco regulatorio, las instituciones, como es el caso de la Secretaría de Desarrollo Agrario, Territorial y Urbano (SEDATU), junto con el Instituto Nacional de Estadística y Geografía (INEGI), son fundamentales para la gestión

y recolección de datos a nivel geoespacial, para la planeación. De hecho, el gobierno de México, además, incorporó la geoplaneación en el Plan Nacional de Desarrollo como parte de las políticas que buscan la sostenibilidad y un ordenamiento alineado a los objetivos de desarrollo sostenible.

Así que, México como un gran ejemplo latinoamericano, avanza en la inserción de políticas que incluyen la geoplaneación, pero aún sigue consolidando estrategias de coordinación, capacitación e implementación. Por lo que es fundamental seguir capacitando profesionales en materia de uso de herramientas geoespaciales y tecnologías digitales para transformar nuestros territorios.

Referencias

- Andrade Pérez, L., Campos Romero, D., Domínguez Calle, E. A., Gómez Cruz, N. A., y Osorio García, S. N. (2009). *Complejidad: revolución científica y teoría*.
- Batty, M. (2013). Big data, smart cities and city planning. *Dialogues in human geography*, 3(3), 274-279. <https://doi.org/10.1177/20438206135133>
- Benavente, F. A., Montes, L. M. V., Lara, J. A. S., Delgado, M. G., y Rocha, W. P. (2011). Escenarios y modelos de simulación como instrumento en la planificación territorial y metropolitana. *Serie Geográfica*, 17, 11-28.
- Benenson, I., y Torrens, P. (2004). *Geosimulation: Automata-based modeling of urban phenomena*. John Wiley & Sons.
- Burrough, P. A., McDonnell, R. A., y Lloyd, C. D. (2015). *Principles of geographical information systems*. Oxford University Press, USA.
- Buryak, Z. A., Grigoreva, O. I., y Pavlyuk, Y. V. (2014). GIS maintenance of rural territories geoplanning under basin principles. *International Journal of Advanced Studies*, 4(2), 56-60.
- Buzai, G. D., Humacata, L., Lanzelotti, S. L., Montes Galbán, E., y Principi, N. (2019). Teoría y métodos de la Geografía Cuantitativa Libro 2: Por una Geografía empírica.
- Carvajal Herrera, M. (2023). *Segregación urbana en la Zona Metropolitana de Acapulco* (Tesis de doctorado inédita). Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura ESIA Tecamachalco.
- Chermack, T. J., y van der Merwe, L. (2003). El papel del aprendizaje constructivista en la planificación de escenarios. *Futures*, 35 (5), 445-460.
- Chowdhury, R. R. (2006). Landscape change in the Calakmul Biosphere Reserve, Mexico: Modeling the driving forces of smallholder deforestation in land parcels. *Applied geography*, 26(2), 129-152.
- de Vries, W. T. (2018). Opportunities and limits of making regions both lucrative and attractive. In Opportunities and Constraints of Land Management in Local and Regional Development. Integrated Knowledge. Factors and Trade-offs., edited by E. Hepperle, J. Paulsson, V. Maliene, R. Mansberger, A. Lisec and S. Guelton: vdf Hochschulverlag AG and der ETH Zürich, 13-23.

- de Vries, W. T. (2021). Trends in The Adoption of New Geospatial Technologies for Spatial Planning and Land Management in 2021. *Geopanning: Journal of Geomatics and Planning*, 8(2), 85-98. <https://doi.org/10.14710/geopanning.8.2.85-98>
- Delgadillo Díaz, R. A. (2024). *Modelo computacional de la seguridad vial en la movilidad de motocicletas en la Ciudad de México* (Tesis de maestría inédita). Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura ESIA Tecamachalco.
- Gambo, J., Shafri, H. M., Shaharum, N. S. N., Abidin, F. A. Z., y Rahman, M. T. A. (2018). Monitoring and predicting land use-land cover (LULC) changes within and around krau wildlife reserve (KWR) protected area in Malaysia using multi-temporal landsat data. *Geopanning: journal of geomatics and planning*, 5(1), 17-34.
- García de León, A., y Humacata, L. (2019). Clasificación espacial exploratoria y multivariada con Sistemas de Información Geográfica. G. Buzai, et al., 39-58.
- Geertman, S., y Stillwell, J. (2000). Geoinformation, Geotechnology, and Geopanning in the 1990s.
- Geertman, S., y Stillwell, J. (2004). Planning support systems: an inventory of current practice. *Computers, environment and urban systems*, 28(4), 291-310.
- Goodchild, M. F. (1992). Geographical information science. *International journal of geographical information systems*, 6(1), 31-45.
- Goodchild, M. F., y Janelle, D. G. (2010). Hacia un pensamiento espacial crítico en las ciencias sociales y las humanidades. *GeoDiario*, 75, 3-13. <https://link.springer.com/article/10.1007/s10708-010-9340-3>
- Grigoreva, O. I., y Buryak, Z. A. (2016). Application of basin approach for soil and water protection geopanning of territory and environmental management.
- Heywood, D. I., Cornelius, S. C., y Carver, S. J. (2011). *Introducción a los sistemas de información geográfica*. (Cuarta ed.) Pearson Prentice Hall. http://wps.pearsoned.co.uk/ema_uk_he_heywood_intro_GIS_4/
- Hopkins, L. D. (2001). Urban development: The logic of making plans. (No Title). <https://cir.nii.ac.jp/crid/1130282269858279680>
- Humacata, L. M., y Buzai, G. D. (2018). Análisis espacial de los cambios de usos del suelo con Sistemas de Información Geográfica.
- Jaimes, N. B. P., Sendra, J. B., Delgado, M. G., y Plata, R. F. (2010). Exploring the driving forces behind deforestation in the state of Mexico (Mexico) using geographically weighted regression. *Applied Geography*, 30(4), 576-591.
- Kitchin, R. (2021). The Data Revolution: A critical analysis of big data, open data and data infrastructures.
- León Pérez, J. (2019). Impacto de las tecnologías disruptivas en la percepción remota: big data, internet de las cosas e inteligencia artificial. *UD y la geomática*, (14). <https://doi.org/10.14483/23448407.15658>

- Lisetskii, F. N., Zemlyakova, A. V., Terekhin, E. A., Naroznyaya, A. G., Pavlyuk, Y. V., Ukrainskii, P. A., ... y Samofalova, O. M. (2014). New opportunities of geo-planning in the rural area with the implementing of geoinformational technologies and remote sensing. *Advances in Environmental Biology*, 8(10), 536-539.
- Lückehe, D., Kramer, O., y Weisensee, M. (2014). An Evolutionary Approach to Geo-Planning of Renewable Energies. In *EnvirolInfo* (pp. 501-508).
- Maguire, D. J., y Longley, P. A. (2005). The emergence of geoportals and their role in spatial data infrastructures. *Computers, environment and urban systems*, 29(1), 3-14.
- Maté Jiménez, C. (2014). Big data. Un nuevo paradigma de análisis de datos. Disponible en: <https://repositorio.comillas.edu/xmlui/handle/11531/4873>
- Melentyev, A. A. (junio de 2022). Proyecto de gestión natural de la cuenca del río Vorskla dentro de los límites del distrito de Prokhorovsky. En Serie de conferencias del IOP: Ciencias de la Tierra y el Medio Ambiente (Vol. 1045, No. 1, p. 012168). Publicación PIO.
- Mena Frau, C., Molina Pino, L., Ormazábal Rojas, Y., y Morales Hernández, Y. (2011). Generalización de modelo digital de elevación condicionada por puntos críticos de terreno. *Boletim de Ciencias Geodesicas*, 17, 439-457.
- Mihalić Arbanas, S., Krkač, M., Bernat, S., y Arbanas, Ž. (2012). Use of existing data in the City of Zagreb (Croatia, Europe) for the purpose of geo-planning. In 13th International Conference of Associated Research Centers for the Urban Underground Space ACUUS 2012 (pp. 465-477).
- Miraglia, M. (2018). Cartografía histórica y sistemas de información geográfica: análisis de transformaciones territoriales. Buzai, Gustavo et al., 147-162.
- Moizo, P. (2004). La percepción remota y la tecnología SIG: una aplicación en Ecología de Paisaje. *GeoFocus. International Review of Geographical Information Science and Technology*, (4), 1-24.
- Montalvo Olguín, B. Y. (2024). *Morfología de la dispersión urbana en el Área Metropolitana de Yucatán, México* (Tesis de maestría inédita). Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura ESIA Tecamachalco.
- Nebert, D. D. (2004). Developing Spatial Data Infrastructures: the SDI cookbook. Global Spatial Data Infrastructure (GSDI) Association.
- Pietsch, M. (2012). GIS in landscape planning. *Landscape Planning*, M. Ozyavuz (Ed.), InTech, Rijeka, Croatia, 55-84.
- Rasse, A., Sabatini, F., Sarella Robles, M., Gómez Maturano, R., Cáceres Quiero, G., y Trebilcock, M. P. (2019). Metodologías de identificación de zonas en gentrificación. Santiago de Chile y Ciudad de México. *Bitácora Urbano Territorial*, 29(1), 53-63.

- Ricardo, J. E., Vázquez, M. Y. L., Palacios, A. J. P., y Ojeda, Y. E. A. (2021). Inteligencia artificial y propiedad intelectual. *Universidad y sociedad*, 13(S3), 362-368.
- Rodriguez Bachiller, A., y Glasson, J. (2004). Expert systems and geographic information systems for impact assessment. CRC Press.
- Romero, F. S. (2016). La Teledetección satelital y los sistemas de protección ambiental. *Revista AquaTIC*, (24).
- Rouhiainen, L. (2018). *Inteligencia artificial*. Madrid: Alienta Editorial, 20-21.
- Ruiz Camacho, M. (2024). *Viajes realizados por distrito y viajes internos del estrato bajo* (Tesis de doctorado inédita). Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura ESIA Tecamachalco.
- Sánchez Díaz, B. (2018). La teledetección en investigaciones ecológicas como apoyo a la conservación de la biodiversidad: una revisión. *Revista científica*, (33), 243-253.
- Scholten, H. J., y Stillwell, J. (Eds.). (2013). Geographical information systems for urban and regional planning (Vol. 17). Springer Science & Business Media.
- Schwartz, P. (1997). Art of the long view: planning for the future in an uncertain world. John Wiley & Sons.
- Shen, Z. (2012). Geospatial techniques in urban planning. Springer Science & Business Media. Heidelberg Dordrecht Londond New York. DOI <https://doi.org/10.1007/978-3-642-13559-0>
- Sili, M. (2022). Planificación y gestión territorial en América Latina: entre la persistencia de las problemáticas territoriales y los nuevos desafíos de futuro. *Ikkara. Revista De Geografías Iberoamericanas*, (1). <https://doi.org/10.18239/Ikkara.3037>
- Steinitz, C. (2012). A framework for geodesign: Changing geography by design. <https://library.wur.nl/WebQuery/titel/2147477>
- Stillwell, J., Geertman, S., Openshaw, S. (1999). Developments in Geographical Information and Planning. In: Stillwell, J., Geertman, S., Openshaw, S. (eds) Geographical Information and Planning. Advances in Spatial Science. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-662-03954-0_1
- Su, D. Z. (1998). GIS-based urban modelling: practices, problems, and prospects. *International Journal of Geographical Information Science*, 12(7), 651-671.
- Tomlinson, R. F. (1988). The impact of the transition from analogue to digital cartographic representation. *The American Cartographer*, 15(3), 249-262.
- Topchiyev, O., Olijnyk, V., y Melnychenko, T. (2010). The concept of territory geo-planning in Ukrainian geography. Selected aspects of transformation in countries of Central and Central-Eastern Europe. University of Gdansk Peplin, 52-62.
- Topchiyiv, O. G., Yavorska, V. V., y Kolomiyets, K. V. (2022). The concept of geographical holism as a combined consideration of nature and society.

- Utami, N. T., y Pigawati, B. (2022). The Correlation Between Urban Development and Land Surface Temperature Change in Palembang City. *Geoplanning: Journal of Geomatics and Planning*, 9(2), 89-102. <https://doi.org/10.14710/geoplanning.9.2.89-102>
- Vázquez Nájera, L. (2021). *Costos de viaje individuales en la movilidad cotidiana dentro del área de influencia del tren suburbano* (Tesis de maestría inédita). Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura ESIA Tecamachalco.
- Wilson, J. P., y Fotheringham, A. S. (Eds.). (2008). *The handbook of geographic information science*. Malden, MA, USA: Blackwell Pub.
- Yeh, A. G. (1999). Urban planning and GIS. *Geographical information systems*, 2(877-888), 1.

Capítulo II. Monocentrismo o policentrismo en la Ciudad de México. Análisis espacial con IA y SIG's

Ricardo Gómez Maturano¹

Este capítulo contó con el apoyo del proyecto de investigación "Monocentrismo o policentrismo en la Zona Metropolitana del Valle de México" (SIP 20250563) del

Instituto Politécnico Nacional.

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),

Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

Este capítulo analiza la evolución de la estructura urbana de la Ciudad de México entre 2010 y 2020, con el objetivo de identificar patrones de monocentrismo y policentrismo funcional. Se parte de un enfoque teórico que considera la centralidad urbana como un fenómeno dinámico, influido por factores territoriales, económicos y sociales. La investigación emplea una metodología cuantitativa de análisis espacial, que integra el cálculo de la densidad de empleo por AGEB, la estimación del Índice de Atracción y un modelo de regresión lineal automatizado. A través del uso de sistemas de información geográfica y programación en Python, se logra una caracterización precisa de los subcentros funcionales. Los resultados evidencian una tendencia hacia la diversificación de nodos de empleo, con mayor presencia de subcentros en las zonas norte y oriente de la ciudad. Estos hallazgos permiten cuestionar la persistencia de una centralidad única, indicando una reconfiguración incipiente del sistema urbano metropolitano.

Palabras clave: estructura urbana, policentrismo funcional, densidad de empleo.

Abstract

This chapter analyzes the evolution of the urban structure of Mexico City between 2010 and 2020, with the objective of identifying patterns of monocentrism and functional polycentrism. It is based on a theoretical approach that views urban centrality as a dynamic phenomenon influenced by territorial, economic, and social factors. The research applies a quantitative spatial analysis methodology that includes the calculation of employment density by AGEB, the estimation of an Attraction Index, and an automated linear regression model. With geographic information systems and Python programming, a precise characterization of functional subcenters is achieved. The results reveal a trend toward the diversification of employment nodes, with increased presence of subcenters in the northern and eastern zones of the city. These

1 Profesor e investigador en el Instituto Politécnico Nacional, ESIA, Unidad Tecamachalco, SEPI. Doctor en Urbanismo, UNAM. Maestro en Ciencias en la Especialidad de Arquitectura e Ingeniero Arquitecto, IPN. Correo: rgomezma@ipn.mx, ORCID: <https://orcid.org/0000-0002-8027-8648>

findings challenge the persistence of a single centrality, indicating an incipient reconfiguration of the metropolitan urban system.

Keywords: urban structure, functional polycentrism, employment density.

Introducción

A lo largo de la historia del pensamiento urbanístico, el análisis de la estructura espacial de las ciudades ha ocupado un lugar central en la teoría urbana. Este interés no se ha limitado a su dimensión morfológica, sino que ha abordado también las distintas dinámicas políticas, económicas y sociales que configuran el territorio. Desde las formulaciones del urbanismo clásico hasta los enfoques críticos contemporáneos, el debate en torno al monocentrismo y el policentrismo ha operado como un eje de interpretación fundamental para comprender la organización y evolución de las metrópolis. Independientemente de la época o el contexto, los estudios urbanos convergen en una pregunta estructural: ¿son las ciudades monocéntricas o policéntricas?

Esta interrogante ha sido abordada desde diferentes tradiciones teóricas, en las que destacan la teoría del lugar central, de Christaller (1933) y Lösch (1954); la teoría de localización de Isard (1956); la teoría general de sistemas de Von Bertalanffy (1986); así como la regla de rango-tamaño de Zipf (1949). Estas corrientes, aunque formuladas en contextos históricos específicos, han permeado gran parte del pensamiento urbanístico moderno, y siguen ofreciendo marcos analíticos vigentes.

En el caso particular de América Latina, y México en especial, este debate se ha complejizado por la persistencia de desigualdades estructurales, altos niveles de informalidad urbana, sistemas de gobernanza fragmentados y procesos territoriales marcados tanto por la concentración funcional como por una expansión desarticulada. En este escenario, la Ciudad de México (CDMX), como aglomeración urbana más densa e influyente del país, constituye un laboratorio privilegiado para explorar las tensiones entre una centralidad histórica consolidada y la emergencia de nuevas centralidades urbanas.

El análisis de la centralidad urbana no solo reproduce la dicotomía centro-periferia, sino que dialoga también con antiguos dualismos, como el urbano-rural. Durante mucho tiempo, esta división impidió reconocer territorios intermedios cuya lógica de funcionamiento escapa a las categorías tradicionales. Es en este vacío teórico donde emergen las áreas periurbanas, espacios híbridos que desdibujan las fronteras morfológicas y funcionales del sistema urbano, y que hoy resultan fundamentales para comprender las formas contemporáneas del crecimiento metropolitano.

De esta manera, el estudio de la CDMX bajo la perspectiva del monocentrismo y el policentrismo no se limita a una descripción espacial, sino que exige una mirada relacional y crítica sobre las dinámicas que moldean el territorio metropolitano. Las herramientas teóricas y metodológicas empleadas para este análisis deben, por tanto, ser capaces de capturar

tanto las permanencias como las transformaciones en la configuración urbana, reconociendo las particularidades del contexto latinoamericano y sus contradicciones estructurales.

Por lo tanto, este capítulo tiene como objetivo determinar si la Ciudad de México tiene una configuración predominante monocéntrica o si ha transitado hacia un modelo de organización policéntrica entre los años 2010 y 2020. Para ello, se parte de una metodología cuantitativa de análisis espacial aplicada a la evolución de la centralidad urbana en la Ciudad de México entre 2010 y 2020. El procedimiento se estructuró en cinco fases: (1) estandarización de datos del DENU, transformando los rangos cualitativos en valores numéricos para estimar la densidad de empleo; (2) georreferenciación de unidades económicas por AGEB urbana y cálculo de densidad espacial de empleo; (3) construcción del Índice de Atracción (IA), interpolado mediante ráster de 1 ha para captar micro variaciones territoriales; (4) implementación de un modelo de regresión lineal en Python, correlacionando la distancia al centro urbano con el logaritmo de la densidad de empleos; y (5) superposición y reclasificación de los resultados del índice de atracción (IA) y los residuos del modelo para identificar subcentros funcionales.

La metodología se distingue por integrar técnicas de geomática, estadística espacial y programación automatizada, lo que permite un análisis replicable, preciso y libre de umbrales administrativos arbitrarios. Este enfoque resulta especialmente pertinente para contextos urbanos latinoamericanos, donde la complejidad morfológica y la fragmentación funcional demandan estrategias analíticas multiescales y adaptativas. Los resultados de ambos años se mapean para hacer una comparación y determinar las tendencias.

El debate del análisis de la centralidad urbana encuentra su raíz en la teoría del lugar central desarrollada por Walter Christaller (1933) y ampliada por August Lösch (1954), quienes explicaron la jerarquización espacial de los asentamientos humanos en función de la provisión de bienes y servicios. Esta visión jerárquica fue uno de los pilares de la planificación territorial en Europa durante el siglo XX. En paralelo, Isard (1956) con su teoría de la localización, y Von Bertalanffy (1986) desde la teoría general de sistemas, introdujeron un entendimiento más complejo de la ciudad como nodo dentro de redes económicas y territoriales más amplias. Estos enfoques abrieron el camino para una lectura sistémica de la ciudad, superando su análisis como unidad aislada.

Durante la segunda mitad del siglo XX, los modelos neoclásicos de localización urbana contribuyeron a las aportaciones destacadas de Alonso (1964), Muth (1969) y Mills (1972), establecieron el paradigma monocéntrico. Estos modelos asumen un único centro urbano, el *Central Business District* (CBD), que concentra las actividades económicas y los servicios, y desde el cual se generan gradientes espaciales de precios y usos del suelo. Bajo esta lógica, la distancia al centro se convierte en un factor clave en la toma de decisiones

residenciales y de localización de actividades, generando patrones concéntricos de expansión urbana.

Sin embargo, los procesos de suburbanización, descentralización industrial y crecimiento extensivo del suelo urbano hicieron evidente la insuficiencia de este modelo. Como respuesta, Fujita y Ogawa (1982) y más adelante Henderson (1986), desarrollaron teorías de equilibrio espacial y modelos de aglomeración que explicaban la aparición endógena de subcentros urbanos. Estos subcentros surgen como soluciones adaptativas frente a las externalidades negativas del monocentrismo, la congestión, los altos precios del suelo, pérdida de eficiencia, y como aprovechamiento de las economías de escala y especialización funcional. Henderson, en particular, demostró que la descentralización no implica necesariamente una pérdida de las ventajas de aglomeración, sino una reorganización espacial de estas dinámicas.

En América Latina, la aplicación de estos modelos ha sido objeto de importantes críticas. Pedro Abramo (2003, 2012) propuso la noción de ciudad caleidoscópica para describir una configuración urbana en la que coexisten racionalidades formales e informales, configurando un espacio reticular no jerarquizado. Esta conceptualización subraya que la emergencia de subcentros en la región no obedece necesariamente a dinámicas de equilibrio de mercado, sino a una combinación de especulación inmobiliaria, autoconstrucción y fragmentación del capital urbano.

Almandoz (2014) complementa esta lectura al señalar que el crecimiento urbano latinoamericano tiende a replicar la centralidad simbólica e histórica de los centros fundacionales, incluso en contextos de expansión periférica descontrolada. En esta línea, de Mattos (2002, 2010) aporta la idea de “archipiélago urbano” para describir ciudades compuestas por enclaves fragmentados, sin conexión funcional ni territorial, como resultado de la urbanización informal, la debilidad de los mecanismos de planificación y la desconexión institucional entre niveles de gobierno.

Borsdorf e Hidalgo (2009), en su análisis de Santiago de Chile, identifican que muchos de los supuestos subcentros no son más que concentraciones de actividades sin autonomía estructural, ya que dependen del centro para su viabilidad económica y funcional. Proponen, por tanto, utilizar indicadores mixtos que combinen densidad, movilidad y especialización para distinguir verdaderos nodos estructurantes de simples acumulaciones espaciales. De manera complementaria, Álvarez de la Torre (2009), en su estudio sobre Guadalajara, demuestra que la desconcentración del empleo no implica por sí misma una transición al policentrismo funcional. Muchos de estos nodos continúan subordinados a la lógica del centro histórico, careciendo de redes autónomas de servicios, empleo y movilidad.

En este contexto, la investigación empírica sobre la estructura urbana ha migrado hacia enfoques cuantitativos que permiten identificar subcentros con mayor rigor. Ramírez Franco (2008) distingue entre estructuras monocéntricas

y policéntricas funcionales, y propone técnicas como la función de densidad kernel, así como regresiones espaciales y umbrales estadísticos para la detección de nodos urbanos. Estas metodologías contribuyen a evitar sesgos derivados de interpretaciones visuales o intuitivas.

De hecho, García Palomares, Gutiérrez y Mínguez (2021) desarrollan un conjunto de indicadores empíricos para evaluar el policentrismo urbano a partir de la densidad de empleo, la distancia al centro principal y la especialización sectorial. Estos indicadores han demostrado ser especialmente útiles en contextos urbanos complejos y con estructuras informales, como es el caso de muchas ciudades latinoamericanas.

Ahora bien, dentro del contexto mexicano, Navarro, Muñiz y Gómez Maturano (2023) argumentan que en las ciudades intermedias el policentrismo puede consolidarse como una forma estable de organización territorial, no necesariamente como una fase transitoria hacia la dispersión. Sus análisis empíricos, centrados en subcentros que surgen por condiciones específicas de conectividad, infraestructura y demanda económica, refuerzan la idea de que lo policéntrico puede responder a factores estructurales locales más que a una extensión radial desde el centro tradicional.

Trabajos como el de Muñiz, et al. (2008), en el caso de Barcelona, y Rojas Quezada, et al. (2009), sobre Concepción, respaldan la hipótesis de que la existencia de nodos de empleo no implica una ruptura automática con el monocentrismo. Estos estudios muestran que la mayoría de los subcentros emergentes operan como extensiones funcionales subordinadas.

Desde una perspectiva más crítica, Lang (2003), Glaeser y Kahn (2004), así como Gordon y Richardson (1996), han propuesto el concepto de ciudades “sin borde” (*edgeless cities*), donde la lógica de localización del empleo se dispersa de forma difusa, eliminando la referencia a un centro. No obstante, estos modelos han demostrado tener poca aplicabilidad en contextos latinoamericanos, donde la desigualdad estructural, la informalidad y la débil articulación institucional limitan la aparición de estructuras urbanas funcionalmente autónomas.

En síntesis, el debate entre monocentrismo y policentrismo debe entenderse como una tensión continua entre modelos teóricos, contextos empíricos y factores estructurales. En el caso de la Ciudad de México, esta tensión se manifiesta con especial intensidad dada la coexistencia de una centralidad histórica consolidada y la aparición de nuevas centralidades potenciales. Evaluar su grado de funcionalidad, autonomía y capacidad estructurante, resulta crucial para entender los procesos actuales de reconfiguración urbana.

Metodología

El presente capítulo parte de una estrategia analítica orientada a identificar y caracterizar el patrón de monocentrismo y policentrismo en la estructura urbana de la Ciudad de México entre los años 2010 y 2020. La metodología se basa en una combinación de herramientas de Sistemas de

Información Geográfica (SIG), y técnicas estadísticas y programación en Python, lo que permite integrar análisis espaciales rigurosos con criterios funcionales y morfológicos. A partir del procesamiento y depuración del Directorio Estadístico Nacional de Unidades Económicas (DENUE), se calcularon indicadores clave, como la densidad de empleo por AGEB, las distancias al centro histórico y un índice de atracción territorial hacia los subcentros urbanos. Esta aproximación multiescalar y cuantitativa permite superar enfoques descriptivos o meramente visuales, proporcionando una base empírica robusta para evaluar si la ciudad ha mantenido una lógica predominantemente monocéntrica, o si presenta indicios de una transición hacia el policentrismo funcional. Lo anterior, a partir de los siguientes pasos:

Preparación y depuración de datos

En una primera etapa, se utilizaron los registros del Directorio Estadístico Nacional de Unidades Económicas (DENUE), correspondiente a los años 2010 y 2020, obtenidos del Instituto Nacional de Estadística y Geografía (INEGI). Este insumo fue seleccionado debido a su cobertura exhaustiva de establecimientos formales en el país, y por ofrecer información georeferenciada a nivel puntual. El proceso de depuración consistió en el filtro y selección de las variables, conservando tres campos importantes: la ubicación geográfica de cada unidad económica (latitud y longitud), el número de personal ocupado reportado (*per ocu*) y la categoría del giro económico (clasificación económica). Estas variables permitieron identificar no solo la distribución espacial del empleo, sino también su intensidad y carácter funcional. No obstante, se eliminaron registros duplicados, inconsistencias en coordenadas y unidades económicas sin personal reportado, con el propósito de asegurar la calidad del análisis posterior.

Transformación del campo de empleados (SIG y Python)

Para garantizar la precisión en el análisis de centralidad funcional, se recurrió a la transformación del campo *per_ocu* del directorio nacional de Unidades Económicas (DENUE). Posteriormente se implementó un procedimiento automatizado en Python dentro del ArcMap, creando un campo doble (*empleados_num*), donde se almacenan valores numéricos continuos. La transformación se llevó a cabo a través de una función que identifica los rangos expresados en texto, extrae los valores mínimo y máximo, y calcula su promedio como valor representativo. En los casos en que el rango se expresa de manera unitaria o con términos como “y más” o “o más”, el script extrae directamente el número disponible. Este enfoque garantiza la consistencia de los datos y permite conservar la granularidad necesaria para los modelos posteriores de análisis espacial (Figura 1).

```

def convertir(rango):
    if not rango:
        return None
    try:
        texto = str(rango).lower()
        texto = texto.replace("personas", "")
        texto = texto.replace("persona", "")
        texto = texto.replace("y más", "")
        texto = texto.replace("o más", "")
        texto = texto.replace("+", "")
        texto = texto.strip()

        if "a" in texto:
            partes = texto.split("a")
            ini = int(partes[0].strip())
            fin = int(partes[1].strip())
            return (ini + fin) / 2.0
        else:
            num = ".join([c for c in texto if c.isdigit()])
            if num:
                return float(num)
            else:
                return None
    except:
        return None

```

Figura 1. La función empleada para transformación con Python. Fuente: elaboración propia.

La función personalizada que se utilizó, aplica los procesos de limpieza de texto (text preprocessing) y segmentación de cadenas, que aseguran todas las unidades económicas (de manera que tengan un valor numérico estimado de personal ocupado). Este valor se utilizó posteriormente para calcular la densidad de empleo por AGEB, así como para interpolar el índice de Atracción (IA) en formato ráster. Esta transformación no solo permite una integración eficaz de los datos en modelos estadísticos y cartográficos, sino que también asegura replicabilidad y eficiencia en el manejo de grandes volúmenes de información censal y económica, lo cual resulta clave para estudios de centralidad urbana en contextos metropolitanos complejos como el de la Ciudad de México.

Asignación espacial de establecimientos económicos a unidades censales y cálculo de densidad de empleo

Con el propósito de proponer una vinculación espacial precisa entre los establecimientos del Directorio Estadístico Nacional de Unidades Económicas (DENUE) y las unidades censales urbanas definidas por el INEGI, se implementó un proceso de geoprocesamiento en ArcMap, que combinó diversas herramientas de análisis espacial. La primera etapa consistió en aplicar la herramienta *Clip*, utilizando como límite espacial las AGEB urbanas del Censo de Población y Vivienda. Esta operación permitió excluir de la base de datos todos aquellos

establecimientos económicos situados fuera del perímetro urbano delimitado, lo que resultó fundamental para evitar distorsiones en los patrones de centralidad y concentración funcional del empleo.

Una vez depurada la información, se procedió a ejecutar la herramienta *Spatial Join*, con la finalidad de asignar cada punto correspondiente a una unidad económica al polígono de la AGEB urbana que lo contenía. Este cruce espacial generó una base georreferenciada en la que cada AGEB quedó asociada a un conjunto específico de establecimientos económicos, permitiendo así construir una representación estadística por unidad censal. A partir de esta base enriquecida, se generaron tablas resumen para los años 2010 y 2020, consolidando el número total de empleados por AGEB a través del campo *per_ocu*, transformado previamente a valores numéricos.

Aunque las AGEB urbanas presentan superficies muy variables, fue necesario estandarizar los datos de empleo en función del área de cada unidad, para obtener un indicador comparable entre zonas. Para ello, se calculó la densidad de empleo mediante la fórmula:

$$\text{Densidad de empleos (empleos/km}^2\text{)} = \text{Total empleados} / \text{Área del AGEB en km}^2$$

A partir de lo anterior, se generaron tres nuevos campos en la tabla de atributos de las AGEB urbanas, donde el primero corresponde al área calculada en km², el segundo a la densidad de empleo y, por último, el tercero al logaritmo natural de dicha densidad. Esto, con el fin de facilitar su incorporación en modelos estadísticos posteriores, y moderar los efectos de asimetría en la distribución de los datos. Por lo tanto, este procedimiento facilita la obtención de una representación cuantitativa y espacial continua de la concentración de empleo urbano, lo que constituye una base para los análisis de centralidad desarrollados en las posteriores etapas. De hecho, la visualización cartográfica se representa en la Figura 2 y la Figura 3, permitiendo contrastar la distribución y densidad de empleo entre el año 2010 y 2020.

En el mapa de la densidad de empleo 2010, se aprecia una distribución altamente concentrada del empleo formal en el núcleo central de la CDMX, puntualmente en torno a las alcaldías de Cuauhtémoc, Benito Juárez y Miguel Hidalgo. Estas zonas tienen mayores densidades de empleo, superando los 26,000 empleos/ km² en algunas AGEB específicas, lo que refleja un persistente patrón monocéntrico, pero con un peso desproporcionado del centro histórico y sus áreas aledañas en cuanto a la estructura funcional metropolitana. Conforme se aleja del centro administrativo, se identifica igual una disminución progresiva de la densidad laboral, lo que es coherente con los supuestos del modelo monocéntrico clásico de Alonso (1964), donde los precios del suelo y la localización del empleo tienden a concentrarse en el núcleo, y a dispersarse con la distancia.

En contraste con el área periférica, puntualmente la del sur y oriente de la CDMX, se tiene densidades por debajo de 2,000 empleos/ km², mostrando una baja presencia de actividades económicas formales y una fuerte dependencia funcional del centro. El patrón espacial que refleja la Figura 2 confirma una configuración jerárquica rígida y centralizada, donde los procesos de descentralización aún no muestran una reconfiguración policéntrica significativa. La ausencia de núcleos secundarios con densidades intermedias consistentes en la periferia sugiere que, para 2010, la Ciudad de México todavía mantenía una estructura urbana dominada por un único polo funcional dominante.




Figura 2. Densidad de empleo por AGEB urbana en la Ciudad de México, 2010.
Fuente: elaboración propia con base en datos del DENUE (INEGI, 2010).

Para el año 2020 se observa una transformación parcial en la distribución espacial del empleo urbano, pero con ciertos indicios de un incipiente proceso de desconcentración funcional respecto al patrón monocéntrico del 2010. En efecto, aunque el núcleo central (de las alcaldías Cuauhtémoc, Benito Juárez y Miguel Hidalgo) se mantiene concentrando las mayores densidades de empleo que ahora son superiores a 27,000 empleos/ km², en algunas AGEB se identifican nuevas áreas con densidades laborales medias y altas en zonas antes marginales al sistema económico formal.

Sin embargo, entre los cambios más significativos se identifica la densidad en corredores emergentes al sur poniente y poniente, así como en zonas intermedias como las alcaldías Azcapotzalco, Iztacalco y algunas partes de Coyoacán. A pesar de que estas zonas presentaban antes densidades moderadas, actualmente muestran un crecimiento en la concentración de actividades económicas, lo que sugerentemente está mostrando una diversificación funcional del espacio urbano.

Este patrón puede estar vinculado al desarrollo de infraestructura comercial, logística y tecnológica en zonas tradicionalmente residenciales o industriales. La periferia sur y oriental continúa mostrando bajos niveles de densidad laboral, lo que confirma una estructura desigual. Lo más relevante en el 2020 es que se observa una transición incompleta hacia una configuración policéntrica, caracterizada por una persistencia de la centralidad dominante, pero acompañada de núcleos funcionales secundarios que comienzan a estructurarse con mayor peso relativo.

La cartografía creada a partir de los datos anteriores permite tener hallazgos que llevan a cuestionar la rigidez del modelo monocéntrico, y abre paso hacia un camino para el análisis de una configuración intermedia, característica de las metrópolis latinoamericanas, donde conviven centralidades consolidadas, con subcentros en proceso de consolidación.

A partir de lo anterior, fue posible tener una lectura espacial para cuestionar el debate conceptual entre los modelos monocéntrico y policéntrico. Por ejemplo, para el 2010 la distribución de empleo en la CDMX revela un patrón monocéntrico fuerte, en línea con los supuestos del paradigma neoclásico de localización urbana (Alonso, 1964; Muth, 1969; Mills, 1972) donde el único centro aglomera las funciones económicas clave, derivando en gradientes espaciales de valor del suelo y ocupación.

Sin embargo, para el año 2020 se observan ciertas transformaciones en este esquema, ya que aunque la centralidad histórica se mantiene, se generan nuevos núcleos secundarios de empleo, indicando una transición hacia formas de centralidad un poco más diversificadas, coherentes con el planteamiento teórico de Fujita y Ogawa (1982) y Henderson (1986) sobre la emergencia endógena de subcentros. Estas concentraciones no surgen por azar, sino como respuesta a factores estructurales como la congestión del centro, el abaratamiento del suelo periférico o la relocalización estratégica de actividades.




Figura 3. Densidad de empleo por AGEB urbana en la Ciudad de México, 2020.

Fuente: elaboración propia con base en datos del DENUE (INEGI, 2020).

Cálculo espacial de centralidad: distancia al núcleo urbano principal

En esta fase se calculó la distancia euclidiana entre cada AGEB y un punto de referencia central, que en este caso es el Zócalo de la Ciudad de México. Para ello, se utilizó la herramienta *near* que permite calcular de manera automática la distancia mínima entre el centroide de cada AGEB y el punto central. De aquí, los valores resultantes se exportaron en CSV, y fueron vinculados de manera posterior a la base de datos principal.

Este paso es importante, ya que es útil para la construcción de modelos estadísticos siguientes, en particular para estimar la relación entre distancia y densidad de empleo. En efecto, con la distancia euclidiana se garantiza mayor precisión analítica, permitiendo establecer gradientes espaciales de concentración económica (Figura 4).




Figura 4. Centroides de AGEB para cálculo de distancias euclidianas.

Fuente: elaboración propia con base en datos del Instituto Nacional de Estadística y Geografía (INEGI) correspondientes a los años 2010 y 2020.

Identificación de subcentros laborales desde el análisis de densidad y regresión lineal

Durante este paso, se implementó un modelo de regresión lineal para evaluar la relación entre la distancia al centro urbano y el logaritmo de densidad de empleos en cada AGEB para los años 2010 y 2020. También se analizó la variación entre ambos periodos.

El código que se utilizó en dicha regresión lineal muestra, primero, la carga de bibliotecas (importando librerías como pandas para manejo de datos, *statmodels* para el modelo de regresión, *matplotlib* y *seaborn* para visualización);

segundo, la preparación de datos (se convierte la distancia a kilómetros y se calcula la diferencia del logaritmo natural de la densidad de empleos 2020-2010 con *delta_logedens*); en tercer lugar, que el modelo de regresión se ajusta a tres modelos con la función *OLS()* de *statsmodels* (uno para 2010, otro para 2020 y un tercero para la variación de los dos años (*delta_logedens*)). Con este resultado, se genera un gráfico de dispersión (*scatterplot*) que muestra la relación entre la distancia al centro urbano y la variación de la densidad logarítmica, y además se agrega una línea de tendencia para ilustrar el ajuste del modelo (Figura 5).

```

import pandas as pd
import statsmodels.api as sm
import matplotlib.pyplot as plt
import seaborn as sns

df_centros["dist_km"] = df_centros["NEAR_DIST"] / 1000
df_centros["delta_logdens"] = df_centros["logaritmod 2020"] - df_centros["logdens 2010"]

X_log_2010 = sm.add_constant(df_centros["dist_km"])
y_log_2010 = df_centros["logdens 2010"]
modelo_log_2010 = sm.OLS(y_log_2010, X_log_2010).fit()

X_log_2020 = sm.add_constant(df_centros["dist_km"])
y_log_2020 = df_centros["logaritmod 2020"]
modelo_log_2020 = sm.OLS(y_log_2020, X_log_2020).fit()

X_log_delta = sm.add_constant(df_centros["dist_km"])
y_log_delta = df_centros["delta_logdens"]
modelo_log_delta = sm.OLS(y_log_delta, X_log_delta).fit()

print(modelo_log_2010.summary())
print(modelo_log_2020.summary())
print(modelo_log_delta.summary())

plt.figure(figsize=(8, 6))
sns.scatterplot(x="dist_km", y="delta_logdens", data=df_centros, lpha=0.6)
plt.plot(df_centros["dist_km"], modelo_log_delta.predict(X_log_delta), color="black", linestyle="--")
plt.axhline(0, color="red", linestyle=":")
plt.title("Cambio en log densidad de empleo (2020 – 2010)")
plt.xlabel("Distancia al centro (km)")
plt.ylabel("Log(dens 2020) – Log(dens 2010)")
plt.tight_layout()
plt.show()

```

Figura 5. Código en Python para el análisis de regresión lineal. Fuente: elaboración propia con base en análisis en Python

Para programar el resultado de esta regresión, se imprimen los resúmenes de los modelos ajustados y se presentan los coeficientes y coeficientes de determinación (R^2), además de interpretar una atenuación en la relación distancia densidad entre 2010 y 2020. Con el análisis estadístico de la regresión

lineal entre la distancia al centro urbano y el logaritmo natural de la densidad de empleo por AGEB, se obtuvieron dos coeficientes: para el año 2010, el coeficiente de regresión fue de -0.131 , con un coeficiente de determinación ($R^2 = 0.282$). Esto indica que por cada kilómetro adicional desde el centro histórico de la ciudad (Zócalo), la densidad de empleo disminuye, en promedio, 0.131 unidades logarítmicas. La distancia explica el 28.2% de la variabilidad en la concentración espacial del empleo. El año 2020 el coeficiente de regresión fue de -0.103 , con un $R^2 = 0.240$. En este caso, la disminución en la densidad es ligeramente menor, lo que sugiere una atenuación del gradiente espacial en torno al centro urbano.

En las Figuras 6 y 7, el año 2010 muestra una pendiente negativa donde los empleos estaban fuertemente concentrados cerca del centro, sugiriendo una estructura monocéntrica clara. Para el año 2020 se mantiene la pendiente negativa, pero es menos pronunciada que en 2010, mostrando una reducción en la centralidad del empleo.

Por otro lado, como resultado también de la regresión, en la Figura 8 se muestra de manera concreta el comportamiento del logaritmo natural de la densidad de empleos con relación a la distancia al Centro Histórico. Aquí cada punto representa un AGEB urbano, mientras que las líneas de regresión muestran la tendencia general de concentración laboral: 2010 (azul), y 2020 (rojo). Con esto, se observa que, en los dos años existe un gradiente negativo donde, a mayor distancia del centro hay menor densidad de empleos. No obstante, la pendiente es menos pronunciada en 2020, lo que puede sugerir una ligera disminución del patrón monocéntrico, y la posible emergencia de una configuración urbana más dispersa o con múltiples núcleos.




Figura 6. Gráficos de dispersión 2010. Fuente: elaboración propia con procesamiento y visualización en Python.




Figura 7. Gráficos de dispersión 2020. Fuente: elaboración propia con procesamiento y visualización en Python.




Figura 8. Distancia al centro urbano y log densidad de empleos. Fuente: elaboración propia mediante regresión lineal en Python.

Delimitación de subcentros urbanos

A partir de los resultados obtenidos de la localización de densidad de empleos y el análisis de la regresión lineal, se llevó a cabo la delimitación de los subcentros urbanos. Esta etapa tuvo como objetivo identificar las AGEB que concentran los valores elevados de densidad logarítmica, interpretados como puntos significativos de aglomeración laboral dentro de la ciudad. La

identificación de estos subcentros se realizó a través de una inspección visual detallada de los mapas temáticos elaborados en ArcMap para los años 2010 y 2020, utilizando simbología graduada.

Posteriormente, se hizo una selección manual de los AGEB, cuya densidad supera el umbral establecido por el promedio más una desviación estándar, criterio que permitió destacar las áreas con mayor intensidad de empleo. Estas unidades espaciales fueron extraídas y almacenadas como capas independientes, diferenciadas por año. Posteriormente, se empleó la herramienta *Feature to Point* para generar los centroides de cada subcentro. Dichos puntos fueron georreferenciados mediante coordenadas cartesianas (X, Y), y se constituyeron como la base geoespacial para el cálculo del Índice de Atracción en la fase posterior del análisis (Figuras 9 y 10).




Figura 9. Subcentros AGEB 2010. Fuente: elaboración propia.




Figura 10. Subcentros AGEB 2020. Fuente: elaboración propia.

Cálculo del Índice de Atracción (IA)

Después de la identificación de subcentros de empleo, la etapa final es la estimación de un índice de Atracción para cada AGEB urbano. Dicho índice está basado en la noción de accesibilidad relativa, que se calcula a través de la suma de la inversa del cuadrado de la distancia desde cada AGEB hacia todos los subcentros identificados. Bajo esta lógica, se penaliza de manera fuerte a los AGEB alejados y se da mayor peso a los cercanos, lo que deriva en su potencial de atracción laboral. Para ello se utilizó la siguiente fórmula:

$$IA_i = \sum (1 / (d_{ij}^2 + 1))$$

Aquí, d_{ij} representa la distancia entre el AGEB i y el subcentro j . Se añadió una unidad al denominador para evitar divisiones por cero y suavizar el efecto de distancias extremadamente cortas. Este procedimiento se llevó a cabo para los años 2010 y 2020 utilizando Python, específicamente con las bibliotecas *geopandas*, *shapely* y *numpy*. La finalidad fue generar una métrica comparable entre años, exportable a formatos SIG para análisis y representación espacial.

En términos de valor, el IA tiene tres características esenciales:

- Número real positivo: todas las distancias al cuadrado son positivas y la fórmula implica una suma de fracciones positivas. Además, puede tomar valores como 0.003, 0.084, 1.000 etc.
- El rango de valores esperados: 1. Siempre mayor que cero (incluso la distancia mínima genera un valor positivo en la fórmula); 2. El valor máximo (lo que obtiene un AGEB que esté muy cerca de muchos subcentros o de uno solo si este subcentro está a distancia cero). 3. El valor mínimo (lo que tiene un AGEB alejado de todos los subcentros si $1/d^2 + 1$ tienden a cero, pero nunca llegan a ser cero exacto).
- Es un índice relativo (no tiene una unidad física).
- Sirve para comparar niveles de atracción entre AGEB, no para interpretar su valor absoluto.

Un ejemplo importante es que un IA de 0.9 indica una alta cercanía a uno o varios subcentros, mientras que un IA de 0.00001 sugiere un AGEB completamente aislado y periférico.

El código se explica de la siguiente manera: primero, la carga de archivos CSV donde están las coordenadas de AGEB y subcentros de 2010 y 2020; segundo, se hace una conversión a *Geo Data Frame*, donde se construyen objetos geométricos tipo punto con las coordenadas; tercero, se hace una re proyección a UTM zona 14 N para garantizar que las distancias se midan en metros; cuarto, se utiliza la Función *calcular_ia()* para calcular el Índice de Atracción para cada AGEB sumando los valores inversos al cuadrado de la distancia de todos los subcentros. Quinto, se hace el cálculo de IA por año, y el resultado que se exporta es en formato CSV para integrarlo con una capa espacial en SIG (Figura 11).

```
import geopandas as gpd
from shapely.geometry import Point
import numpy as np

# Cargar archivos de AGEBs y subcentros con coordenadas
agebs_coords = pd.read_csv("mm_3.csv", sep=";")
subs_2020 = pd.read_csv("2020X.csv", sep=";")
subs_2010 = pd.read_csv("2010X.csv", sep=";")

# Convertir a GeoDataFrames
geometry_agebs = [Point(xy) for xy in zip(agebs_coords['POINT_X'], agebs_coords['POINT_Y'])]
gdf_agebs = gpd.GeoDataFrame(agebs_coords[['ageb']], geometry=geometry_agebs, crs="EPSG:4326")
```

```

geometry_2020 = [Point(xy) for xy in zip(subs_2020['POINT_X'], subs_2020['POINT_Y'])]
gdf_subs_2020 = gpd.GeoDataFrame(subs_2020[['ageb']], geometry=geometry_2020, crs="EPSG:4326")

geometry_2010 = [Point(xy) for xy in zip(subs_2010['POINT_X'], subs_2010['POINT_Y'])]
gdf_subs_2010 = gpd.GeoDataFrame(subs_2010[['ageb']], geometry=geometry_2010, crs="EPSG:4326")

# Reproyección a UTM zona 14N
gdf_agebs = gdf_agebs.to_crs(epsg=32614)
gdf_subs_2020 = gdf_subs_2020.to_crs(epsg=32614)
gdf_subs_2010 = gdf_subs_2010.to_crs(epsg=32614)

def calcular_ia(origenes, destinos):
    ia_values = []
    for _, origen in origenes.iterrows():
        dists = destinos.distance(origen.geometry)
        ia = np.sum(1 / (dists**2 + 1))
        ia_values.append(ia)
    return ia_values

gdf_agebs['IA_2020'] = calcular_ia(gdf_agebs, gdf_subs_2020)
gdf_agebs['IA_2010'] = calcular_ia(gdf_agebs, gdf_subs_2010)

resultado_ia = gdf_agebs.drop(columns='geometry')
resultado_ia.to_csv("indice_atraccion_resultado.csv", index=False)

```

Figura 11. Código para IA. Fuente: elaboración propia en Python.

Este cálculo permitió obtener un valor cuantitativo de atracción para cada AGEb, facilitando su comparación espacial temporal.

Resultados

El índice de atracción del año 2010 muestra una estructura concentrada en torno al centro histórico de la ciudad, donde se localizan los valores más altos del índice, como se aprecia en la Figura 12, que se representa en rojo. En efecto, estos rangos alcanzan hasta 1.00092. Esta concentración de áreas con alta atracción laboral se extiende con fuerza hacia el sur poniente, abarcando partes de Cuauhtémoc, Benito Juárez y Miguel Hidalgo, y formando un núcleo compacto con valores que oscilan entre 0.000071 y 1.000092.

Las zonas con valores medios (representadas en color naranja y amarillo, entre 0.000017 y 0.000070) se ubican en una franja intermedia que rodea este núcleo central, reflejando una disminución progresiva de la atracción conforme aumenta la distancia al centro. En estas áreas se identifican algunas alcaldías con actividad significativa pero no dominante, como Coyoacán o ciertas zonas de Azcapotzalco. Por otro lado, la mayor parte del territorio presenta valores bajos o muy bajos de atracción, especialmente en las periferias sur y oriente (destacadas en azul claro y azul medio), con índices entre 0.000000 y 0.000016. Esta amplia cobertura de AGEb con escasa atracción laboral, refuerza la idea de una estructura predominantemente monocéntrica en 2010, donde las oportunidades de empleo estaban fuertemente concentradas en una

zona núcleo, sin una distribución significativa hacia subcentros alternativos, las zonas periféricas con el tejido económico de la metrópoli (Figura 11).

Frente al índice de atracción del año 2020, se observa una reconfiguración en los patrones de atracción urbana con respecto a la década anterior.

Aunque el núcleo central conformado por las alcaldías Cuauhtémoc, Benito Juárez y Miguel Hidalgo, sigue concentrando los valores más altos del Índice de Atracción (IA), identificados en rojo oscuro (rango 0.00077 - 1.000094), se observa una expansión hacia zonas periféricas del poniente y suroeste, como Álvaro Obregón y parte de Coyoacán, que muestran valores en rangos medio-altos (naranja y amarillo).




Figura 12. Índice de Atracción 2010. Fuente: elaboración propia.

Este desplazamiento sugiere un leve debilitamiento del patrón monocéntrico observado en 2010, dando paso a una mayor dispersión espacial de los focos de atracción laboral. Asimismo, emergen nuevos nodos de atracción en zonas anteriormente marginales, como algunos puntos en Gustavo A. Madero, Iztapalapa y Tlalpan que, aunque mantienen valores bajos (azules), empiezan a integrarse a la estructura funcional mediante corredores urbanos.

En términos cuantitativos, el área correspondiente al valor más alto del índice (rojo) se amplía y extiende en comparación con 2010, indicando una mayor conectividad y jerarquía de ciertos subcentros. A diferencia del 2010, donde los valores extremos estaban más contenidos, en 2020 la distribución presenta un gradiente más amplio, lo cual puede reflejar procesos de descentralización parcial y diversificación del empleo en la CDMX.

El patrón espacial del IA 2020, sugiere un tránsito desde una organización urbana monocéntrica rígida hacia una forma más compleja, donde el centro histórico conserva su predominio, pero coexiste con un sistema incipiente de subcentros articulados (Figuras 12 y 13).




Figura 13. Índice de Atracción 2020. Fuente: elaboración propia.

Discusión y reflexiones finales

El debate sobre la centralidad urbana ha estado vinculado históricamente a la tensión entre lo monocéntrico y lo policéntrico. Esta dicotomía, aunque conceptual, tiene implicaciones prácticas en la planificación, el acceso a servicios y la justicia territorial. En este capítulo, donde se analiza puntualmente a la Ciudad de México, los resultados cartográficos del Índice de Atracción (IA) para 2010 y 2020 evidencian una transformación estructural importante, que pone a discusión los marcos teóricos clásicos para interpretarlos en la realidad metropolitana latinoamericana.

Aunque autores como Christaller (1933) y Lösch (1954), desde la teoría del lugar central, formularon modelos jerárquicos con un núcleo principal que ordena espacialmente a las periferias; la lógica observada del patrón en 2010 se caracterizó por una fuerte concentración de empleos hacia el centro y una rápida caída hacia la periferia, lo que sugiere una configuración marcadamente monocéntrica. Por lo tanto, esta lectura es coherente también con la teoría de la localización de Isard (1956), la cual sostiene que las decisiones de localización están determinadas por la minimización de costos y la maximización de accesibilidad, concentrando funciones económicas en zonas centrales.

En contraste con lo anterior, la estructura de 2020 muestra una expansión más difusa de nodos laborales sin que desaparezca el núcleo central, pero sí coexistiendo con otras áreas de atracción secundaria. Este patrón refleja un debilitamiento del monocentrismo clásico, sin llegar aún a una condición completamente policéntrica. De hecho, el patrón intermedio dialoga con la propuesta de Von Bertalanffy (1986), para quien los sistemas urbanos deben analizarse como estructuras abiertas, dinámicas y no lineales. Asimismo, se aproxima a las ideas de Zipf (1949), donde el tamaño relativo de los centros urbanos sigue una distribución que no obedece a un único vértice hegemónico, sino a una jerarquía funcional múltiple.

Por otro lado, se puede inferir que el método aplicado a partir del cálculo del Índice de Atracción (IA), representa una manera más contemporánea de estudiar el espacio urbano, al incorporar herramientas de inteligencia artificial (Python) y sistemas de información geográfica (SIG). La formulación basada en la inversa de la distancia al cuadrado permite captar no solo la proximidad espacial, sino la intensidad relativa de los subcentros en función del empleo, lo que resulta relevante en contextos urbanos fragmentados como el de la CDMX. Este enfoque no solo permite superar los límites de los análisis cartográficos descriptivos tradicionales, sino que introduce una dimensión relacional y cuantificable al debate sobre la centralidad urbana. Al vincular la georreferenciación de subcentros con distancias ponderadas, el análisis revela patrones que difícilmente serían detectables a simple vista. La identificación de AGEB con alta atracción en zonas no tradicionales del centro abre nuevas líneas de investigación sobre la reconfiguración funcional del territorio metropolitano.

De hecho, el modelo aplicado se alinea parcialmente con las teorías clásicas, pero también las matiza. Mientras que la lectura monocéntrica de 2010 valida los postulados de Christaller (1933) e Isard (1956), la tendencia observada en 2020 hacia una estructura más distribuida plantea tensiones con esos enfoques jerárquicos. Bajo esta perspectiva, la evidencia empírica respalda una lectura más contemporánea, donde la ciudad se entiende como una red compleja de centralidades múltiples (Batty, 2007).

De manera complementaria, el análisis plantea una crítica que se encuentra implícita a los marcos normativos de planeación que siguen operando bajo supuestos de homogeneidad urbana. La dispersión observada en las periferias, sin una articulación clara con los subcentros, da cuenta de una fragmentación estructural que los modelos clásicos no logran explicar del todo.

Así que la aplicación de inteligencia artificial y SIG no solo mejora la precisión del análisis espacial, sino que también democratiza el acceso a herramientas metodológicas avanzadas. Estos recursos permiten a investigadores y planificadores identificar patrones, evaluar escenarios y tomar decisiones basadas en evidencia, algo relevante en contextos de alta complejidad territorial, como lo es el mexicano.

En conclusión, este tipo de metodología ofrece una alternativa significativa para repensar las estructuras urbanas más allá de la dicotomía centro-periferia. En lugar de forzar a las ciudades dentro de modelos heredados, se trata de construir herramientas que revelen sus dinámicas propias. En este sentido, el cruce entre teoría urbana, análisis espacial e inteligencia artificial, abre un horizonte propicio para los estudios urbanos del siglo XXI.

Referencias

- Abramo, P. (2003). La ciudad caleidoscópica: Coordinación espacial y racionalidad urbana. *Eure*, 29(86), 55-75. <https://doi.org/10.4067/S0250-71612003008600004>
- Abramo, P. (2012). Cidade, propriedade e valorização: uma explicação para a informalidade urbana latino-americana. In P. Abramo (Ed.), *A cidade da informalidade* (pp. 17-46). Lincoln Institute of Land Policy.
- Alonso, W. (1964). *Location and land use: Toward a general theory of land rent*. Harvard University Press.
- Almendoz, A. (2014). *Modernización, urbanización y desarrollo en América Latina, 1900-2000*. Routledge.
- Álvarez de la Torre, G. (2009). Policentrismo metropolitano en América Latina: el caso de Guadalajara. *Eure*, 35(105), 27-50. <https://doi.org/10.4067/S0250-71612009000100002>
- Batty, M. (2007). *Cities and complexity: understanding cities with cellular automata, agent-based models, and fractals*. The MIT press.

- Bertalanffy, L. V. (1986). *Teoría general de los sistemas: fundamentos, desarrollo, aplicaciones*. Fondo de Cultura Económica.
- Borsdorf, A., y Hidalgo, R. (2009). Aportes para una teoría de la urbanización latinoamericana en el contexto de la globalización. *EURE*, 35(104), 35–58. <https://doi.org/10.4067/S0250-71612009010400003>
- Christaller, W. (1933). *Die zentralen Orte in Süddeutschland*. Jena: Gustav Fischer. [Traducción al inglés: *Central Places in Southern Germany* (1966), Prentice Hall]
- De Mattos, C. (2002). Globalización, políticas neoliberales y reestructuración urbana en América Latina: el caso de Santiago de Chile. *Eure*, 28(85), 29–40.
- De Mattos, C. (2010). Procesos de metropolización y expansión urbana en América Latina: el caso de Santiago de Chile. *Revista INVI*, 25(68), 13–40.
- Fujita, M., y Ogawa, H. (1982). Multiple equilibria and structural transition of non-monocentric urban configurations. *Regional Science and Urban Economics*, 12(2), 161–196. [https://doi.org/10.1016/0166-0462\(82\)90031-X](https://doi.org/10.1016/0166-0462(82)90031-X)
- García Palomares, J. C., Gutiérrez, J., y Mínguez, C. (2021). Identification of polycentric structure in urban areas with employment data. *European Planning Studies*, 29(2), 219–242. <https://doi.org/10.1080/09654313.2020.1726299>
- Glaeser, E. L., y Kahn, M. E. (2004). Sprawl and Urban Growth. In J. V. Henderson y J.-F. Thisse (Eds.), *Handbook of Regional and Urban Economics* (Vol. 4, pp. 2481–2527). Elsevier. [https://doi.org/10.1016/S1574-0080\(04\)80063-0](https://doi.org/10.1016/S1574-0080(04)80063-0)
- Gordon, P., y Richardson, H. W. (1996). Beyond polycentricity: The dispersed metropolis, Los Angeles, 1970–1990. *Journal of the American Planning Association*, 62(3), 289–295. <https://doi.org/10.1080/01944369608975693>
- Henderson, J. V. (1986). Efficiency of resource usage and city size. *Journal of Urban Economics*, 19(1), 47–70. [https://doi.org/10.1016/0094-1190\(86\)90036-7](https://doi.org/10.1016/0094-1190(86)90036-7)
- Instituto Nacional de Estadística y Geografía. (2010). *Directorio Estadístico Nacional de Unidades Económicas (DENUE)*, 2010 [Base de datos]. <https://www.inegi.org.mx/app/mapa/denue/>
- Instituto Nacional de Estadística y Geografía. (2020). *Directorio Estadístico Nacional de Unidades Económicas (DENUE)*, 2020 [Base de datos]. <https://www.inegi.org.mx/app/mapa/denue/>
- Isard, W. (1956). *Location and Space Economy*. MIT Press.
- Lang, R. E. (2003). *Edgeless Cities: Exploring the Elusive Metropolis*. Brookings Institution Press.
- Lösch, A. (1954). *The Economics of Location*. Yale University Press.
- Mills, E. S. (1972). *Studies in the structure of the urban economy*. The Johns Hopkins Press.

- Muñiz, I., Galindo, A., y García, M. A. (2008). Policentrismo y localización de empleo en el área metropolitana de Barcelona: un análisis de microdatos censales. *EURE*, 34(103), 25–44.
- Muth, R. F. (1969). *Cities and Housing: The Spatial Pattern of Urban Residential Land Use*. University of Chicago Press.
- Navarro, L., Muñiz, I., y Gómez-Maturano, R. (2023). Estructura urbana y subcentros funcionales en ciudades intermedias mexicanas. *Revista Iberoamericana de Urbanismo*, (20), 1–20. <https://doi.org/10.37230/riu.20.2023.01>
- Ramírez Franco, J. (2008). La estructura espacial del empleo: una aproximación empírica al monocentrismo y policentrismo urbanos. *Revista de Estudios Regionales*, 82, 67–88.
- Rojas Quezada, C., Henríquez, C., y Fernández, J. (2009). Caracterización espacial de los subcentros de empleo en Concepción. *Revista de Geografía Norte Grande*, (44), 29–44. <https://doi.org/10.4067/S0718-34022009000200003>
- Zipf, G. K. (1949). *Human behavior and the principle of least effort: An introduction to human ecology*. Addison-Wesley.

Capítulo III. Planeación urbana: proyección de la densificación urbana al 2030. Caso de estudio Polanco, México

María Fernanda Islas Monroy¹

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA), Unidad
Tecamachalco. Naucalpan, Estado de México.

Resumen

Dentro de la planeación urbana la principal estrategia es el plan de desarrollo urbano, y una de sus características importantes son los niveles permitidos de construcción. Estas herramientas son clave para áreas ya existentes, que maximizan el número de niveles permitidos, provocando el incremento de la cantidad de vivienda, fenómeno denominado densificación urbana. Aunque este acontecimiento se ha convertido en una importante estrategia ante la escasez de suelo, ciertas regiones no cuentan con la infraestructura para sustentar la demanda de vivienda; tal y como ocurre en nuestro caso de estudio, Polanco, donde ya existe congestión vehicular y escasez de agua. Para este estudio se utilizaron datos del 2008 al 2022, con un total de 3,510 predios, donde durante este periodo 624 tuvieron cambio de niveles. En base a estos datos se propone una proyección al 2030, para anticipar y mitigar impactos colaterales.

Palabras clave: planeación urbana, densificación, verticalidad.

Abstract

Within urban planning, the main strategy is the urban development plan, and one of its important characteristics is the permitted building levels. These tools are key for existing areas that maximize the number of permitted levels, causing an increase in the housing stock, a phenomenon known as urban densification. Although this phenomenon has become an important strategy in the face of land scarcity, certain regions lack the infrastructure to support housing demand, as is the case in our case study of Polanco, where traffic congestion and water scarcity already exist. This study uses data from 2008 to 2022, with a total of 3,510 properties, 624 of which underwent level changes during this period. Based on these data, a projection to 2030 is proposed to anticipate and mitigate collateral impacts.

Keywords: urban planning, densification, verticality.

Introducción

La expansión urbana horizontal se ha estudiado desde hace algunos años, comprendiendo relativamente bien este crecimiento. Sin embargo, el conocimiento de los perfiles verticales de las estructuras construidas y la

1 Candidata a Maestra en Ciencias en Arquitectura y Urbanismo, Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura, ESIA, Unidad Tecamachalco. Correo: maria.9909@hotmail.com, ORCID: <https://orcid.org/0009-0003-8347-0592>

expansión urbana vertical hoy en día continúa siendo limitado (Yang y Zhao, 2022). Ambos crecimientos (crecimiento vertical y horizontal) surgen como consecuencia de factores geográficos o socioeconómicos, produciéndose tanto en forma horizontal como en vertical (López, 2021). También los perfiles urbanos verticales se complementan con la expansión urbana horizontal, evidenciada por el aumento de la altura de los edificios, la menor proximidad a los centros urbanos y la creciente intensidad de la urbanización (Yang y Zhao, 2022), sobre todo, en ciudades en vías de desarrollo donde se produce un crecimiento de población y extensión urbana de manera acelerada durante los últimos 20 años (Sarasola, 2024).

En cuanto a las intervenciones y transformaciones urbanas, estas se han hecho por diversos motivos, entre ellos: la construcción de nuevos edificios, la recuperación o rehabilitaciones de zonas, o el incremento de la densidad, la cual requiere mayor demanda de suelo (Sarmiento, 1999). Consecuentemente, las intervenciones aumentan cerca de los centros de actividad, ya que la competencia por el suelo eleva los costos e impulsa a los desarrolladores a economizar el uso del terreno (De Mattos, et al., 2014).

Para lograr un uso más intensivo y eficiente del suelo urbano, diversos gobiernos e instituciones recurren a un conjunto articulado de políticas públicas, estrategias normativas y dinámicas de transformación del entorno construido, lo cual se ha agrupado bajo el concepto de densificación urbana (Sarasola, 2024). Este enfoque implica la implementación de mecanismos que promueven una mayor concentración de edificaciones y habitantes dentro de áreas previamente urbanizadas, sin necesariamente expandir el límite físico de la ciudad. En este contexto, se da lugar a procesos de sustitución edificatoria, en los cuales construcciones de baja densidad son reemplazadas por desarrollos de mayor altura y capacidad habitacional. Como resultado, se incrementa significativamente la cantidad de viviendas por unidad de superficie, particularmente en sectores con alta demanda inmobiliaria. Este fenómeno se acompaña además de una marcada verticalización del espacio urbano, es decir, del crecimiento de las ciudades hacia arriba mediante edificaciones en altura, como respuesta a las presiones del mercado y a la necesidad de optimizar el uso del suelo disponible (Vicuña, 2017). Lejos de ser un proceso homogéneo, la densificación adopta múltiples formas y efectos, que dependen tanto de las condiciones locales como de las políticas de regulación territorial implementadas.

Algunos de los objetivos de la densificación son: a) tratar de limitar las extensiones de las ciudades, reduciendo las distancias y tiempos de movilidad; por otro lado, b) buscar generar economías aglomeradas, obteniendo sinergias de actividades con agentes cercanos. La densificación puede favorecer la interacción social a comparación del aislamiento de zonas residenciales con baja densidad (Sarasola, 2024), teniendo como finalidad lograr el modelo de

la ciudad de los 15 minutos; sin embargo, esto va a la par con las políticas urbanas.

A finales del siglo pasado, a nivel mundial las políticas urbanas comenzaron con transformaciones significativas, ajustándose a desafíos como la globalización, la digitalización y las nuevas dinámicas del mercado. Estos cambios han tenido ciertos impactos en la estructura y la dirección de las ciudades, generando modelos de progreso que buscan equilibrar la innovación tecnológica con la inclusión social y la sustentabilidad (Mena, 2024).

La ciudad no es lo mismo que una isla en medio de una superficie “abstracta”, como se suelen conceptualizar los planes y programas de desarrollo urbano. La ciudad está inserta dentro de un territorio o región con características ambientales, donde junto con otras ciudades de mayor o menor dimensión ha tejido una interdependencia social, económica y funcional que va a lo largo de las décadas y los siglos de la historia. Los planes urbanos se vuelven fijos y pierden esta vigencia con el tiempo, siempre y cuando no sean actualizados y revisados constantemente, por lo que dejan de ser operativos. Se plasman como documentos legales para los usos del suelo de los fraccionamientos o nuevas construcciones, pero al no dar respuesta a las demandas sociales pierden la validez como instrumentos y para ordenar recursos y acciones para ir creciendo la ciudad para el futuro (Bazant, 2010).

En el actual contexto del desarrollo urbano contemporáneo, la figura de la ciudad-región emerge como un modelo clave para abordar los desafíos de la globalización y la planificación territorial (Sierra, 2024). Sin embargo, la planeación urbana en México enfrenta limitaciones que dificultan su capacidad de responder a las necesidades de las ciudades modernas. El actual modelo vigente conserva componentes de enfoques físicos-espaciales y racionales-sistémicos de las décadas pasadas, sin una adaptación clara a las dinámicas actuales (Chaparro, 2014). Asimismo, la incorporación de teorías y modelos urbanos extranjeros se ha hecho de manera superficial, sin una adecuada contextualización. Como resultado, estas estrategias de planeación urbana en el país han sido afectadas por decisiones políticas y económicas, debilitando las estructuras administrativas encargadas del desarrollo urbano (Chaparro, 2009).

Si bien estas ciudades contemporáneas deben responder a necesidades, como es la rápida expansión, la planificación urbana es propicia para el crecimiento urbano, tratando de lograr eficientemente la sostenibilidad. Las intenciones de planificación afectan diferentes aspectos del crecimiento, lo que contribuye a una comprensión más profunda de la heterogeneidad espacial en procesos de urbanización complejos (Zhao, et al., 2025). Gobernar el crecimiento futuro de las megaciudades del mundo hacia una mayor eficiencia en el uso del suelo es importante para lograr la sostenibilidad global (Chakraborty, et al., 2022).

Por lo tanto, el estudio se centra en la colonia Polanco, dentro de la alcaldía Miguel Hidalgo, una de las principales zonas más importantes de la Ciudad de México en términos inmobiliarios y de turismo. En la década de los 60s, incrementaron los edificios de uso habitacional. En los 70s, disminuyó la población y esto empeoró con el terremoto de 1985; por último, en la década de los 90s existió un crecimiento inmobiliario muy importante (Gutiérrez, 2024).

Esta investigación se enfoca en el área de la planeación urbana y análisis territorial, con una perspectiva en la densificación de los predios entre 2008 y 2022. Este lapso permite la evaluación entre las relaciones de la transformación del entorno construido con respecto a las normativas implantadas en el Programa Parcial de Desarrollo Urbano de Polanco 2014, lo que proporcionó información clave sobre los usos de suelo permitidos y los niveles máximos de construcción establecidos en la normativa vigente (Figura 1).

La presente investigación se justifica desde la importancia de prevenir la problemática urbana, si bien las viviendas con baja densidad poblacional, como lo son las casas antiguas en una zona central, son el punto focal para la densificación, y más si tienen uso de suelo mixto. El plan de desarrollo urbano cobra relevancia al otorgar un límite de niveles permitidos a los que vamos a denominar predios potenciales. Dado este crecimiento vertical, la infraestructura también tendría que ser modificada para prever la demanda de servicios y lograr satisfacer a la comunidad.

El objetivo de este capítulo fue proyectar la densificación al 2030 del caso estudio Polanco, como una herramienta para soportar los futuros problemas urbanos como lo son la infraestructura, la congestión y la escasez.



Desarrollo Urbano (2014), recuperado de SEDUVI.

Metodología y resultados

Para el desarrollo de la proyección al 2030, se optó por una metodología de carácter cuantitativa que, según Hernández (2014), se basa en la recopilación y análisis de datos multivariados. En este capítulo, se integraron diversos datos, como los niveles de construcción, el uso de suelo, las normativas vigentes, los datos socioeconómicos, así como la información histórica y la más reciente.

Desde el enfoque de la **Geografía Automatizada**, los Sistemas de Información Geográfica (SIG) se han consolidado como herramientas esenciales para representar, gestionar y analizar el espacio geográfico en su dimensión digital, facilitando una lectura más precisa y operativa del territorio (Buzai y Montes, 2021). Estos sistemas permiten procesar grandes volúmenes de información espacial mediante algoritmos especializados y entornos gráficos interactivos, lo cual favorece la toma de decisiones informadas en múltiples campos de estudio. En tanto evolución de la Geografía Cuantitativa, la Geografía Automatizada no solo incorpora técnicas estadísticas avanzadas, sino que las articula mediante procedimientos automatizados que mejoran el manejo, la actualización y la visualización de los datos territoriales. En el marco de esta investigación, se utilizan plataformas como **ArcGIS** y **ArcScene**, cuyas funcionalidades permiten no solo representar fenómenos espaciales en dos dimensiones, sino también desarrollar modelizaciones tridimensionales del entorno urbano. Estas herramientas resultan fundamentales para proyectar escenarios de **densificación urbana**, ya que posibilitan visualizar los cambios en la ocupación del suelo, estimar impactos morfológicos en el paisaje urbano y simular distintos niveles de intensidad constructiva. Su integración en el análisis territorial aporta una mirada más compleja y detallada de los procesos urbanos, especialmente en contextos donde la presión sobre el suelo exige respuestas técnicas que consideren tanto la eficiencia espacial como los efectos sociales y ambientales derivados de la transformación vertical del hábitat.

El enfoque metodológico, consiste en proyectar la densificación espacial de Polanco al 2030, con el propósito de identificar el origen de las manifestaciones empíricas actuales y realizar un estudio prospectivo sobre su desarrollo urbano. En este sentido, se busca evaluar conjuntos de datos específicos relacionados con la planificación urbana y la verticalidad del entorno construido.

Este es un estudio temporal de carácter de distribución longitudinal de tendencia que se ha logrado recolectando datos de *tiempo 1*: 2008; *Tiempo 2*: 2022, analizando los cambios y relacionando variables para llegar al *tiempo k*: 2030. Dentro de la evolución espacial, se delimita en el área estudio de Polanco, y se analizan los tiempos, los que se dirigen al pasado, generando un estudio génesis (2008 y 2022), y el caso a futuro, como un estudio prospectivo (2030).

Colección de datos

En una primera etapa, se clasificó la información relevante. Para ello, se inició con la búsqueda y selección de datos, tanto oficiales como los del Plan de Desarrollo Urbano (2014), así como estadísticas socioeconómicas disponibles en portales gubernamentales (insumos generados desde la observación directa en plataformas como el Street View del caso de estudio, que es Polanco). Adicionalmente, se consideraron las capas espaciales en formato Shp, csv y proyecciones en formato TIFF, para estimar escenarios a futuro. La Tabla 1 presenta la síntesis de la clasificación detallada de las fuentes de datos utilizadas en un análisis territorial de la zona de Polanco, organizadas según el tipo de variable, el año de referencia, el formato y el programa utilizado para llevar a cabo un procesamiento asertivo. La gestión y análisis de estos datos se realizan principalmente en ArcMap, complementado con herramientas de Excel para el cálculo de variables derivadas como el potencial de crecimiento urbano y la diferencia en indicadores socioeconómicos entre 2010 y 2020. Esta estructura permite cruzar información espacial y temporal, integrando procesos de georreferenciación, modelación y cálculo manual para sustentar los análisis urbanos del estudio.

Una vez teniendo la recopilación de datos se identificaron 3,510 predios, de los cuales se reveló que **624** tuvieron un cambio en sus niveles durante el 2008 y 2022, lo que representa el **17.8%** del total, por lo cual se indica una mayor densificación. Este estudio corresponde a un periodo de 14 años. Aproximadamente, durante este tiempo se estima que 22 predios crecieron cada año. Con los mismos datos se logró identificar los predios que sobrepasaba el plan de desarrollo urbano del 2014. De los 3,510 predios, se identificó que **876 predios (24.9%)** sobrepasaron los niveles máximos de construcción; se encontraron patrones que demuestran que la mayoría de estas edificaciones fueron construidas años atrás del Plan de Desarrollo Urbano, o bien, en su caso fueron polígonos de actuación.

Se encontró un grupo significativo, y es el que denominamos **predio potencial**; de los 3,510 fueron **1,954 predios (55.7%)** los que tienen aún niveles de crecimiento, esto quiere decir que todavía tienen margen para crecer más en los próximos años, aumentando su densificación. Este es un dato muy relevante, ya que puede indicar que existe la oportunidad de expansión, lo que podría ser aprovechado para proyectos inmobiliarios.

Con los datos anteriores se puede analizar el crecimiento que hubo; sin embargo, en esta parte es necesario identificar los factores que hacen que se impulse este fenómeno para poder proyectar la densificación.

Tabla 1. Información de datos recopilados, archivo y procesamiento.

Fuente de datos	Variable	Año	Archivo	Programa procesamiento
Programa parcial de desarrollo urbano Polanco 2014	Uso de suelo	2014	Shp.	Arcmap
https://www.seduvi.cdmx.gob.mx/programas-parciales-de-desarrollo-urbano	Niveles máximos de construcción	2014	Shp.	Arcmap/ingresar datos manuales
	Año de construcción	Real	Csv.	Arcmap/integrar csv a capa PPDU
	Valor_Unitario	2014	Shp.	Arcmap/integrar csv
	Valor_Suelo			
	Sup_terreno	2014	Shp.	Arcmap/integrar csv
	Superficie de construcción			
Datos socioeconómicos	Indicadores socioeconómicos	2010, 2020	Shp.	Arcmap, Recorte de datos
https://datos.cdmx.gob.mx/dataset/tasa-de-crecimiento-medio-anual-2010-2020				
https://developers.google.com/earth-engine/datasets/catalog/JRC_GHS_L_P2023A_GHS_POP?hl=es-419	Proyección de datos socioeconómicos	2030	TIFF.	Arcmap Extraer datos
Street View Google	Uso de suelo	2008, 2022	manual	Arcmap/ingresar datos
https://www.google.com/intl/es-419_mx/streetview/	Niveles de construcción	2008	manual	Arcmap/ingresar datos
	Año de remodelación/construcción	2008, 2022	manual	Arcmap/ingresar datos
Variables calculadas	Potencial de crecimiento 1 (Niv. máx. - Niv. 2008)		manual	Excel/formula
	Potencial de crecimiento 2 (Niv. máx. - Niv. 2022)		manual	Excel/formula
	Diferencia de datos socioeconómicos (2010-2020)		manual	Excel /formula
	Diferencia de crecimiento poblacional entre (2008-2022)		manual	Excel/formula
	Diferencia de datos socioeconómicos (2020-2030)		manual	Excel/formula

Fuente: elaboración propia con base en datos recopilados.

Análisis estadístico y correlación de datos

Después de obtener los datos en ArcMap, se exportó la tabla de atributos y se convirtió en formato Excel para su posterior análisis. Utilizando Python, se

llevó a cabo un estudio de correlación con el objetivo de identificar las relaciones significativas entre las variables incluidas en la base de datos, como se muestra en el script 1 de la Figura 2. Inicialmente, se consideró un conjunto amplio de variables, abarcando diversas características de los predios analizados. A través del análisis estadístico, se determinaron los coeficientes de correlación entre las distintas variables, lo que permitió evaluar la fuerza y dirección de las relaciones existentes. Aquellas variables que mostraron una correlación débil o no significativa fueron descartadas progresivamente, optimizando así la selección de los factores más relevantes para el estudio.

```
import pandas as pd
import numpy as np
import statsmodels.api as sm
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import accuracy_score, classification_report

# Cargar los datos
df = pd.read_csv("datos.csv")

Y=df['predc'] # 1 si creció, 0 si no
X=df[['anio_const',
'DifDenPob','pot08v2']]

correlation_matrix = X.corr()
highly_correlated = correlation_matrix[correlation_matrix > 0.5]
print("Highly Correlated Features:\n", highly_correlated)

X_train, X_test, y_train, y_test = train_test_split(X, Y, test_size=0.2, random_state=42)

# Normalizar variables numéricas
scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)

scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)

X_train_sm = sm.add_constant(X_train_scaled)
X_test_sm = sm.add_constant(X_test_scaled)

from statsmodels.stats.outliers_influence import variance_inflation_factor

def calculate_vif(data):
    vif = pd.DataFrame()
    vif["features"] = data.columns
    vif["VIF"] = [variance_inflation_factor(data.values, i) for i in range(data.shape[1])]
    return vif

vif_data = calculate_vif(pd.DataFrame(X_train_scaled))
print("\nVIF Values:\n", vif_data)

logit_model = sm.Logit(y_train, X_train_sm)
result = logit_model.fit()

# Imprimir los coeficientes y significancia estadística
print(result.summary())
```

Figura 2. Script 1: coeficientes y significancia estadística. Fuente: elaboración propia con Python.

El proceso permitió depurar la base de datos y centrarse en los atributos con mayor impacto en la dinámica de crecimiento urbano, facilitando una interpretación más precisa de los patrones identificados en el estudio. Estas correlaciones fueron evaluadas mediante el Variance Inflation factor (VIF) para evitar la multicolinealidad.

Tabla 2. Información de variables y VIF.

Variable	VIF
Año de construcción	1.0038
Diferencia de densidad de vivienda	1.0008
Potencial de crecimiento	1.0037

Fuente: elaboración propia con base de datos de Python.

Como en la Tabla 2 los valores obtenidos de VIF son cercanos a 1, se concluyó que no hay problema de multicolinealidad entre estas variables. Por consiguiente, pasamos al siguiente script, donde realizamos la predicción con el conjunto de prueba (Figura 3).

```
# Hacer predicciones en el conjunto de prueba
y_pred_prob = result.predict(X_test_sm)
y_pred = (y_pred_prob >= 0.5).astype(int)

# Evaluación del modelo
print("Accuracy:", accuracy_score(y_test, y_pred))
print(classification_report(y_test, y_pred))

print(X_train_sm.shape)

coef_df = pd.DataFrame({"Variable": ['const'] + list(range(X_train_sm.shape[1]-1)), "Coeficiente": result.params})
print(coef_df)
```

Figura 3. Script 2: conjunto de pruebas. Fuente: elaboración propia con Python.

Tabla 3. Información contante, coeficiente.

Constante	P<[Z]	Coeficiente
Año de construcción	0.000	-0.0016
Diferencia de densidad de población	0.000	0.0122
Potencial de crecimiento 2008	0.000	0.7346

Constante de = -1.8119

Fuente: elaboración propia con base de datos de Python.

Como la Tabla 3 mostró resultados en $P > [Z]$ menores o igual 0.05, ello significa que los datos son relevantes. Por lo tanto, tenemos esos coeficientes obteniendo al de mayor significancia: la variable de Potencial de crecimiento 2008. Una vez obteniendo nuestros coeficientes, se utilizó la Regresión Logística para predecir la probabilidad de crecimiento vertical, usando la fórmula siguiente:

$$P(Y=1) = 1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}$$

Donde:

- **$P(Y=1)$** : es la probabilidad de que el evento ocurra (crecimiento vertical).
- **β_0** : es la constante del modelo.
- **$\beta_1, \beta_2, \dots, \beta_n$** : son los coeficientes de las variables.
- **$X_1, X_2, \dots, X_n$** : son las variables independientes.
- **e**: es la base del logaritmo natural.

Posteriormente, en Excel se agrega la siguiente formula:

$$\text{Predicción2030} = 1 / (1 + \text{EXP} (-(1.811939 - (\text{Año de construcción} * 0.08865) + (\text{Dif densidad poblacional 2030} * 0.347822) + (\text{Potencial de crecimiento 2022} * 0.579215)))$$

Dando como resultado la probabilidad calculada, y si es mayor o igual a 0.90, se considera que el edificio crecerá; de lo contrario permanece igual, conforme a los resultados visualizados en ArcMap, como se muestra en la Figura 4.




Figura 4. Proyección 2030 del crecimiento vertical en Polanco. Fuente: elaboración propia con base en datos obtenidos de la regresión logística.

A partir de un modelo de regresión logística, se identifican los predios que muestran una probabilidad significativa de experimentar procesos de densificación mediante la construcción en altura. Las áreas resaltadas en color rojo corresponden a aquellos lotes donde se estima que existe una alta posibilidad de transformación vertical en el mediano plazo, mientras que los predios en color azul claro indican zonas donde, según el modelo, no se prevé crecimiento vertical. Esta representación cartográfica permite visualizar con claridad los patrones espaciales de transformación urbana, destacando las zonas más propensas a modificaciones estructurales en su configuración morfológica.

La distribución no es homogénea: se observa una concentración de probabilidad de crecimiento en los bordes y en ciertas franjas interiores, lo que sugiere una relación directa entre los niveles actuales de edificación, la disponibilidad de suelo, las condiciones normativas y la presión inmobiliaria. Esta proyección se convierte en una herramienta clave para anticipar escenarios urbanos y orientar la planeación territorial con base en evidencia empírica.

Cálculo de niveles esperados en 2030

Una vez teniendo los resultados de qué edificios crecerán, es importante visualizar cuántos pisos harán los mismo. Para calcular los niveles esperados para 2030 se usó una regresión lineal múltiple, como en el script de las Figuras 5 y 6, donde el script, desarrollado en Python, ilustra la primera etapa del análisis: la carga de bibliotecas esenciales como *pandas*, *numpy*, *statsmodels* y módulos de *sklearn*, los cuales permiten realizar la división de datos para entrenamiento y prueba, así como aplicar el modelo de regresión. Esta parte del proceso técnico establece la base para la modelación predictiva, integrando variables cuantitativas que explican los niveles constructivos esperados bajo escenarios normativos, económicos o espaciales futuros.

```
import pandas as pd
import numpy as np
import statsmodels.api as sm
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression

# Cargar los datos
df = pd.read_csv("niveles.csv")
```

Figura 5. Script 3. Cargar datos. Fuente: elaboración propia con Python.

Después se crea la variable de crecimiento observado entre 2008 y 2022 (los niveles de pisos que crecieron) para que este instrumento sea un buen predictor, manteniéndolo como un dato histórico, para después entrenar el modelo.

Se seleccionan las variables independientes (año de construcción, diferencia de densidad poblacional y potencialidad entre 2008 y 2024) y la variable dependiente (crecimiento entre 2008 y 2022).

Figura 6. Script 4. Cálculo de niveles para 2030. Fuente: elaboración propia con Python.

```
df['crecimiento_2008_2024'] = df['N94'] - df['N08']
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression

# Variables predictoras (independientes)
X = df[['anio_const', 'difden', 'pot08v2']]

# Variable objetivo (dependiente) = Cuántos pisos crecieron entre 2008 y 2024
y = df['crecimiento_2008_2022']

# Dividir en datos de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Crear el modelo de regresión lineal
modelo = LinearRegression()

# Entrenar el modelo
modelo.fit(X_train, y_train)

# Predecir el crecimiento entre 2024 y 2030
df['prediccion_crecimiento_2024_2030'] = modelo.predict(X)

# Calcular niveles en 2030
df['niveles_2030_pred'] = df['N94'] + df['prediccion_crecimiento_2024_2030']
```

Tabla 4. Información de constante, coeficiente.

Constante	P>[Z]	Coeficiente
Año de construcción	0.000	-0.0016
Diferencia de densidad de población	0.000	0.0122
Potencial de crecimiento 2008	0.000	0.7346

Fuente: elaboración propia con base a datos de Python.

Como la Tabla 4 mostró resultados en P>[Z] menores a 0.00, esto significa que los datos son relevantes. Por lo tanto, tenemos esos coeficientes obteniendo al de mayor significancia, la variable de Potencial de crecimiento 2008, siguiendo la siguiente fórmula de la regresión lineal múltiple:

$$Y=\beta_0+\beta_1X_1+\beta_2X_2+\beta_3X_3+...+\beta_nX_n$$

Donde:

- **Y** = es la variable dependiente (niveles proyectados en 2030).
- **β_0** = es la constante o intercepto del modelo.
- **$\beta_1, \beta_2, \beta_3, \dots, \beta_n$** = son los coeficientes de regresión obtenidos.
- **$X_1, X_2, X_3, \dots, X_n$** = son las variables independientes utilizadas en el modelo.

En Excel se coloca la siguiente fórmula:

$$\text{Número de niveles} = (-1.8119) + (-0.001215 * (\text{Año de construcción} / 2000)) + (0.034173 * \text{Dif densidad poblacional 2030}) + (0.592356 * \text{Potencial de crecimiento 2022})$$

Los resultados mostraron decimales, por lo tanto, aplicamos la siguiente fórmula en otra celda para poder redondear el resultado:

$$\text{Total, de niveles} = \text{número de pisos 2022} + \text{ROUND}(\text{Número de niveles}, 0)$$

A partir de estos valores aplicamos el límite de construcción basado en la normativa urbana:

$$\text{Total de niveles con normativa} = \text{MIN}(\text{Niveles máximo de construcción} - \text{Total de niveles})$$




Figura 7. Número de niveles de acuerdo con los predios proyectados al 2030 en Polanco. Fuente: elaboración propia con base en datos obtenidos de la regresión lineal múltiple.

Por último, a partir de ArcScene y para tener un resultado más claro obteniendo una vista en 3D, se procedió a pasar la capa con la información; y se elevaron los resultados en propiedades de la capa, multiplicándose por 3.2, semejando la altura de cada nivel de piso proyectado para 2030, colocando un color rojo al cambio. También se agregaron otras capas, como las alturas de la alcaldía Miguel Hidalgo para una mejor visualización, y los predios sin crecimiento (Figura 7).

Resultado con modelado 3d de la proyección

Tras el análisis de los datos se logró identificar que el primer periodo de tiempo, entre 2008 y 2022, reveló que de 3,510 predios, 624 tuvieron crecimiento en un periodo de 14 años. Para la proyección de 2030 se tomaron los datos de la proyección de densidad de crecimiento poblacional que nos indica una densidad más alta que la que hubo entre el anterior periodo; por lo tanto, de esos 3,510 predios, 1,066 **presenta una posibilidad de cambio**. Como se mostró anteriormente, la correlación de variables demuestra que si el año de construcción es más antiguo, y sobre todo el predio tiene potencial para construir más niveles, existe una mayor probabilidad de densificación (Figuras 8, 9 y 10).



Figura 8. Gráfico de resultado de datos. Fuente: elaboración propia.

Gráfico de datos




Figura 9. Crecimientos proyectados al 2030 en Polanco, perspectiva A. Fuente: elaboración propia con ArcScene.



Figura 10. Crecimientos proyectados al 2030 en Polanco perspectiva B. Fuente: elaboración propia con ArcScene.

Discusión y reflexiones finales

La primera información recolectada permite visualizar la densificación que existió entre el periodo de 2008 al 2022. Se identificó que la mayoría de estos resultados que tuvieron potencialidad eran casas, ya sea que solo se aumentaba un predio, o que se integraban más predios para crear principalmente edificios.

La densificación es una buena estrategia para lograr una ciudad más compacta sin necesidad de estar desplazándose, pues todos los edificios tienen un ciclo de vida, y estos se adaptan a la necesidad contemporánea de vivienda; por el contrario, la parte urbana no va de la mano con esta misma transición. Actualmente el caso estudio cuenta con problemas como la congestión vehicular y problemas de ruido. Se ha identificado también escasez de agua (situación que ha derivado en problemas de presión en las redes de distribución).

Dentro de la política urbana, el Plan de Desarrollo Urbano puede ser modificado, siempre y cuando esto se haga bajo ciertas condiciones. Dichas modificaciones se realizarían bajo la justificación de nuevas necesidades sociales, densidad poblacional o temas ambientales. Para ello, esta herramienta tiene como propósito que las proyecciones y las simulaciones puedan prever los problemas urbanos.

Cuando una zona en particular se ve en la necesidad de densificar, será posible simular los escenarios posibles y lograr una infraestructura que responda al plan de desarrollo urbano que se quiera proyectar, generando un modelo digital de la ciudad. De esta forma, la infraestructura responderá a las necesidades humanas.

Tras el desarrollo de este estudio se evidenció un incremento en la densificación urbana en el periodo histórico analizado. Aumentó de 624 predios, con potencial de crecimiento entre los 3,510 predios estudiados. A partir de la proyección realizada, se prevé que para el año 2030 esta cifra podría alcanzar aproximadamente 1,066 predios. Sin embargo, en esta proyección los predios con uso de suelo destinado a equipamiento no fueron eliminados del análisis, lo cual reduce la probabilidad de densificación de dichos predios. La herramienta basada en geografía automatizada es eficaz para detectar patrones y áreas propicias para la densificación. A nivel general, este trabajo aporta a la disciplina de la Geomática el aplicar un enfoque automatizado dentro del análisis territorial, ofreciendo una solución técnica y replicable para apoyar procesos de planeación urbana sostenible.

Cabe destacar que, si en el futuro se produjera un crecimiento poblacional acelerado u otra variable anteriormente mencionada que afecte directamente al desarrollo del crecimiento vertical, los resultados podrían variar. Sin embargo, esto sería útil, pues permitiría simular distintos escenarios con estas modificaciones de variable, y anticipar posibles comportamientos bajo ciertas condiciones.

Referencias

- Bazant, J. (2010). Expansión urbana incontrolada y paradigmas de la planeación urbana. *Espacio Abierto*, 19(3), 475–503. <https://www.redalyc.org/pdf/122/12215112003.pdf>
- Buzai, G., y Montes E. (2021). *Estadística Espacial: Fundamentos y aplicación con Sistemas de Información Geográfica*. Instituto de Investigaciones Geográficas. <https://ri.conicet.gov.ar/handle/11336/161048>
- Chakraborty, S., Dadashpoor, H., Novotný, J., Maity, I., Follmann, A., Patel, P. P., ... y Pramanik, S. (2022). In pursuit of sustainability – Spatio-temporal pathways of urban growth patterns in the world's largest megacities. *Cities*, 131, 103919. <https://doi.org/10.1016/j.cities.2022.103919>

- Chaparro, J. J. G. (2009). Planeación urbana en México: un análisis crítico sobre su proceso de evolución. *Urbano*, 47–63. <https://www.redalyc.org/pdf/198/19811644008.pdf>
- Chaparro, J. J. G. (2014). Planeación Urbana: crítica y tendencias desde el campo de la Teoría. El caso del estado de México. *Bitácora Urbano Territorial*, 24(1), 19–26. <https://www.redalyc.org/pdf/748/74830875003.pdf>
- De Mattos, C., Fuentes, L., y Link, F. (2014). Tendencias recientes del crecimiento metropolitano en Santiago de Chile. ¿Hacia una nueva geografía urbana? *Revista INVI*, 29(81), 193–219. <https://revistainvi.uchile.cl/index.php/INVI/article/view/62589>
- Gutiérrez, A. (2024). Conoce Polanco: Historia, ubicación, qué hacer y más. GDC Desarrollos. <https://gdcdesarrollos.com/blog/conoce-polanco-historia-ubicacion-que-hacer-y-mas/>
- Hernández Sampieri, R. (2014). Metodología de la investigación (3.ª ed.). McGraw-Hill Education. https://apiperiodico.jalisco.gob.mx/api/sites/periodicooficial.jalisco.gob.mx/files/metodologia_de_la_investigacion_-_roberto_hernandez_sampieri.pdf
- López, L. (2021). Un modelo de crecimiento urbano vertical con factores característicos basado en inteligencia artificial (Tesis de maestría). Universidad Autónoma del Estado de México. <http://hdl.handle.net/20.500.11799/112219>
- Mena, F. C. (2024). Planeación urbana ¿para qué proyecto de la Ciudad de México? Universidad Autónoma Metropolitana (México). <https://doi.org/10.24275/uama.5916.10760>
- Sarasola, J. (2024). Densificación urbana. Ikusmira.org. <https://www.ikusmira.org/densificacion-urbana>
- Sarmiento, Y. (1999). Algunas causas y evolución de la renovación urbana por densificación en Colombia. *Bitácora Urbano Territorial*, 11. https://www.researchgate.net/publication/50407219_Algunas_causas_y_evolucion_de_la_renovacion_urbana_por_densificacion_en_Bogota
- Secretaría de Desarrollo Urbano y Vivienda (SEDUVI). (2014). Programa parcial de desarrollo urbano Polanco. <https://www.seduvi.cdmx.gob.mx/programas/programa/programas-parciales-de-desarrollo-urbano-ppdu>
- Sierra Ríos, G. D. (2024). Estrategias de planeación urbana: Sincelejo como modelo de ciudad-región en el contexto de la globalización. *Journal of Scientific Metrics and Evaluation*, 2(1), 13–31. <https://journalsme.com/index.php/home/article/view/>
- Vicuña del Río, M. (2017). Impacto de la densificación residencial intensiva en la segmentación del tejido urbano de Santiago: Un enfoque cuantitativo. *Revista 180*, (40). <https://revista180.udp.cl/index.php/revista180/article/view/399>

- Yang, C., y Zhao, S. (2022). Urban vertical profiles of three most urbanized Chinese cities and the spatial coupling with horizontal urban expansion. *Land Use Policy*, 113, 105919. <https://doi.org/10.1016/j.landusepol.2021.105919>
- Zhao, C., He, Z., y Hersperger, A. M. (2025). How do planning intentions spatiotemporally drive 3-D urban growth? *Habitat International*, 157, 103307. <https://doi.org/10.1016/j.habitatint.2025.103307>

Capítulo IV. Percepción remota en el análisis de la dispersión urbana en zonas costeras. Clasificación supervisada de imágenes satelitales

Rogelio Contreras González¹

*Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),
Unidad Tecamachalco. Naucalpan, Estado de México.*

Resumen

La presente investigación analiza la dispersión urbana causada por el turismo residencial en zonas costeras mediante el uso de herramientas avanzadas de percepción remota, como Google Earth Engine, y el uso de sistemas de información geográfica como ArcGIS para el manejo de datos espaciales. Adicional a esto, el uso de Chat GPT fue clave en la estructuración del análisis y en el desarrollo del código para la reclasificación de imágenes satelitales. Para ello, se mapearon las viviendas de uso temporal con datos de Airbnb y Google Maps, evaluando su relación con el crecimiento urbano en la localidad de Todos Santos, Baja California Sur. Por último, la conversión de imágenes ráster a polígonos permitió un análisis detallado de patrones espaciales, logrando observar una relación espacial directa, y confirmando la expansión urbana dispersa vinculada a la oferta de viviendas de uso temporal para alojamiento turístico.

Palabras clave: dispersión, percepción remota, Google Earth Engine.

Abstract

This research analyzes urban sprawl caused by residential tourism in coastal areas through the use of advanced remote sensing tools such as Google Earth Engine and geographic information systems like ArcGIS for spatial data management. Additionally, the use of ChatGPT was key in structuring the analysis and developing the code for satellite image reclassification. To achieve this, temporary-use housing was mapped using data from Airbnb and Google Maps, evaluating its relationship with urban growth in the town of Todos Santos, Baja California Sur. Finally, the conversion of raster images into polygons enabled a detailed analysis of spatial patterns, allowing the identification of a direct spatial relationship and confirming dispersed urban expansion linked to the supply of temporary housing for tourist accommodation.

Keywords: sprawl, remote sensing, Google Earth Engine.

¹ Maestrante en Ciencias en Arquitectura y Urbanismo, Ingeniero Arquitecto por el Instituto Politécnico Nacional, ESIA, Tecamachalco, y consultor independiente en programas de desarrollo urbano y planes maestros. Correo: arq.roycg@gmail.com, rcontrerasg2200@alumno.ipn.mx, ORCID: <https://orcid.org/0009-0000-8405-8186>

Introducción

El turismo residencial ha cobrado un papel cada vez más relevante en la transformación del paisaje urbano, especialmente en localidades costeras que combinan belleza natural, oferta turística y potencial inmobiliario. Más allá del turismo convencional, esta modalidad implica la presencia temporal y/o recurrente de visitantes que adquieren o alquilan viviendas para estadias con fines turísticos, lo que influye directamente en la forma en que las ciudades crecen (Daniel Hiernaux Nicolas, 2005).

En el caso de la dispersión urbana, es importante establecer que se entiende como una falta de concentración de viviendas (Audirac, Shermeyen, y Smith, 1990), y que dicho fenómeno dificulta la planeación ordenada de las ciudades (Ewing, 1997) y la distribución equitativa de servicios públicos (Downs, 1999).

En el caso del municipio de La Paz, Baja California Sur, este fenómeno se ha hecho evidente, ya que entre 2010 y 2020, el número de viviendas de uso temporal creció más de 55% respecto al total de viviendas registradas (INEGI, 2010; 2020). Este dato no solo refleja una transformación demográfica, sino también una presión constante sobre la estructura urbana y el turismo tradicional.

Aunque en Europa ya se han realizado estudios que exploran cómo el turismo residencial influye en la dispersión urbana, aplicar esas mismas metodologías en contextos mexicanos no siempre resulta correcto. Las condiciones geográficas, la legislación urbana, los patrones de desarrollo y las dinámicas sociales propias del país hacen necesario adaptar las herramientas y enfoques a la realidad local.

En este capítulo se plantea un enfoque metodológico que busca atender la necesidad de entender cómo se presenta la dispersión urbana en ciudades costeras mexicanas a partir de la presencia del turismo residencial; es decir, de viviendas de uso temporal. También plantea cómo hacerlo con herramientas que permitan identificar el fenómeno urbano.

Para ello, se propone el uso de plataformas como Google Earth Engine y ArcGIS, que ofrecen capacidades avanzadas de análisis espacial y manejo de datos georreferenciados. Al combinar estas herramientas y poder observar las relaciones entre los patrones de crecimiento y la ubicación de las viviendas de uso temporal, se espera aportar evidencia del fenómeno y contribuir en las discusiones sobre cómo deben planificarse las ciudades costeras frente a este tipo de presiones.

Metodología general

El presente estudio adopta un enfoque cuantitativo basado en las metodologías de la geografía cuantitativa; geografía que Buzai y Montes (2021) mencionan como una corriente que utiliza herramientas matemáticas

y estadísticas para analizar patrones espaciales y su relación con variables geográficas a través de Sistemas de Información Geográfica (SIG).

Como se mencionó en el párrafo anterior, la geografía cuantitativa se basa en datos estadísticos, por lo cual se emplearon datos del Censo de Población y Vivienda 2010 y 2020 del INEGI, los cuales fueron complementados con información extraída de plataformas digitales, como Airbnb, que es la principal plataforma para renta de viviendas vacacionales en México y Google Maps.

Estas fuentes alternativas de información permitieron una ubicación más precisa de las viviendas de uso temporal, ya que la propia plataforma de Airbnb no permite visualizar la ubicación exacta de las propiedades hasta que se confirme una reservación, esto por políticas de privacidad de datos personales de los usuarios.

La metodología general utilizada en esta investigación se basa en el análisis espacial mediante Sistemas de Información Geográfica (SIG) que fue aplicado a la zona de estudio. Como lo mencionan Buzai y Montes (2021), el análisis espacial es un análisis cuantitativo y sistémico que permite identificar patrones en el espacio de la zona de estudio con el objetivo de examinar la evolución del uso del suelo con respecto al crecimiento urbano y la demanda turística de viviendas de uso temporal.

Además de lo anterior, es importante resaltar que la investigación es “no experimental”, pues se analizan los datos en su contexto natural sin manipulación de variables, como lo indican Hernández Sampieri, Fernández Collado y Baptista Lucio (2014). En esta investigación se observan los patrones espaciales resultantes del turismo residencial, es decir, las viviendas de uso temporal georreferenciadas y su impacto en la dispersión urbana sin ningún tipo de manipulación externa.

También es importante mencionar que el estudio tiene un enfoque transversal, centrado únicamente en el periodo 2020-2024, con el objetivo de encontrar la selección de una imagen satelital representativa para analizar el fenómeno en un momento específico (Hernández Sampieri, Fernández Collado y Baptista Lucio, 2014).

Por último, el estudio sigue un enfoque de asociación espacial, ya que se analizan diferentes capas que conviven en el mismo espacio geográfico (Buzai y Montes, 2021), con el objetivo de identificar relaciones entre el incremento de viviendas de uso temporal y la expansión urbana en el área de estudio.

Metodología de las variables

Para analizar el impacto del turismo residencial, es decir, las viviendas de uso temporal en el desarrollo urbano, se llevó a cabo una búsqueda y recopilación de información sobre la ubicación de las viviendas ofertadas en Airbnb (<https://www.airbnb.mx/>) (Figura 1), la plataforma líder en la renta de alojamientos temporales en México. Esta plataforma, ampliamente utilizada por turistas que

buscan estancias flexibles, y por propietarios interesados en obtener ganancias de sus inmuebles, fue la herramienta principal de localización de la información necesaria para esta investigación, ya que a través de su página de internet es posible identificar la oferta de viviendas en la zona de estudio.

Sin embargo, una de las principales limitaciones al utilizar Airbnb como fuente de datos, es la política de seguridad y privacidad que protege a aquellos que ofrecen sus propiedades en renta, restringiendo la ubicación exacta de las propiedades listadas hasta tener una reserva confirmada. En su lugar, la plataforma proporciona una localización aproximada de cada vivienda, la cual se representa en un mapa interactivo disponible en su página de internet.

Esta restricción impide conocer la dirección exacta de cada inmueble, lo que genera desafíos en el análisis espacial del fenómeno, por lo cual, para mitigar esta limitación y mejorar la calidad de los datos obtenidos, se complementó con otras fuentes la información proporcionada por Airbnb.




Figura 1. Captura de pantalla del sitio web de AIRBNB de las cuatro zonas de estudio.

Fuente: tomada el 23 de junio de 2024, de <https://www.airbnb.com/>

Para mejorar la precisión en la localización de las viviendas de uso temporal dentro del área de estudio, se llevó a cabo una búsqueda complementaria a través de Google Maps, es decir, se incluyó la integración de datos de esta plataforma mediante herramientas de Sistemas de Información Geográfica (SIG). Es importante mencionar que la búsqueda de viviendas en renta en Google Maps se filtró para evitar todos los inmuebles relacionados con el turismo tradicional (hoteles, moteles, posadas, etc), para únicamente incluir datos de viviendas completas en renta. Esta plataforma permitió obtener información más detallada sobre la ubicación de las propiedades, mejorando la calidad de

los datos recopilados y proporcionando una base más sólida para el análisis espacial del turismo residencial.

Adicional a lo anterior, se realizó una validación visual de las propiedades detectadas en imágenes satelitales por medio de vistas a nivel de calle disponibles en *Google Street View*, lo que permitió corroborar la veracidad de la información y descartar posibles inconsistencias en la geolocalización (Figura 2).




Figura 2. Captura de pantalla del sitio web de Google Maps de la zona de estudio.

Fuente: tomada el 23 de junio de 2024, de <https://www.google.com/maps>

Para lograr la georreferenciación de las viviendas de uso temporal, se realizó un análisis espacial de localización, donde, como lo mencionan Buzai y Montes (2021), “todas las entidades (con sus atributos asociados) tienen una ubicación específica en el espacio geográfico, es decir, que se encuentran sobre la superficie terrestre”.

Para ello, las imágenes obtenidas en la plataforma de Airbnb y Google Maps fueron importadas y analizadas en el software ArcGIS, donde se aplicaron herramientas de análisis espacial para tener, con mayor precisión, la ubicación de las viviendas de uso temporal identificadas.

Para realizar este proceso, se llevó a cabo la georreferenciación de las viviendas utilizando la herramienta *georeferencing* de ArcGIS, la cual permite asignar puntos de control entre las imágenes satelitales, y puntos de referencia de capas ya georreferenciadas (Figura 3). Este procedimiento aseguró una mayor precisión en la localización de las viviendas de uso temporal, permitiendo una integración más rigurosa de los datos y facilitando su análisis dentro del contexto de la dispersión urbana en la región.

Esta metodología ayudó a la creación de un conjunto de datos más sólido y confiable, para evaluar de manera más exacta el impacto del turismo residencial, es decir, las viviendas de uso temporal en el crecimiento y desarrollo urbano de la zona de interés.




Figura 3. Georreferenciación con imágenes satelitales. Fuente: captura de pantalla de ArcMap, (2024).

Ahora bien, para el análisis de la dispersión urbana se solicitó al Instituto Municipal de Planeación (IMPLAN) de La Paz la información cartográfica correspondiente a las manzanas que conforman las manchas urbanas dentro de la zona de estudio. Estos datos fueron entregados en formato *Shapefile* (.shp) con el propósito de ser visualizados en el software ArcMap, para permitir así la ejecución de diversos geoprocursos para determinar la presencia o ausencia de dispersión urbana. Sin embargo, al revisar y analizar la información proporcionada, se identificó que las capas cartográficas presentaban un grado considerable de desactualización.

A través de la comparación con imágenes satelitales recientes, se evidenció la existencia de nuevas construcciones en áreas que no estaban mapeadas en los archivos *Shapefile*, lo que generó inconsistencias en la representación espacial de la urbanización. Esta situación resaltó la necesidad de complementar los datos oficiales con herramientas de percepción remota para obtener una visión más precisa y actualizada de la expansión urbana dentro de las zonas de estudio.

Es por esto que se recurrió a la clasificación supervisada de imágenes satelitales con *Google Earth Engine*, la cual es una metodología ampliamente utilizada en teledetección y análisis geoespacial para separar y categorizar áreas

dentro de una imagen satelital en clases específicas, de acuerdo con patrones previamente definidos. Este proceso semi automático se basa en la selección de muestras de entrenamiento y comprobación, las cuales representan diferentes tipos de cobertura terrestre; en este caso, áreas construidas, cuerpos de agua, vegetación, suelo desnudo, etc.

El proceso que utiliza el motor de *Google Earth Engine* se realiza mediante el uso de algoritmos de aprendizaje automático, los cuales hacen que el sistema analice características espectrales de los píxeles dentro de las muestras de entrenamiento, y construyen un modelo predictivo que permite clasificar el resto de la imagen. De este modo, cada píxel es analizado y asignado a una categoría determinada con anterioridad, obteniendo una representación cartográfica desglosada de la categorización del territorio.

Para llevar a cabo lo descrito en el párrafo anterior, fue necesario el desarrollo de un código en lenguaje *Python*, el cual es el lenguaje utilizado por el motor de *Google Earth Engine*. Dicho código está diseñado para realizar las actividades de reclasificación mencionadas, y fue elaborado con ayuda de herramientas tecnológicas de inteligencia artificial, en este caso con ayuda de Chat GPT (Figura 4).

Uno de los primeros pasos del código elaborado es determinar un área de interés específica, representada por un archivo *Shapefile* cargado desde la colección de archivos en *Google Earth Engine*. Este *Shapefile* delimita la región de estudio y, bajo esta dinámica, representa el polígono en el cual se aplica el Programa Subregional de Desarrollo Urbano vigente en la región.


Posteriormente se realizó la búsqueda de la mejor imagen disponible de la zona para realizar la reclasificación; para ello se utilizaron imágenes satelitales de Landsat 8 (LANDSAT/LC08/C02/T1_L2), ya que estas ofrecen una resolución óptima para la identificación de las distintas categorías establecidas (30 x 30 metros).

Este conjunto de datos fue filtrado por:

- Región: con base en el *Shapefile* del área de interés.
- Periodo: del 1 de enero de 2020 al 30 de abril de 2024.
- Bandas espectrales:
 - Se seleccionaron bandas específicas (SR_B2, SR_B3, SR_B4, SR_B5, SR_B6, SR_B7) para el análisis.

La selección de bandas responde a la formación de la imagen en formato RGB y en color natural, ya que la banda azul (SR_B2) ayuda a identificar cuerpos de agua, la banda verde (SR_B3) permite observar la vegetación, la banda roja (SR_B4) es útil para diferenciar entre áreas con vegetación y sin ella, la banda infrarrojo cercano (SR_B5) se emplea para confirmar la presencia de vegetación sana y, por último, las bandas de infrarrojo de onda corta (SR_B6 y SR_B7)

permiten identificar zonas con humedad, áreas quemadas o con vegetación seca, ya que debido al entorno desértico de la zona de Baja California Sur es muy común la presencia de vegetación seca (Figura 4).



```
TS_2024
Get Link Save Run Reset Apps
1 // Define el área de interés
2 var myShapefile = ee.FeatureCollection('projects/arqroycg/assets/PB_Todos_Santos');
3 // Visualiza el área de interés en el mapa
4 Map.centerObject(myShapefile);
5 Map.addLayer(myShapefile, {color: 'red'}, 'AOI');
6 // Carga el conjunto de datos de imágenes de Sentinel-2 y filtrar por fecha y área
7 var dataset = ee.ImageCollection('COPERNICUS/S2_SR')
8   .filterBounds(myShapefile)
9   .filterDate('2023-01-01', '2024-04-30');
10 // Agrega una propiedad de porcentaje de nubes para cada imagen del periodo seleccionado
11 var withCloudiness = dataset.map(function(image) {
12   var cloudiness = image.select('SCL').eq(3).or(image.select('SCL').eq(9)).reduceRegion({
13     reducer: ee.Reducer.mean(),
14     geometry: myShapefile,
15     scale: 30,
16     maxPixels: 1e9
17   });
18   return image.set('cloudiness', cloudiness.get('SCL'));
19 });
20 // Selecciona la imagen con la menor cobertura de nubes
21 var leastCloudy = withCloudiness.filter(ee.Filter.lt('cloudiness', 0.1)).sort('cloudiness').first();
22 // Obtiene la fecha de la imagen seleccionada para su uso
23 var date = leastCloudy.date().format('YYYY-MM-dd').getInfo();
24 // Definir las bandas a utilizar
25 var bands10m = ['B2', 'B3', 'B4', 'B8']; // Bandas de 10 metros
26 var bands20m = ['B5', 'B6', 'B7', 'B8A', 'B11', 'B12']; // Bandas de 20 metros
27 // Seleccionar las bandas de 10 metros y reescalar las de 20 metros
28 var selected10m = leastCloudy.select(bands10m);
29 var selected20m = leastCloudy.select(bands20m).resample('bilinear').reproject({
30   crs: selected10m.projection().crs(),
31   scale: 10
32 });
33 // Combina las bandas de 10m y 20m reescaladas en una sola imagen
34 var combinedBands = selected10m.addBands(selected20m);
35 // Carga las muestras de entrenamiento desde tus assets
36 var trainingFeatures = ee.FeatureCollection('projects/arqroycg/assets/ENT_TS_2024_V3');
37
38 // Prepara las muestras de entrenamiento muestreando las bandas necesarias
39
```

Figura 4. Código elaborado en R para el ejercicio de reclasificación. Fuente: captura de pantalla de Google Earth Engine, (2024).

Ahora bien, para reducir la interferencia causada por la presencia de nubes y asegurar una representación más clara y homogénea del área de estudio, se estableció un porcentaje máximo de presencia de nubes en la imagen satelital, siendo del 30% como máximo. Posteriormente se calculó la mediana de las imágenes satelitales filtradas en el periodo establecido. Este procedimiento permitió generar una imagen compuesta más representativa y estable, minimizando el impacto de la nubosidad en la zona.

Para finalizar las actividades iniciales de la reclasificación, la imagen resultante fue recortada al área de interés mediante la función *clip*, asegurando que solo se trabajaran las zonas que se encuentran dentro del área definida por el polígono del *Shapefile*.

El siguiente paso es comenzar con el entrenamiento del código; para ello, las muestras de entrenamiento, que corresponden a distintas categorías establecidas, fueron importadas desde un archivo *Shapefile* y cruzadas con la imagen elaborada, basada en el paso anterior para extraer los valores espectrales asociados a cada categoría. Este paso es crucial para alimentar el modelo de clasificación supervisada, ya que permite que los algoritmos de aprendizaje automático identifiquen patrones específicos y puedan determinar la categoría del resto de la imagen satelital.

Los polígonos de entrenamiento determinan seis categorías principales: zonas construidas, arroyos, terreno natural, vegetación, vialidades y zonas agrícolas (Figura 5).




Figura 5. Polígonos de entrenamiento y comprobación (Todos Santos–El Pescadero, 2020-2024). Fuente: captura de pantalla de ArcMap, (2024).

Para realizar la reclasificación de las categorías mencionadas, el código implementó dos clasificadores: *Random Forest* y Distancia Mínima, con el objetivo de categorizar los distintos píxeles de la imagen satelital elegida dentro de la zona de estudio. Cada uno de los clasificadores realiza acciones específicas: el *Random Forest* toma ejemplos de cada tipo de cobertura (como vegetación, agua, suelo, etc.) y, con base en muchos árboles de decisión, categoriza a qué clase pertenece cada píxel de la imagen; por su parte, la Distancia Mínima compara el color de cada píxel con los ejemplos que se le dieron en el entrenamiento, y lo clasifica según a cuál se parece más y a cuál tiene más cerca a su alrededor.

La imagen compuesta fue clasificada con ambos modelos, produciendo dos mapas categorizados:

- Clasificación con *Random Forest*.
- Clasificación con Distancia Mínima.

Estas clasificaciones se visualizaron en el mapa mediante una paleta de colores definida.

Las imágenes clasificadas se exportaron en formato GeoTIFF, con los siguientes parámetros:

- Resolución espacial: 30 metros, definida por la resolución original de la imagen satelital.
- Región: área definida por el *Shapefile*.

Para complementar el análisis, se generó una visualización en color natural, utilizando las bandas espectrales correspondientes (SR_B4, SR_B3, SR_B2), las cuales corresponden a la visualización RGB. Esta imagen también fue exportada como GeoTIFF con los mismos parámetros de resolución y región.

Por último, se cargaron las muestras de verificación desde un archivo *Shapefile*, y se evaluaron los clasificadores entrenados con estas muestras mediante el cálculo de matrices de confusión y exactitudes globales.

Una vez finalizado el proceso de reclasificación en *Google Earth Engine*, la imagen en formato GeoTIFF se convirtió en polígonos mediante el uso de ArcGIS, aplicando la herramienta *Raster to Polygon*. Este procedimiento permitió convertir la información clasificada en un formato vectorial, facilitando su manipulación y análisis dentro de un entorno SIG.

El principal objetivo de esta conversión fue generar una capa en formato *Shapefile* que pudiera ser utilizada para obtener información cuantitativa, como lo es la medición de superficies, distancias, densidades y distribuciones espaciales de las distintas clases de cobertura terrestre identificadas en el análisis, en especial de la categoría “zonas construidas” (Figura 6).



Figura 6. Conversión de imagen reclasificada a polígonos en ArcGIS (Todos Santos–El Pescadero, 2020-2024). Fuente: captura de pantalla de ArcMap, (2024).

Después de la conversión de las imágenes ráster a polígonos, se realizó una revisión de los resultados obtenidos en el análisis inicial, debido a que, como se ha mencionado, el entorno desértico de la zona de estudio dificulta la reclasificación en distintas zonas; sin embargo, durante esta etapa se identificaron y corrigieron dichos errores derivados de la clasificación automática de los píxeles en *Google Earth Engine*, los cuales generaban polígonos incorrectos.

Estas inconsistencias fueron particularmente notorias en cauces de arroyos y zonas de playa, donde las características naturales del terreno presentan un color casi blanco, el cual es confundido con “zonas construidas”, e influyeron en

la similitud de los valores espectrales, dificultando una correcta diferenciación de las categorías establecidas.

Es por ello que, para mejorar la precisión del análisis, se llevó a cabo un proceso de limpieza y depuración de datos, eliminando los polígonos erróneamente clasificados que no representaban la realidad del área de estudio.

Este paso resultó fundamental para garantizar la validez de los resultados y fortalecer la exactitud del modelo, asegurando una representación más confiable de las distintas coberturas terrestres en la región, ya que, como se mencionó en el párrafo anterior, las zonas que fueron erróneamente clasificadas eran muy evidentes, por lo cual el ejercicio de limpieza no presentó un gran reto.

Por último, se efectuó la superposición espacial entre las capas de los polígonos de la imagen reclasificada y la capa de las ubicaciones georreferenciadas de las viviendas de uso temporal, previamente mapeadas.

Este cruce de información permitió identificar patrones de distribución, evaluar si existe una relación significativa entre la ubicación de estas viviendas y la expansión urbana, y determinar si su presencia incide en el crecimiento disperso de las localidades analizadas (Figura 7).

Resultados

Como resultado del proceso metodológico aplicado a lo largo de este capítulo, se obtuvo un mapa que refleja de manera clara el comportamiento del crecimiento urbano en la zona de estudio.

Esta representación espacial no solo muestra la expansión de la mancha urbana, sino que también permite identificar la dirección y el patrón que ha seguido dicho crecimiento en los últimos años. Lo más notable al observar el mapa es que la urbanización se ha extendido principalmente hacia los sectores norte y sur, alejándose progresivamente del centro consolidado de la localidad, lo que se interpreta como una dispersión urbana clara.

Este fenómeno de dispersión urbana adquiere mayor relevancia cuando se superpone la ubicación de las viviendas de uso temporal; al hacerlo, se evidencia una relación considerable entre las zonas de crecimiento disperso y la presencia de este tipo de viviendas, de nuevo principalmente en las zonas norte y sur de los centros de población originales, lo que sugiere una posible relación entre la demanda de alojamiento turístico y la ocupación de nuevos espacios urbanizables.

En otras palabras, se interpreta que la aparición de viviendas destinadas al turismo residencial ha estado acompañada, y se podría decir que incluso ha impulsado la expansión del tejido urbano hacia zonas donde antes no se registraba actividad habitacional significativa. También es importante visualizar que la mancha urbana establecida por las manzanas urbanas con las que cuentan las bases de datos del IMPLAN, se encuentran desactualizadas, ya que en la realidad la mancha urbana es más grande que lo marcado por el *Shapefile* (Figura 7).



Figura 7. Superposición de las viviendas de uso temporal con el crecimiento urbano en Todos Santos-El Pescadero, 2020-2024. Fuente: elaboración propia (2024).

Una interpretación adicional que se puede obtener desde el mapa resultante es que, principalmente en la zona norte del polígono del área de estudio, se está comenzando a presentar la construcción de viviendas de uso temporal en zonas completamente deshabitadas, lo cual otorga un síntoma muy claro de una futura urbanización en zonas mucho más alejadas de los centros de población existentes, lo que debería tomarse en cuenta para tomar acciones preventivas y evitar que la dispersión urbana continúe creciendo (Figura 8).




Figura 8. Correlación de las viviendas de uso temporal y el crecimiento disperso de la zona de Todos Santos-El Pescadero. Fuente: elaboración propia (2024).

Discusión

Uno de los hallazgos más relevantes de este estudio, es que las viviendas de uso temporal se ubican principalmente en las zonas más alejadas de los centros de población, lo que sugiere que su presencia puede estar contribuyendo al desarrollo de nuevas áreas habitacionales, muchas veces sin una planificación adecuada.

Este fenómeno refuerza la hipótesis de que el turismo residencial actúa como un impulsor de la dispersión urbana, generando una ocupación territorial

que posiblemente no sigue los lineamientos establecidos en los instrumentos de planeación urbana.

Si bien este crecimiento urbano puede representar una oportunidad económica para los propietarios y desarrolladores, también plantea desafíos significativos en términos de infraestructura, movilidad y sostenibilidad ambiental, ya que dichas zonas alejadas de los centros de población carecen de servicios públicos básicos.

Sin embargo, de continuar la expansión de la mancha urbana hacia zonas alejadas del centro, esto puede incrementar la demanda de servicios básicos, transporte y equipamiento urbano, lo que en algunos casos puede generar una mayor presión sobre los recursos locales y dificultar la gestión del crecimiento urbano, generando nuevos problemas para los encargados del desarrollo de las localidades.

Además, esta investigación abre la puerta a nuevas líneas de estudio que pueden contribuir a un entendimiento más profundo de la relación entre turismo residencial y crecimiento urbano. Algunas direcciones para futuras investigaciones incluyen:

- Análisis temporal del fenómeno: un estudio longitudinal que compare la evolución del turismo residencial y su impacto en la dispersión urbana a lo largo del tiempo.
- Evaluación del impacto en la infraestructura y servicios públicos: la creciente expansión urbana impulsada por el turismo residencial podría estar generando una mayor presión sobre los servicios públicos básicos (agua, electricidad, transporte), por lo que un análisis de esta relación ayudaría a diseñar estrategias de mitigación.
- Comparación entre diferentes ciudades costeras: un estudio comparativo que analice este fenómeno en distintas localidades con características similares permitiría identificar patrones comunes y mejores prácticas.
- Modelado espacial predictivo: la aplicación de modelos de predicción basados en SIG y técnicas de aprendizaje automático podría ayudar a anticipar futuras zonas de expansión relacionadas con el turismo residencial, y permitir una mejor planificación urbana.

Conclusiones

Los resultados de este estudio muestran con claridad cómo el turismo residencial está influyendo en la forma en que crece la ciudad.

Se ha podido observar que muchas de las viviendas de uso temporal se localizan en zonas que han experimentado una expansión dispersa, sobre todo en las áreas periféricas. Esto sugiere que este tipo de turismo está participando activamente en la transformación del territorio, empujando el desarrollo urbano hacia las orillas de la localidad y fuera del núcleo urbano consolidado.

Por ello se vuelve indispensable pensar en nuevas formas de ordenar el territorio que respondan a estas dinámicas, es decir, que se necesita aplicar estrategias de planeación más eficaces que ayuden a regular el impacto del turismo residencial sobre la ciudad.

Entre esas medidas, resulta clave promover la ocupación de espacios ya urbanizados mediante procesos de densificación, así como reforzar los instrumentos que limitan el crecimiento descontrolado hacia zonas no planificadas.

Estas acciones podrían ser fundamentales para contener los efectos de la dispersión urbana y avanzar hacia un desarrollo más equilibrado.

En conclusión, los hallazgos de esta investigación señalan la importancia de contar con una planificación urbana que no solo reaccione, sino que se anticipe a las transformaciones que traen consigo fenómenos de reciente auge, como el turismo residencial.

Continuar con estudios que profundicen en este fenómeno permitirá entenderlo mejor, y diseñar políticas más acertadas que garanticen un crecimiento ordenado del territorio, y un entorno urbano más justo para quienes lo habitan.

Referencias

- Audirac, I., Shermeyen, A., y Smith, D. (1990). Characteristics of urban sprawl: A comprehensive review. *Journal of Urban Planning and Development*, 116(1), 1-11.
- Buzai, G. D., y Montes Galbán, E. (2021). *Estadística Espacial: Fundamentos y aplicación con Sistemas de Información Geográfica*, (1a ed). Impresiones Buenos Aires Editorial. Libro digital, PDF.
- Downs, A. (1999). Some realities about sprawl and urban decline. *Housing Policy Debate*, 10(4), 727-748.
- ESRI. (n.d.). ArcMap (Versión 10.8.2) [Software]. Environmental Systems Research Institute. <https://www.esri.com/en-us/arcgis/products/arcgis-desktop/overview>
- Ewing, R. (1997). Is Los Angeles-style sprawl desirable? *Journal of the American Planning Association*, 63(1), 107-126.
- Google Earth Engine. (n.d.). Google Earth Engine [Software]. <https://earthengine.google.com/>
- Hernández Sampieri, R., Fernández Collado, C., y Baptista Lucio, M. del P. (2014). *Metodología de la investigación* (6ª ed.). McGraw-Hill / Interamericana Editores.
- Hiernaux Nicolas, D. (2005). El turismo residencial: Una aproximación conceptual. *Revista de Turismo y Patrimonio Cultural*, 3(1), 3-11.
- Instituto Municipal de Planeación (IMPLAN) de La Paz. (2022). Manzanashp

- Instituto Nacional de Estadística y Geografía. (2010). *Censo de Población y Vivienda 2010*. <https://www.inegi.org.mx/programas/ccpv/2010/>
- Instituto Nacional de Estadística y Geografía. (2020). *Censo de Población y Vivienda 2020*. <https://www.inegi.org.mx/programas/ccpv/2020/>
- U.S. Geological Survey. (2022). Landsat 8 Collection 2 Level-2 (LANDSAT/LC08/C02/T1_L2) [Conjunto de datos]. Recuperado de https://developers.google.com/earth-engine/datasets/catalog/LANDSAT_LC08_C02_T1_L2

Capítulo V. Evaluación de políticas públicas urbanas: una herramienta estratégica para la planificación integral del territorio

Alvaro Flores Miranda¹

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),
Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

La urbanización habitualmente se asocia como un símbolo de progreso, el cual facilita el acceso a servicios, infraestructura y oportunidades a las cuales difícilmente se podría acceder desde un entorno precarizado. Cuando la urbanización carece de una planificación adecuada exacerba desigualdades que posteriormente se intentan reducir implementando diversas políticas públicas. Cuando estas se enfocan a la gestión y uso del territorio se denominan políticas urbanas. Para conocer los resultados asociados a una determinada política pública urbana es necesaria su evaluación, siendo esta un proceso clave para reconocer qué tan efectiva ha resultado o si cumple con el objetivo planteado. Por lo cual es prioritario sistematizar la evaluación, pero además posibilitar su aprovechamiento como una herramienta que permita la obtención de resultados concretos que propicien una planificación territorial integral, contribuyendo a disminuir la brecha entre los más vulnerables. Este capítulo busca participar en la discusión sobre la necesidad de considerar el seguimiento y la evaluación como algo inalienable y fundamental de las políticas públicas urbanas, permitiendo mejorar la toma de decisiones de los planificadores urbanos, desde un proceso evaluativo de aprendizaje.

Palabras clave: evaluación de políticas públicas urbanas, planificación territorial, urbanismo.

Abstract

Urbanization is commonly regarded as a symbol of progress, facilitating access to services, infrastructure, and opportunities that would be difficult to obtain in precarious environments. However, when urbanization lacks proper planning, it exacerbates inequalities that later require mitigation through the implementation of public policies. When these policies focus on the management and use of land, they are known as urban policies. To understand the outcomes associated with a given urban public policy, evaluation is necessary. This being a key process for determining how effective the policy has been and whether it has achieved its stated objectives. Therefore, it is a priority to systematize evaluation, as well as to enable its use as a tool for generating concrete results that foster comprehensive territorial planning and help reduce the gap affecting

1 Candidato a Doctor en Ciencias en arquitectura y urbanismo, por la Escuela Superior de Ingeniería y Arquitectura, Unidad Tecamachalco (ESIA), Instituto Politécnico Nacional (IPN); Maestro en Ciencias en Arquitectura y Urbanismo por ESIA-IPN; y, Licenciado en Arquitectura por la UAEH. Correo: afloresm2200@alumno.ipn.mx, ORCID: <https://orcid.org/0009-0004-9989-3968>

the most vulnerable. This chapter seeks to contribute to the discussion on the need to consider monitoring and evaluation as inalienable and fundamental components of urban public policies, thereby improving urban planners' decision-making through a learning-oriented, rather than punitive, evaluative process.

Keywords: evaluation of urban public policies, spatial planning, urbanism.

El estado actual de la evaluación de políticas públicas urbanas y su papel en los procesos de planificación territorial

Actualmente, las zonas urbanas donde se insertan las ciudades están creciendo significativamente y se prevé que para el año 2050 el sesenta y seis por ciento de la población mundial se desarrolle dentro de estas. La tendencia actual de este crecimiento se considera como desordenado y sin planificación; de continuar así se provocaría el surgimiento de diversos problemas y afectaciones sociales que posteriormente se pretenderán resolver, como se ha hecho hasta ahora: a través del uso e implementación de diversas políticas públicas. Estas políticas, cuando se enfocan al territorio, el plano geográfico y la impartición de servicios, se consideran como políticas públicas urbanas, las cuales tienen por objetivo disminuir ciertas desigualdades socio territoriales.

Planear las ciudades tiene diversos propósitos y funciones. Destacan las planteadas por la Comisión Económica para América Latina y el Caribe, CEPAL (2020), que considera cuatro principales funciones básicas de la planeación, las cuales son: prospectiva, coordinar, concertar y evaluar. Dentro de esta última (evaluación) es donde este capítulo enfoca su principal interés.

La evaluación de Políticas Públicas Urbanas (PPU), se puede realizar con objetivos y criterios muy diversos y con intenciones igualmente variadas, desde una evaluación de impacto hasta una costo beneficio o de eficiencia, por lo cual sistematizar la evaluación podría reconstruir el principio público del estado, el cual en los últimos años ha perdido validez en México y América Latina debido a la percepción que tiene gran parte de la población sobre la implementación de este tipo de PPU, percibiéndolas como clientelares y particularistas, donde solo se benefician algunos cuantos y no quien verdaderamente lo necesita.

Por lo cual, el primer paso en esta relación entre evaluación de PPU y la planificación territorial, es ofrecer instrumentos de evaluación sustentados a través de una metodología justificada objetivamente. Por ejemplo, en esta investigación se partió de formular una propuesta metodológica, y al mismo tiempo utilizar bases de datos proporcionadas por fuentes oficiales y, de manera sistemática, con la intención de que la misma variable temporal demuestre el cumplimiento de objetivos y sirva como herramienta en la planificación urbana.

Existen diversos motivos por los cuales la sociedad muestra interés sobre la eficacia del sector público; uno de los más importantes es el factor económico, que está relacionado a las obligaciones y derechos adquiridos cuando un individuo se desarrolla dentro de una zona urbana.

Dichas obligaciones sociales van desde respetar normas de convivencia y denunciar cualquier conducta que infrinja estas normas, hasta contribuir económicamente con sus respectivos impuestos para que el sector público cubra sus gastos, financie obras públicas y se encargue de disminuir esta brecha entre los más vulnerables generando un estado de bienestar; por ende, al cumplir con dicha obligación también se genera un derecho que es el acceso a la información pública, en el cual el ciudadano generara dudas sobre el cómo y a quien están beneficiando los tomadores de decisiones con estos recursos, teniendo en cuenta que cada decisión favorable o desfavorable agota recursos de diversa índole, ya sea económicos, humanos o políticos, lo que lleva a exigir una eficacia pública y el perfeccionamiento de procesos como el de la evaluación.

Aunque ya existen actualmente evaluaciones de PPU, no se ha logrado afianzar la relación entre sus resultados y la planeación territorial, ya que regularmente estos procesos de evaluación concluyen con la obtención de una cualificación; sin embargo, estos resultados tienen el potencial de ser una herramienta que propicie una planificación territorial adecuada a través de un ciclo que parte de la planificación, continúa con la evaluación, y culmina con el aprendizaje y la emisión de recomendaciones.

Aproximación teórico-conceptual sobre la evaluación de políticas públicas urbanas

De acuerdo con lo expuesto por Cardozo (2013), las políticas públicas conforman productos del proceso en el posicionamiento del estado frente a una problemática Cardozo (2013). Complementando lo anterior, además es indispensable que cualquier propuesta de una política pública esté sustentada teórica y metodológicamente; así mismo, debe ser respaldada por un servidor con la preparación adecuada para el cargo y la experiencia necesaria, ya que se trata de acciones tan complejas que influyen en cientos o miles de habitantes, siendo recomendable también que sea una tarea transdisciplinaria, con un marco de soporte fundamentado apropiadamente para concretar así un posicionamiento idóneo.

Por su parte, Bertranou (2019) las define como acciones de gobierno que tienen como propósito alcanzar objetivos de interés público. Las situaciones de interés, necesidad o beneficio públicos en las que socialmente se considera que el gobierno debe intervenir, son problemas públicos, y las políticas públicas son entendidas como respuestas a tales problemas públicos (Bertranou, 2019). Por lo tanto, se coincide en que las PPU son procesos conformados por acciones mentales y físicas que preparan y planifican la toma de una decisión que posteriormente se ejecutará; en este contexto, se reafirma que la formulación de una propuesta busca solucionar una necesidad de interés público, por lo cual será favorecedor sistematizar este proceso de evaluación, con la finalidad

de tener la certeza de que esta decisión satisfizo la necesidad para la que se planteó, o en caso de obtener resultados negativos conocer las áreas de oportunidad para poder mejorar.

Según lo planteado por Subirats, et al., (2008), las PPU son las que encuentran su objeto en la esfera territorial en la que se desarrollan, en la concatenación y articulación de políticas sectoriales que se despliegan en ese territorio, y en el solapamiento de las políticas e intervenciones procedentes de distintas esferas de gobierno (supraestatal, estatal, autonómica y local) (Dente y Subirats, 2014). A partir de esto se puede afirmar que si las políticas públicas son estrategias para resolver problemas públicos, las PPU agregan este elemento territorial, es decir, donde se analiza una porción de la superficie terrestre que por ende contendrá características geográficas únicas.

Barenboim (2012) señala que las PPU constituyen la dimensión espacial del Estado de bienestar y la regulación pública de la división económica y social del espacio. Además, este autor añade que existe el reto de diseñar y poner en práctica instrumentos de regulación pública de la ciudad si no se quiere que esta sea el resultado estricto de la lógica del mercado (Barenboim, 2012). Esta aproximación complementa sustancialmente el enfoque conceptual de este capítulo, ya que enmarca las facultades y responsabilidades que el sector público posee dentro de la gestión del territorio, como son: su responsabilidad en la regulación, ordenamiento, restructuración, y la oferta de servicios públicos, con la finalidad de delimitar el actuar del sector privado otorgándole sus respectivas obligaciones, siendo imprescindible que el sector público sea quien tome la batuta para planificar las ciudades, y no que en esta lógica del mercado capitalista el sector privado sea quien tome las decisiones sobre la construcción de las mismas, como ya ha ocurrido antes.

En síntesis, para este capítulo, se considera a las PPU como las acciones del estado para intervenir una situación de interés público o una problemática colectiva determinada, con lo cual se pretende disminuir, pero principalmente dar solución, ocasionando consecuencias planeadas o no.

Como aproximación conceptual a la evaluación de políticas públicas urbanas, se parte de la definición de evaluar, que de acuerdo con Nirenberg (2000) se define como una actividad programada de reflexión sobre una acción, que se basa en procedimientos metódicos, con el objetivo de emitir un juicio valorativo fundamentado donde posteriormente se plantean recomendaciones (Nirenberg, et al., 2000). Parte de lo expuesto está ligado a la necesidad actual que existe de brindar propuestas de modelos de evaluación de PPU, lo que permitiría conocer resultados, y que además dichos resultados sean útiles como herramienta en los procesos de planificación territorial.

También es primordial resaltar, a partir de lo anterior, que el proceso de una PPU no tendría por qué finalizar en la evaluación, sino que es preciso emitir las recomendaciones necesarias, así como sugerir mejoras para enriquecer la

implementación y seguimiento, articulando la evaluación como una herramienta vinculante que permita que los tomadores de decisión utilicen estos resultados a favor de la planificación territorial, siendo desacertado encaminar el proceso hacia la sanción, o emitir únicamente una valoración/cualificación, siendo lo más conveniente brindar este sentido de integralidad en el que la retroalimentación sirva para el fortalecimiento de estos procesos.

Ante ello, Weiss (2005) manifiesta que la evaluación de políticas es una herramienta de indagación aplicada para auxiliar a organizaciones y actores a optimizar sus planes, políticas y prácticas en beneficio de la población (Weiss, et al., 2005, como se cita en Bertraneou, 2019). Justamente, a partir de lo expresado se aspira a que con la propuesta de este modelo exista una opción que asista al sector público a mejorar el proceso de implementación de PPU, propiciando un seguimiento práctico, para que además estos resultados coadyuven a mejorar la planificación territorial.

A su vez, Bertranou (2019) desde su perspectiva señala que la evaluación de PPU es una actividad investigativa, con rasgos muy similares a los desarrollados por la investigación académica, pero con la particularidad de que debe generarse un aprendizaje en el nivel de las organizaciones públicas (y no gubernamentales) para poder aplicar los nuevos conocimientos a la mejora de las intervenciones (Bertranou, 2019). Por lo tanto, se comparte el hecho de que la evaluación de PPU es una actividad investigativa, sin embargo, es también deseable el llegar a un fin práctico como lo es el modelo propuesto, ya que esto permitirá, con resultados visibles, consolidar saberes en el campo de la planificación territorial y de la implementación de PPU.

La evaluación de PPU puede realizarse con criterios diversos, pero dependerá de la postura y enfoque que plantee el analista, así como del cómo se desarrollará el proceso metodológico para presentar una propuesta. Los diversos enfoques existentes son tres: el positivista, el constructivista y el post positivista, cada uno con características específicas que permiten conocer diferentes rasgos de una misma política. El positivista, por ejemplo, exalta la cuantificación, la objetividad y la estandarización de datos. El constructivista es pluridimensional y cualitativo; y el post positivista es una conjunción de ambos.

La evaluación de políticas públicas puede considerarse como reciente en México, ya que se inició en los años 80s, sobre todo si se compara internacionalmente con otros países, por ejemplo Estados Unidos y Francia, donde se inició desde los años 50s. La primera institución federal del estado mexicano encargada de evaluar políticas y programas públicos en México surge en 2006, bajo el nombre de Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL). A nivel estatal, fue conformado en el año 2008 el Consejo de Evaluación del Desarrollo Social, EVALÚA. Además de estas dos instancias se han conformado ya varios institutos y órganos regionales.

Estas acciones demuestran el interés por institucionalizar y sistematizar la práctica de la evaluación de PPU; sin embargo, este es un camino aún incierto si se pretende llegar a un proceso sistémico conciso. En la actualidad, por ejemplo en el año 2024, se ha planteado el desaparecer el CONEVAL, además de que son pocas las propuestas que se enfocan en una evaluación integral de la implementación de PPU (pues la gran mayoría se enfoca principalmente en el factor económico, lo que termina encasillándolas como una auditoría).

Al margen de estas definiciones precisas sobre la evaluación de programas y políticas públicas urbanas, se encuentra también la de Osuna y Márquez (2000), que refuerza el sentido de esta propuesta al establecer que la evaluación de políticas es aquella que examina e inspecciona qué elementos justifican la necesidad de la intervención y la forma en que esta se articula (Osuna y Márquez, 2000).

Merriam (1987), en cambio, plantea que es primordial la formulación de propuestas de evaluación, exponiendo la necesidad de incorporar mayores dosis y niveles de ciencia a las operaciones del gobierno, evitando así caer en el capricho, la ignorancia y la pasión que planteen las decisiones de sus respectivos gobernantes (Merriam, 1987); por ello es indispensable aportar nuevas propuestas de evaluación que exploten las tecnologías actuales, y que además sirvan como un recurso del cual la planeación territorial pueda fortalecerse, mejorando la calidad de vida de las personas dentro de las zonas urbanas.

Dentro de la búsqueda de trabajos afines a la evaluación de PPU realizados en los últimos años existe una producción bibliográfica prolífica, aunque con un inicio lento, en el cual desde el año 1968 surge el interés por el tema con un solo documento; de este modo, la curva de investigación se va ampliando hasta llegar a los 201 documentos en el año 2023, tal como se aprecia en el gráfico (Figura 1), siendo un tema relevante para la comunidad científica, debido a la necesidad apremiante de disminuir esta brecha de desigualdad socio territorial.




Figura 1. Publicación de documentos por año. Fuente: elaboración propia con base en el análisis bibliométrico generado mediante la plataforma Scopus (Elsevier, 2024).

Por otro lado, los principales países que han abordado el tema, y donde se han producido la mayor cantidad de documentos relacionados al análisis y evaluación de PPU, son en primer lugar Estados Unidos de América, con casi 600 documentos, en segundo lugar se encuentra China con 390, y en tercer lugar Reino Unido con casi 250 documentos. No es de extrañar que Estados Unidos de América ocupe el puesto número uno, cuando son pioneros en la evaluación de políticas a través de visiones como la de Harold Laswell (Figura 2).




Figura 2. Publicación de documentos por país. Fuente: elaboración propia con base en el análisis bibliométrico generado mediante la plataforma Scopus (Elsevier, 2024).

A través de la Figura 3, y relacionado a la evolución en su asociación de conceptos principales, se observa que actualmente la evaluación de PPU se asocia principalmente con la salud pública, el desarrollo sustentable, el desarrollo humano, la economía, la política social, y sobre todo la planificación territorial.




Figura 3. Análisis de conceptos o clústeres. Fuente: elaboración propia con base en el análisis bibliométrico generado mediante la plataforma Scopus (Elsevier, 2024).

El uso de un modelo de evaluación de PPU como herramienta en la planificación territorial

Antes de diseñar y emprender una evaluación de PPU, es indispensable determinar cuál será su enfoque, ya que esto influirá en su abordaje, siendo la base que sustente la propuesta, además de contribuir para conseguir un respaldo social y científico.

La evaluación de políticas públicas puede abordarse desde tres enfoques teóricos distintos: el positivismo, el constructivismo y el postpositivismo. En este caso, se parte del positivismo debido a que, en él, el desarrollo ocurre principalmente a partir de datos periódicos de fuentes oficiales (estadísticos) y normativas, priorizando la objetividad y la autenticidad de su diseño metodológico, robustecido mediante datos obtenidos del Instituto Nacional de Estadística y Geografía (INEGI), aunque se deja abierta la posibilidad para complementar la propuesta con datos cualitativos si llegaran a ser requeridos, y así evaluar aspectos que no son posibles de valorar mediante datos estadísticos, o en su caso aspectos sociales que no fueron considerados por este modelo.

Respecto a la metodología, para este modelo es cuantitativa; los métodos cuantitativos tradicionales pueden contribuir de manera significativa al análisis de políticas y programas públicos, siempre que se consideren los supuestos en los que se basan y, en consecuencia, las limitaciones que implican (Cardozo, 2013). El interés de esta propuesta es llegar a un modelo integral, no al cuantitativismo en exceso que se inclina a simplificar las técnicas de análisis, llegando en casos extremos a una modelación aritmética, excluyendo aspectos primordiales en temas urbanos.

Patton (2014) afirma que, aunque las herramientas actualmente disponibles resultan adecuadas para la evaluación de programas y proyectos, no son suficientes para abordar la complejidad que implica la evaluación de políticas, ámbito en el que existen escasas propuestas metodológicas. Esto demanda una alta capacidad de innovación en el diseño metodológico, una disposición abierta frente a explicaciones teóricas diversas y un conocimiento profundo y especializado sobre el objeto de evaluación (Patton, 2014). Si bien es cierto que México ha avanzado en la tarea de evaluar una PPU, la falta de planificación y sistematización han sido un gran impedimento para que nuevas propuestas surjan y de verdad se puedan utilizar como una herramienta a favor de la planificación, sin dejar a un lado la existencia de aspectos que dificultan la formulación de indicadores y la obtención de información.

Para delimitar el criterio del modelo, se recurre a lo planteado por Guerrero (1995), quien diferencia cinco criterios de evaluaciones de acuerdo a características específicas y diferenciadoras, que son:

- Descriptivas: no se basan en criterios previos. Su objetivo es simplemente registrar y comparar dos momentos: el inicio y el final de una intervención para identificar los cambios ocurridos.

- Clínicas: se desarrollan a partir de criterios definidos internamente, es decir, por el propio programa evaluado. Son las más comunes y responden a los objetivos y parámetros establecidos desde dentro de la intervención.
- Normativas: se fundamentan en criterios establecidos externamente. Un actor ajeno al programa, como una entidad reguladora o certificadora, determina los estándares de evaluación. Este enfoque se asocia con procesos de normalización y certificación.
- Pluralistas: integran múltiples criterios de evaluación provenientes de diversos actores, tanto internos como externos (beneficiarios, profesionales, técnicos, entre otros). Se trata de evaluaciones participativas que promueven la inclusión de diferentes perspectivas en su diseño y ejecución.
- Experimentales: se basan en la comparación entre un grupo destinatario del programa y un grupo de control, definido o construido conforme a los criterios del propio programa. Este enfoque busca establecer relaciones causales entre la intervención y los resultados observados (Guerrero, 1995, como se cita en Bertranou, 2019).

En este sentido, el criterio adoptado responde a un enfoque clínico, ya que fue definido en función de los objetivos establecidos por la política pública seleccionada. En este caso, se trata de los Sistemas de Actuación por Cooperación (SAC), los cuales, según lo establecido por la Secretaría de Desarrollo Agrario, Territorial y Urbano (SEDATU, 2022), constituyen un instrumento contemplado en la Ley de Desarrollo Urbano del Distrito Federal. Su propósito es ejecutar proyectos y obras específicas de infraestructura, equipamiento y espacio público que generen beneficios tangibles para la población y el entorno urbano en áreas determinadas.

A partir de la justificación de las características ya antes mencionadas, se plantea la propuesta metodológica de la Tabla 1.

Tabla 1. Metodología del modelo de evaluación.

Tipología de la evaluación	
Enfoque	POSITIVISTA
Metodología	CUANTITATIVA
Criterio	CLÍNICO
Objeto de estudio SAC Granadas	

Fuente: elaboración propia.

Existen cinco SAC en Ciudad de México, siendo el SAC Granadas donde se implementó el modelo de evaluación, esto debido a que cuenta con características específicas que favorecen el desarrollo e instauración de la propuesta. Los demás proyectos son el SAC Alameda Reforma, SAC Distrito San Pablo, SAC La Mexicana y SAC Tacubaya.

El proceso, como se abordó en la formulación de los primeros indicadores, fue el siguiente; como ya se ha mencionado, los indicadores se plantearon a partir de los objetivos de la política seleccionada SAC Granadas, que son 18, y que se dividen en 6 categorías generales: movilidad, medio ambiente, reactivación urbana, espacio público y transparencia; para efecto de este trabajo solo se presentan dos indicadores de los 18, los cuales son los siguientes:

1. Promover una mezcla de usos equilibrada que favorezca el aumento de la población residente, dinamice el comercio y la economía local, incentive el uso del espacio público y contribuya a la construcción de una identidad urbana y social en la zona. Asimismo, se busca regular la afluencia de población flotante, lo que permitiría reducir los desplazamientos individuales motorizados hacia el área. Para los fines de este trabajo, este objetivo se ha sintetizado bajo el concepto de incremento poblacional.
2. Garantizar aportaciones proporcionales derivadas de las medidas de mitigación, calculadas a partir del modelo de tasación definido por el Sistema de Actuación por Cooperación, en función del impacto urbano previsto para el área de actuación. Estas contribuciones permiten distribuir de manera equitativa los costos asociados a infraestructura, pavimentación, espacios públicos, obras complementarias y proyectos estratégicos que beneficiarán a todos los predios del polígono de intervención Granadas. Tales acciones son fundamentales para asegurar un funcionamiento urbano, ambiental y social adecuado, así como el acceso efectivo a dicha infraestructura. En el marco de este estudio, este objetivo se ha resumido como “accesibilidad a infraestructura urbana”.

A partir de este par de objetivos expuestos en los lineamientos generales del SAC Granadas, se desarrolló la conformación de dos indicadores. Cabe señalar que la propuesta está pensada para evaluar integralmente al instrumento, por lo cual hasta el momento solo se expresaran los resultados específicos sin llegar a generalizar ni a emitir recomendación alguna.

El proceso comenzó al sintetizar objetivos expresados cualitativamente, y transformarlos a objetivos cuantitativos para poder hacerlos cuantificables y medibles. Regularmente este tipo de evaluación parte de la conformación de una Matriz de Marco Lógico (MML), que fue utilizada para gran parte de los 18

indicadores. La siguiente tabla (Tabla 2) muestra la conformación del indicador 1, mediante una MML donde se llega a sintetizar hasta la fórmula que permitió evaluar este primer objetivo.

Tabla 2. MML para indicador uno.

Resumen narrativo	Indicadores verificables objetivamente	Medios de verificación	Supuestos
FIN: Contribuir a incrementar la población residente	Ocupación del 95% de la vivienda ejecutada	INEGI inf. estadística censos 2010 y 2020 fórmula incremento poblacional	La oferta excedió la demanda vivienda desocupada
PROPÓSITOS : Vivienda asequible y mezcla de estratos	Al finalizar 80% de población de estrato medio alto y 20% de vivienda social	Informe cartera de proyectos	Mercado suficiente para adquirir inmuebles de este estrato
COMPONENTES: Bolsa de vivienda equilibrada	Equilibrio 50-50 entre vivienda vertical y horizontal	Usos de suelo SEDUVI de acuerdo con PPDU	Voluntad e inmobiliarios
ACTIVIDADES: Facilidades administrativas	12 mill x plan maestro 130 mill mitigación 142 mill de adeudo	Auditoría	Rigidez normativa

Fuente: elaboración propia con metodología del BID.

Posterior a la síntesis del objetivo a través de la MML, se procedió a realizar el análisis espacial, utilizando las bases de datos e información estadística recabada por el Instituto Nacional de Geografía y Estadística (INEGI). De acuerdo con el *Environmental Systems Research Institute* (ESRI), instituto caracterizado por desarrollar software de Sistemas de Información Geográfica (SIG), el análisis espacial es un proceso donde se examinan ubicaciones, atributos y relaciones en datos espaciales mediante una serie de técnicas; desde superposiciones sencillas hasta estadísticas espaciales avanzadas y otras técnicas de análisis (ESRI, 2025). En este capítulo, se decidió abordar el primer indicador mediante datos estadísticos poblacionales, y el segundo indicador mediante una superposición de planos para conocer el alcance de cobertura, como se detalla más adelante.

De acuerdo con Buzai, et al., (2019) el análisis espacial es un conjunto de técnicas matemáticas que se basan en el razonamiento lógico de las relaciones formales abstractas numéricas y estadísticas mediante inferencias en datos

que constituyen muestras representativas Buzai, et al., (2019). Entre sus principales características están el realizarse sobre datos distribuidos sobre la superficie terrestre, lo que puede ser aplicado a través de SIG. Para poder realizar esta aplicación es necesario recurrir a la estadística espacial como una herramienta del análisis espacial cuantitativo.

En este modelo se ha privilegiado el enfoque cuantitativo, por lo cual se parte del análisis espacial a través de SIG para el abordaje de los indicadores propuestos. Existen varios conceptos centrales que se hacen operativos con el análisis espacial, siendo la asociación espacial el principio geográfico sobre el que se fundamenta el modelo.

En este primer indicador que aborda el incremento poblacional, se utilizó el geoproceto (GEOP) Unión espacial *join*, el cual ocurre al unir tablas en función de una localización, como se detalla a continuación:

Con información estadística de los censos realizados por el INEGI en los años 2010 y 2020, y con el empleo del software ArcGIS (herramientas de los SIG) se realizó una comparativa, plasmando mediante el siguiente mapa el incremento o reducción de población dentro del polígono del área de estudio, siendo este el primer objetivo propuesto por el SAC Granadas (Figura 4).

El incremento poblacional se determinó utilizando la siguiente fórmula:

$$r = \left(\frac{Pt - Po}{Po} \right) 100$$

Donde:

r = la tasa de crecimiento poblacional

Pt = Población 2020

Po = Población 2010

100 = Porcentaje

De acuerdo con el mapa presentado en la Figura 4, se observa que la población aumenta dentro del polígono SAC, existiendo un aumento significativo a diferencia del resto de la alcaldía, consolidándose además una nueva centralidad que surge por la reactivación económica y cultural que sufrió la zona al estar subutilizada. Queda comprobado que el objetivo principal de esta intervención se cumplió al contar con un incremento poblacional del 578.72%, sin embargo, al tratarse de una zona de reciclamiento urbano no se puede omitir que parte de su éxito depende de que el uso de suelo de esta zona era industrial, no habitacional o mixto, por lo cual sería prudente analizar otros aspectos que favorezcan a la política, para que esta se pueda considerar como un éxito o un objetivo cumplido.

Relacionado al éxito de su incremento poblacional surgen nuevas incógnitas, como el reconocer si la infraestructura y los servicios serán suficientes, ya que este incremento podría traer consigo problemas futuros; reiterando que no es

conveniente manifestar una conclusión precipitada debido al interés de que el modelo parta desde la integralidad, por lo cual, para asegurar el éxito del objetivo, será necesario esperar hasta que el modelo haya sido concluido.



Figura 4. Mapa general Incremento poblacional SAC Granadas. Nota. Estudio exploratorio con imágenes satelitales. Fuente: elaboración propia.

El segundo indicador se aborda a través del geoproceso denominado como zona de influencia o *buffer*, el cual se considera como el alcance geográfico en torno a un objeto o espacio determinado, y está contenido dentro de una distancia determinada por un criterio normativo. Por lo cual se abordó de acuerdo a lo establecido en la norma NOM-00-2021 de la Secretaría de Desarrollo Agrario, Territorial y Urbano (SEDATU, 2022) de espacios públicos,

que clasifica la cobertura de los espacios públicos recreativos, en este caso parques, de acuerdo con sus dimensiones, es decir que, partiendo del área del espacio público es como se obtuvo su área de influencia a través de la Tabla 3.

Tabla 3. Clasificación del espacio público de acuerdo con su área.

ÁREA	CLASIFICACIÓN	DISTANCIAS A LA POBLACIÓN DIRECTAMENTE BENEFICIADA	
		Distancia máxima de la vivienda a un solo espacio público (aislado) D1	Distancia máxima de la vivienda a cada espacio público cuando son dos o más (sistema) D2
0.01 A 2 HA	A-1	400 metros	500 metros
2 A 5 HA	B2	600 metros	800 metros
5 A 10 HA	C3	800 metros	1,200 metros
10 A 50 HA	D4	2000 metros	2,500 metros
MAS DE 50 HA	E-5	12 kilómetros	

NOTA: las distancias máximas se consideran medidas en terreno plano. El municipio o gobierno podrá modificar estas distancias de acuerdo con el caso particular de cada espacio y justificándolo con la topografía en la que se encuentra y el gasto energético que representan sus recorridos.

Fuente: elaboración propia con información de la Secretaría de Desarrollo Agrario, Territorial y Urbano (SEDATU, 2022).

Conforme a la Tabla 3 se catalogaron los espacios públicos de acuerdo con sus dimensiones, considerando los presentados dentro de la cartera de proyectos del polígono SAC Granadas, los cuales se encuentran dentro de la escala A-1, ya que son espacios públicos que atienden la demanda de la ciudadanía residente en la unidad más pequeña de núcleos de población determinados por su aglomeración geográfica y una identidad propia. En asentamientos nucleares, suelen ser las zonas determinadas por la posibilidad de ser recorridas peatonalmente de forma segura e ininterrumpida (SEDATU, 2022). Debido a que la suma de las áreas de los parques Pedro Plascencia, Presa Escame, Ferrocarril de Cuernavaca y Lago Alberto no rebasan las dos hectáreas, su clasificación corresponde a una D1 con una cobertura de hasta 400m, pero donde al ser parques próximos la clasificación cambia a D2, por lo cual su rango de alcance aumenta 100m más, terminando con un radio de cobertura de 500mts (Figura 5).




Figura 5. Mapa de accesibilidad a espacio público SAC Granadas. Nota: estudio exploratorio con imágenes satelitales. Fuente: elaboración propia.

De acuerdo con el mapa de la Figura 5, se aprecia que gran parte de la población del polígono SAC Granadas está dentro de las áreas de influencia de los espacios públicos nuevos y existentes. Sin embargo, hay pequeñas zonas donde la cobertura no fue suficiente. Desde una perspectiva espacial o geográfica podría considerarse este segundo objetivo como cumplido, sin embargo, si se analiza de acuerdo a otros criterios o recomendaciones, como lo sugerido por la Organización Mundial de la Salud (OMS), de contar con al menos con 9m² de área verde por habitante, no se cubriría con la recomendación solicitada.

La escasez y el desequilibrio del espacio público es una constante no solo dentro del polígono del caso de estudio, sino que es común en gran parte de las ciudades latinoamericanas, lo que es absurdo en casos como este, donde se cuenta con una planeación, cartera de proyectos y muchas otras facilidades.

Cuando el espacio público no sea una prioridad, es indispensable contar con un verdadero compromiso de los planificadores territoriales, una mejor regulación del sector inmobiliario y la aplicación de normativas y leyes más contundentes para ayudar a mejorar los resultados de este indicador.

El indicador dos arroja como resultado que, si bien de alguna manera se cumple con el objetivo, este no es completamente satisfactorio, siendo incluso algo contradictorio; aunque dependerá desde qué enfoque se analice. En general, debido a que este tipo de instrumentos de intervención se configuran para propiciar la equidad y la mejora común, la evaluación es una ruta útil para conocer el compromiso que tienen tanto el sector público para conocer sus resultados, como el sector privado de comprometerse con la sociedad. Así, es evidente la necesidad de implementar estos procesos evaluativos relacionados al análisis espacial, que además podrían eficientizar la planificación territorial.

Discusión y reflexiones finales

La relación entre la evaluación de políticas públicas urbanas y la planificación urbana pone de manifiesto un paradigma recurrente en la gobernanza y la gestión, donde anteriormente se vinculaba que evaluar podría ser algo negativo si los resultados no eran favorables, principalmente para el sector institucional o gubernamental.

La Ciudad de México, al ser una de las más pobladas del mundo, evidentemente presentará una problemática que exacerba desigualdades sociales, pero que mediante la aplicación de políticas públicas se han logrado disminuir. Lo que actualmente se debe tener en consideración para mejorar los resultados es la forma adecuada de abordarles, de implementarles, y de sistematizar este proceso de evaluación.

El objetivo de este capítulo se centra en la vinculación entre la evaluación PPU, con el propósito de usarle como herramienta en la planificación del territorio, posibilitando construir ciudades más equitativas e inclusivas; sin embargo, aún no existen suficientes modelos ni propuestas de evaluación aprobados por las instancias correspondientes, además, regularmente los modelos aceptados se centran en el aspecto económico convirtiéndolas en auditorías; si se llega a generar esta conexión, la evaluación puede llegar a ser una herramienta estratégica en la planificación territorial si se plantea de manera sistémica, ya que evaluar identifica fortalezas y debilidades, lo cual ayuda en el proceso de aprendizaje, y además a corregir o evitar errores de planificación, replicando así buenas prácticas y promoviendo la participación y transparencia al conocer sus resultados.

Por lo cual se exhorta a incentivar dicho tipo de evaluaciones con esta perspectiva territorial a través del análisis espacial y mediante SIG, ya que como se ha demostrado con los indicadores presentados, se refleja de forma puntual si la implementación de la PPU fue efectiva para, de no ser así, realizar

las acciones pertinentes para mejorarla. Si bien el modelo presentado aún no se concluye, este evidencia los beneficios de la evaluación y las áreas de oportunidad en proyectos de tal magnitud, mejorando el actuar de los planificadores del territorio, tanto para los que intervinieron en esta propuesta, como para los que generen nuevos instrumentos similares.

Se deja abierta la posibilidad de completar el modelo, si así lo requiere, y convertirlo de una versión positivista cuantitativa a un modelo mixto post positivista, así como de recurrir a otras técnicas de investigación o considerar otros aspectos sociales que se han dejado fuera en esta propuesta.

Finalmente, los resultados preliminares de los indicadores presentados responden parcialmente a la interrogante inicial sobre si la evaluación de PPU puede ser una herramienta para propiciar una adecuada planificación urbana. Si bien es complejo comprobar esta correlación, la intención de esta propuesta no es usarle como una fórmula, sino más bien tener una opción diversa a las ya existentes, partiendo desde una perspectiva cuantitativa y geográfica, y con ello facilitar la toma de decisiones de los planificadores urbanos.

Es indudable que el trabajo investigativo transdisciplinario enriquecerá este tipo de propuestas. La utilización de nuevas tecnologías, como los SIG, aporta una novedosa visión de la evaluación de políticas públicas a través de elementos gráficos como son los mapas, lo cual es ideal en el área urbana ya que, a causa de la escala, previamente se dificultaba realizar estos procesos.

Está claro que la evaluación de PPU en México se encuentra en un estado temprano; sin embargo, esta puede ser perfectible, además de que es fundamental incrementar el número de propuestas de todos los enfoques cuantitativos, cualitativos y mixtos existentes, con la finalidad de enriquecer estos procesos de análisis, y así remover esa visión punitiva de la evaluación, orientándola al aprendizaje.

Referencias

- Barenboim, C. A. (2012). Políticas públicas urbanas e instrumentos de regulación en la ciudad de Rosario. *Revista Iberoamericana de Urbanismo*, (7), 31-41. <https://revistes.uab.cat/revibru/article/view/v7-barenboim>
- Bertranou, J. (2019). El seguimiento y la evaluación de políticas públicas: Modelos disponibles para producir conocimiento y mejorar el desempeño de las intervenciones públicas. *Millcayac. Revista Digital de Ciencias Sociales*, VI (10).
- Buzai, G. D., Humacata, L., y Principi, N. (2019). *Análisis espacial con sistemas de información geográfica*. Bernal: Universidad Nacional de Quilmes.
- Cardozo Brum, M. (2013). Políticas públicas: los debates de su análisis y evaluación. *Andamios*, 10(21), 39-59.

- Comisión Económica para América Latina y el Caribe (CEPAL). (2020). *Planificación para el desarrollo en América Latina y el Caribe: Enfoques, instrumentos y experiencias*. Naciones Unidas. <https://www.cepal.org>
- Dente, B. O., y Subirats Humet, J. (2014). *Decisiones públicas-Análisis y estudio de los procesos de decisión en políticas públicas*. Ariel. Disponible en: <https://re.public.polimi.it/handle/11311/766674>
- Elsevier. (2024). Scopus [Base de datos]. <https://www.scopus.com>
- ESRI. (2025). GeoAI in ArcGIS Pro. <https://pro.arcgis.com/es/pro-app/latest/help/analysis/ai/geoai.htm>
- Guerrero, A. J. P. (1995). La evaluación de políticas públicas: Enfoques teóricos y realidades en nueve países desarrollados. *Gestión y Política Pública*, IV, 47-115.
- Merriam, C. E. (1987). *Political power: Its composition and incidence*. Transaction Books.
- Nirenberg, O., (2000). *Evaluar para la transformación: Innovaciones en la evaluación de programas y proyectos sociales*. Paidós.
- Osuna, L. J. L., y Márquez, G. C. (2000). *Guía para la evaluación de políticas públicas*. Universidad de Sevilla, Instituto de Desarrollo Regional, Fundación Universitaria.
- Patton, MQ (2014). *Métodos de investigación y evaluación cualitativos: Integrando la teoría y la práctica*. Publicaciones Sage.
- Secretaría de Desarrollo Agrario, Territorial y Urbano [SEDATU]. (2022, febrero 22). *Diario Oficial de la Federación*. https://www.dof.gob.mx/nota_detalle.php?codigo=5643417&fecha=22/02/2022#gsc.tab=0
- Subirats, J., Knoepfel, P., Larrue, C., y Varone, F. (2008). *Análisis y gestión de políticas públicas* (Vol. 1). Barcelona: Ariel. Disponible en: http://orga.blog.unq.edu.ar/wp-content/uploads/sites/28/2024/03/Subirats_y-otros-2008-Cap-2-y-3.pdf

Capítulo VI. Micro-segregación residencial en Managua: entre la conciliación espacial y la fractura social

Perla María Sánchez Uriarte¹

Universidad Nacional Autónoma de México (UNAM), Instituto de Geografía, Coyoacán,

Ciudad de México.

Resumen

Este capítulo ilustra cómo se utilizó el software ArcGIS para documentar cambios en la segregación residencial en Managua entre 2005 y 2018 a través de tres procesos: i) Un análisis de agrupamiento espacial con la Autocorrelación Local de Moran (ALM) para dos grupos sociales: aquellos sin educación formal y aquellos con educación terciaria; ii) Un inventario georreferenciado de viviendas construidas en el mercado formal durante este período; y iii) Un análisis de superposición de mapas temáticos creados mediante el cálculo de la ALM y el inventario de vivienda. Los resultados indican que el grupo más segregado por agrupamiento, en función del nivel educativo, es la población con educación terciaria. Adicionalmente, Managua muestra una micro-segregación, vinculada a desarrollos residenciales dirigidos a los grupos de ingresos altos ubicados en medio de zonas de menores ingresos. Esto plantea una cuestión importante: ¿La reducción de las distancias geográficas entre estos grupos debe considerarse un paso hacia la reconciliación espacial o una prueba de fractura social?

Palabras clave: segregación residencial, micro-segregación, análisis espacial.

Abstract

This chapter illustrates how ArcGIS was used to document changes in residential segregation in Managua between 2005 and 2018 through three key processes: i) A spatial clustering analysis with Moran's Local Autocorrelation (ALM) for two social groups: those without formal education, and those with tertiary education; ii) A georeferenced inventory of housing built in Managua's formal market during this period; and iii) An overlay analysis of thematic maps from the ALM calculations and the housing inventory. The findings indicate that the most segregated group by clustering, based on educational attainment, is the population with tertiary education. Additionally, Managua shows micro-segregation, linked to new residential developments targeting upper socioeconomic strata located amid lower-income areas. This raises an important question: Should the reduced geographical distances between these groups be seen as a step toward spatial reconciliation or as evidence of social fracture?

Keywords: residential segregation, micro-segregation, spatial analysis.

1 Maestra y Doctora en Ciencias en Arquitectura y Urbanismo, Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura, ESIA, Unidad Tecamachalco. Correo: uriarte@gmail.com, ORCID: <https://orcid.org/0000-0003-2716-0218>

Introducción

Al año 2005, punto de partida de este estudio, Managua, capital de Nicaragua, abarcaba una superficie de 267.17 km² y tenía una población estimada de 937,489 habitantes, distribuida en 5 distritos, 618 barrios y 23 comarcas (Figura 1). Se trataba de una ciudad caracterizada por una producción del territorio fragmentada y dispersa, resultado de una gestión pública flexible. En este contexto, la estrategia de segmentación de la oferta de vivienda estuvo basada en la estratificación de la demanda a partir del ingreso, derivada de la Ley Especial para el Fomento de la Construcción de Vivienda y de Acceso a la Vivienda de Interés Social (Ley N° 677). Esto favoreció una relocalización espacial de los distintos grupos de ingreso en la ciudad, lo que estimuló transformaciones del patrón de segregación residencial asociadas a las escalas geográficas del fenómeno (Sánchez y Gómez, 2021).




Figura 1. Delimitación del área de estudio. Fuente: elaboración propia.

La segregación, según Linares (2013), hace referencia a la existencia de diferencias sociales dentro de un colectivo urbano, e implica el agrupamiento de individuos en función de características específicas, lo que favorece la homogenización interna y disminuye las interacciones con otros grupos.

Si bien la literatura actual al respecto tiene orientaciones diversas, el estudio del fenómeno ha sido impulsado por tres objetivos analíticos principales: i) la descripción de los patrones de segregación; ii) las causas de la segregación; y iii) las consecuencias de la segregación (Reardon, Matthews, O'Sullivan, Barrett, Firebaugh, Farrell, y Bischoff, 2008). Al aproximarse al estudio de los patrones de segregación residencial, resulta útil retomar las consideraciones de

Louf y Barthelemy (2016) quienes definen segregación como cualquier arreglo espacial de distribución de categorías que se desvía significativamente de una distribución aleatoria.

En este sentido, Sabatini (2015) sostiene que en Latinoamérica existe un patrón tradicional de segregación residencial, que puede resumirse en tres rasgos: i) una notable concentración espacial de los grupos de ingresos altos y medios ascendentes en un área de la ciudad, que parte del centro histórico con una trayectoria de crecimiento definida hacia la periferia, conformando lo que denomina como “cono de alta renta”; ii) la configuración de extensas áreas residenciales de los grupos de ingresos más bajos, localizadas en la periferia distante y subatendida, así como en sectores degradados cercanos al centro de la ciudad; y iii) la importante diversidad social del cono de alta renta, en el cual también residen grupos de ingresos medios y bajos.

Como señalan Hidalgo y Borsdorf (2005), las reformas económicas y cambios políticos ocurridos en la región a partir de los años ochenta, dieron lugar a nuevas dinámicas que han reconfigurado el patrón tradicional de segregación residencial en Latinoamérica. Esta transformación puede categorizarse en dos tendencias dialógicas vinculadas a la escala geográfica del fenómeno: i) una disminución de la distancia geográfica entre las áreas residenciales de los distintos grupos de ingreso, asociada a la proliferación de condominios y urbanizaciones cerradas; y ii) un aumento de la escala de la segregación, que afecta sobre todo a los nuevos hogares empobrecidos, asociado a su limitado acceso a la vivienda en zonas distantes de la periferia urbana.

Por tanto este capítulo busca ilustrar cómo, mediante la utilización del software ArcGIS, es posible aproximarse al fenómeno de la segregación residencial en Managua en el periodo 2005-2018, desde una postura geográfica que permite documentar sus patrones espaciales y tendencias, en tanto aborda cómo los grupos sociales en estudio se distribuyen en el espacio, o según Massey y Denton (como se cita en Gómez y Sánchez, 2021, p. 54), “el grado en el que dos o más grupos viven separados unos de otros, en diferentes partes del espacio urbano”.

Para tal fin, se plantea una ruta metodológica que recurrió al VIII Censo de Población y IV de Vivienda del año 2005 (INEC, 2006), para desagregar la variable educación en dos grupos sociales extremos (población sin educación formal y población con estudios terciarios), y utilizarla como variable proxy de segmentación socioeconómica en el análisis de una única dimensión espacial de la segregación residencial: el agrupamiento. Esto se operacionaliza a través de la Autocorrelación Local de Moran (ALM), un indicador espacial que mediante la aplicación del software ArcGIS permite determinar el patrón y las tendencias de la segregación residencial en Managua al año 2005.

Ante la carencia de datos censales actualizados que permitan el cálculo de la ALM al año 2018, el estudio también se apoya en el software ArcGIS para

la elaboración de un inventario georreferenciado de las viviendas producidas en el mercado formal en Managua entre 2005 y 2018. Este no solo posibilita determinar sus principales lógicas de localización, sino que además facilita captar y representar en el territorio las posibles transformaciones del patrón de segregación ocurridas en un periodo de trece años, a través de un análisis de superposición realizado con ArcGIS. Es decir que se trata de un estudio que privilegia un abordaje del fenómeno en términos cuantitativos, espaciales, descriptivos y relacionales.

Los resultados permiten concluir que, al año 2005, Managua exhibía un patrón de segregación en el que coexistían rasgos del patrón tradicional de segregación latinoamericano y cambios asociados a su proceso de transformación. De manera que, al año 2018, el patrón de segregación residencial de Managua mostraba transformaciones vinculadas a las lógicas de localización espacial de las viviendas producidas en el mercado formal en el periodo 2005-2018, entre las que destacaban: i) un aumento de la escala de segregación para hogares de los grupos de ingresos más bajos, asociado al acceso a vivienda subsidiada y altamente subsidiada en localizaciones periféricas desfavorables; y ii) una disminución de la escala de la segregación entre los grupos sociales en estudio, asociado a la dispersión de nuevos formatos residenciales para los grupos de ingresos superiores.

Así mismo, se puede concluir que, si bien en Managua el grupo social más segregado por agrupamiento es la población con educación terciaria o de ingresos superiores, la ciudad presenta un arreglo espacial al que se conoce como microsegregación, el cual es susceptible de ser interpretado como una característica positiva capaz de propiciar la conciliación espacial, o una característica negativa que apunta hacia la fractura social y la disputa. Sin embargo, el enfoque, la metodología y el alcance de este estudio únicamente brindan la posibilidad de poner en discusión dicha cuestión, más no proporcionan elementos teóricos ni empíricos que permitan solucionarla.

Los SIG como núcleo del análisis cuantitativo de la segregación residencial

Este subcapítulo trata de un estudio dentro del ámbito de la Geoinformática, el cual lleva a los sistemas de información geográfica (SIG) como núcleo, y busca brindar una explicación deductiva a la dimensión espacial de un fenómeno al que se le conoce como segregación residencial. Mediante los SIG, una entidad geográfica, en este caso la ciudad de Managua se modeló a través de dos componentes, el de la forma y el contenido, partiendo de una visión informática que posibilitó la creación y gestión de bases de datos gráficas y alfanuméricas que se vincularon a representaciones geométricas y mediciones cuantitativas (Buzai y Montes, 2021).

La noción de segregación residencial abordada en este estudio emplea un abordaje cuantitativo, espacial, descriptivo y relacional del fenómeno.

Para ello fue necesario establecer criterios de representatividad estadística y utilizar como fuente primaria de datos el VIII Censo de Población y el IV Censo de Vivienda de Nicaragua, realizados en 2005. Aunque los datos censales son de vieja data, como es usual en Centroamérica, estos son de buena calidad y permiten una aproximación efectiva al fenómeno en estudio a escala barrial.

El VIII Censo de Población y IV de Vivienda de Nicaragua carece de datos sobre la estratificación socioeconómica de los hogares encuestados. No obstante, permitió desagregar la variable educación en dos grupos extremos (población sin educación formal —grupo de ingresos bajos—, y población con educación terciaria —grupo de ingresos altos—). Esta clasificación se utilizó como proxy de segmentación socioeconómica en el análisis cuantitativo de una de las tres dimensiones espaciales de la segregación residencial, identificadas por Massey y Denton en 1988, centrándose específicamente en el agrupamiento (Figura 2).




Figura 2. Tres dimensiones espaciales de la segregación residencial. Fuente: adaptación desde Linares y Ramírez (2014).

La dimensión agrupamiento describe la proximidad entre unidades territoriales que contienen categorías de población similares, e indica si estas unidades se auto-correlacionan en su distribución, dando lugar a un patrón no aleatorio (Figura 3).

Según Domínguez (2017), en esencia esta dimensión evalúa la proximidad entre las unidades territoriales ocupadas por el mismo grupo social, destacando su inclinación a formar agrupaciones o clústeres en el espacio urbano.




Figura 3. Segregación espacial entendida a partir de la dimensión de agrupamiento. Fuente: Ruiz Tagle y López (2014).

Se analizó esta dimensión, porque frecuentemente se cuantifica a través de indicadores espaciales, los cuales pueden capturar con mayor eficacia cómo se distribuye espacialmente el fenómeno de la segregación residencial (Garrocho y Alanís, 2013; Ruiz Tagle y López, 2014). Dicha dimensión se operacionalizó a través de la Autocorrelación Local de Moran (ALM). Mediante la utilización de ArcGIS fue posible visualizar el patrón de segregación residencial para ambos grupos sociales en estudio en el año 2005, así como inferir sus tendencias.

La ALM resulta útil para conocer los fenómenos de agrupamiento o clustering (Sabatini, Wormald, Sierralta, y Peters, 2007). Este índice trabaja variables continuas en el espacio, para entregar variables categóricas que señalan si un área se encuentra o no dentro de un determinado clúster, el cual se define por el grado de autocorrelación entre el valor de una variable para una zona cualquiera y los valores para la misma variable en sus zonas vecinas.

Para ejecutar este análisis de forma precisa en el software ArcGIS, se requieren idealmente al menos 30 entidades de entrada que permitan reflejar las relaciones inherentes entre ellas, y visualizar cómo interactúan mutuamente en el espacio, por lo cual la ALM resultó idónea para calcularse a escala barrial.

La ALM se expresa así:

$$5. I_i = Z_i \sum_j W_{ij} Z_j$$

Donde:

Z_i y Z_j = se expresan en desviaciones de la media:

$$z_i = \left(\frac{x_i - \bar{x}}{\sigma} \right)$$

σ es la desviación estándar de x_i .

Según Lloyd (como se citó en Garrocho y Campos Alanís, 2013), la interpretación de este índice corresponde a las siguientes categorías:

- Bajo-Bajo: esta categoría abarca unidades espaciales caracterizadas por valores bajos de la población estudiada, rodeadas de otras unidades espaciales que también presentan valores bajos. Por ejemplo, barrios con un bajo porcentaje de población con educación terciaria que colindan con otros barrios que también registran valores bajos del mismo grupo de población. Estas zonas muestran una segregación significativa de población sin educación formal.
- Alto-Alto: esta categoría abarca unidades espaciales con valores altos de la población estudiada, rodeadas de otras unidades espaciales que también presentan valores altos. Por ejemplo, barrios con un alto porcentaje de población con educación terciaria que colindan con otros barrios que también registran valores altos del mismo grupo de población.

Estas zonas muestran una segregación significativa de la población con educación terciaria.

- Bajo-Alto: esta categoría abarca unidades espaciales con valores bajos de la población estudiada, rodeadas de unidades espaciales con valores altos. Por ejemplo, barrios con un bajo porcentaje de población con educación terciaria que colindan con barrios que registran valores altos del mismo grupo de población. Estas zonas muestran una segregación no significativa de la población con educación terciaria.
- Alto-Bajo: esta categoría abarca unidades espaciales con valores altos de la población estudiada, rodeadas de unidades espaciales con valores bajos. Por ejemplo, barrios con un alto porcentaje de población con educación terciaria que colindan con barrios que registran valores bajos del mismo grupo de población. Estas zonas muestran una segregación no significativa de la población con educación terciaria, y una alta probabilidad de interacción con población sin educación formal.
- Estadísticamente no significativa: esta categoría se refiere a unidades espaciales caracterizadas por valores estadísticamente insignificantes, donde los valores de segregación no pueden determinarse con fiabilidad.

La carencia de datos censales para el año 2018 imposibilitó el cálculo de la ALM y la visualización del patrón de segregación residencial por agrupamiento, para ambos grupos sociales, en el estudio de ese año. Esto derivó en la búsqueda de una alternativa metodológica que posibilitara captar y representar en el territorio las posibles transformaciones de este, trece años después. Con este fin, se optó por apoyarse en el software ArcGIS para elaborar un inventario georreferenciado que descubriera las lógicas de localización de la vivienda producida en el mercado formal entre 2005 y 2018, clasificada en tres categorías asociadas al monto máximo de subsidio establecido por la Ley 677, con la intención de estimular su construcción: vivienda altamente subsidiada, vivienda subsidiada, y vivienda no subsidiada.

Finalmente, se realizó un análisis de superposición (Overlay Analysis) con ArcGIS, el cual permitió unir dos capas o layers basándose en su relación espacial. En este caso, se trató de las capas del patrón de segregación residencial por agrupamiento para cada grupo social en estudio, y de las lógicas de localización de la vivienda producida en el mercado formal en Managua entre 2005 y 2018, clasificada por monto de subsidio definido para su construcción. Esto se realizó con el propósito de vincular las lógicas de localización de la vivienda con las transformaciones del patrón de segregación residencial y sus tendencias.

Es decir que, a través de la aplicación de los SIG, este estudio logró operativizar 3 conceptos fundamentales del Análisis Espacial: Distribución Espacial, Localización y Asociación Espacial, en ese orden. Lo hizo, primero, al determinar cómo un conjunto de entidades de un mismo tipo se reparte

en el espacio geográfico hasta formar un patrón definido; posteriormente, al considerar que todas las entidades tienen una ubicación, cuya posición específica respecto de otras permite establecer vínculos funcionales, y, por último, al comparar mediante un análisis visual la superposición cartográfica de dos distribuciones espaciales (Buzai y Montes, 2021).

Los patrones y tendencias de la segregación residencial en Managua

El cálculo del ALM permitió identificar clústeres en la ciudad al año 2005. En escala barrial, la población sin educación formal se agrupaba en algunas áreas de la periferia distante, así como cerca del área central de Managua y el Lago Xolotlán (Figura 4). En contraste, la población con educación terciaria se agrupaba principalmente en una zona de crecimiento denominada el “cono de alta renta”, que conecta el centro de Managua con la periferia a lo largo de un eje geográfico claramente definido en dirección NO-SE. Esta zona se extiende por Carretera a Masaya y Carretera Sur, y ciertas áreas suburbanas (Figura 5). Los resultados también revelan que la población con educación terciaria se agrupaba con mayor intensidad que la población sin educación formal.




Figura 4. Autocorrelación espacial según porcentaje de población sin educación formal al año 2005. Fuente: elaboración propia.




Figura 5. Autocorrelación espacial según porcentaje de población con educación terciaria al año 2005. Fuente: elaboración propia.

Por otro lado, el inventario georreferenciado de la vivienda producida con participación del Estado y el capital inmobiliario entre 2005 y 2018, evidenció una localización fragmentada principalmente en siete sectores, a los cuales se ha denominado: Central, Carretera Norte, Carretera Vieja a León, Carretera Sur, Aeropuerto, Carretera Nueva a León, y Carretera a Masaya. Esto se expresó, en el año 2018, a través de un patrón de expansión urbana híbrido (tentaculado y fragmentado) que fue estimulado por un proceso de expansión de la ciudad formal sobre suelos adyacentes a las principales vialidades de Managua, el cual se observa como un crecimiento discontinuo a manera de piezas residenciales fuera del área urbana consolidada (Figura 6).

La superposición entre las capas de los patrones de segregación por agrupamiento para cada uno de los grupos sociales bajo análisis al año 2005, y la capa del inventario correspondiente a la vivienda producida entre 2005 y 2018, clasificada por monto de subsidio definido para su construcción, evidenció que las localizaciones están asociadas a la capacidad de compra de la demanda (Figura 7). Los grupos de ingresos medios, medios ascendentes y altos, es decir, aquellos que pudieron acceder a vivienda no subsidiada a través del mercado, usualmente se localizan dentro del cono de alta renta, en los sectores Central, Carretera a Masaya, Carretera Sur, y Carretera Vieja a León, así como en medio de áreas rurales históricamente habitadas por grupos de ingresos bajos y muy bajos, pero adyacentes a barrios de alta renta (Figuras 7 y 8).




Figura 6. Producción de vivienda por sector urbano entre los años 2005 y 2018.
Fuente: elaboración propia.




Figura 7. Residenciales por monto de subsidio definido para su construcción entre 2005 y 2018. Fuente: elaboración propia.




Figura 8. Superposición entre el patrón de segregación residencial por agrupamiento para la población con educación terciaria al año 2005 y las lógicas de localización de la vivienda producida entre 2005 y 2018. Fuente: elaboración propia.

Para los grupos de ingresos medios bajos, particularmente hogares nuevos que accedieron a una vivienda social subsidiada a través del mercado, se destinaron localizaciones tanto cercanas, como lejanas al borde urbano o en centros poblados menores (Carretera Nueva a León y Carretera Norte). Finalmente, para los grupos de ingresos bajos y muy bajos, es decir, aquellos que accedieron a soluciones habitacionales mínimas a través de altos subsidios o subsidios no recuperables, la oferta de vivienda se localizó en pequeños vacíos urbanos alrededor del área central y cercanos al Lago Xolotlán, pero principalmente en espacios abiertos cercanos al borde urbano, estructuralmente pobres, mal servidos y escasamente integrados, como es el caso del Sector Aeropuerto (Figura 9).

En resumen, los resultados indican lo siguiente: i) el grupo con mayor nivel de agrupamiento o más segregado es el de la población con educación terciaria; ii) Managua ha experimentado un aumento de la segregación entre los hogares de los grupos de ingresos más bajos, lo cual se vincula con el acceso a vivienda subsidiada y altamente subsidiada en localizaciones periféricas desfavorables; y iii) Managua presenta un arreglo espacial conocido como segregación de pequeña escala o micro-segregación. Este fenómeno refleja una disminución en la escala geográfica de la segregación, lo que resulta en distancias físicas más cortas entre los diferentes grupos sociales estudiados. Esto puede entenderse

como una ampliación del cono de alta renta hacia áreas adyacentes que históricamente estaban habitadas por grupos de ingresos más bajos.




Figura 9. Superposición entre el patrón de segregación residencial por agrupamiento para la población sin educación formal al año 2005 y las lógicas de localización de la vivienda producida entre 2005 y 2018. Fuente: elaboración propia.

Una lectura geográfica de los patrones de segregación residencial en Managua

Los resultados demuestran que los indicadores espaciales de segregación, como el ALM, ofrecen una alternativa robusta y altamente efectiva para analizar el fenómeno de la segregación en términos cuantitativos, descriptivos y relacionales. Este estudio proporcionó una visualización clara de cómo, en Managua, las unidades territoriales habitadas por el mismo grupo social se ubican próximas entre sí, a menudo formando agrupamientos o clústeres en el espacio urbano (Domínguez, 2017). Esto subraya la capacidad de ArcGIS y sus herramientas de análisis espacial para ilustrar eficazmente cómo se distribuye espacialmente el fenómeno de la segregación.

Por otro lado, ello permite discutir cómo la segmentación de la oferta de vivienda basada en la estratificación de la demanda a partir del ingreso, promovida por el Estado y los capitales inmobiliarios y financieros en Nicaragua, se articuló hacia una búsqueda de distinción espacial por parte de los grupos de ingresos superiores (Sánchez y Gómez, 2021; Abramo, 2011), hasta resultar

en la configuración de una estructura urbana socioespacialmente fragmentada, que impacta directamente en cómo opera el fenómeno de la segregación residencial, principalmente a partir de dos tendencias:

1. Un aumento de la escala de la segregación para los hogares nuevos de los grupos de ingresos más bajos, vinculado a un acceso a vivienda subsidiada y altamente subsidiada en localizaciones distantes del borde urbano, o en medio de áreas donde predominan los grupos de ingresos bajos y muy bajos.
2. Una reducción de la escala geográfica de la segregación o acortamiento de las distancias físicas entre los grupos sociales en estudio, asociado a la dispersión de nuevos formatos residenciales promovidos por el capital inmobiliario para los grupos de ingresos superiores.

El análisis espacial apunta a la emergencia y consolidación de estas dos tendencias que suponen una notoria transformación del patrón tradicional de segregación latinoamericano en Managua, asociada a las escalas geográficas del fenómeno, lo cual se asemeja a lo descrito por Sabatini, et al. (2001) para las principales ciudades chilenas. De acuerdo a Fernández (2004), esto parece derivar de “una configuración y cualificación selectiva del espacio urbano” (p. 19), a partir de la que se promueven procesos de fragmentación socioespacial que facilitan simultáneamente el agrupamiento y concentración de los grupos de ingresos superiores, y la insularización de los grupos de ingresos más bajos que logran acceder a vivienda a través de mecanismos formales dispuestos por el Estado y el mercado (Hidalgo y Borsdorf, 2005; Rasse, 2015).

Además, esto evidencia la persistencia de la segregación residencial por ingresos, lo que se traduce en el desplazamiento de los grupos de ingresos más bajos a zonas periféricas desfavorecidas en proximidad a entornos barriales, donde los más pobres se hallan segregados y altamente segregados, lo cual no solo los restringe de la posibilidad de habitar la ciudad y gozar de las oportunidades y beneficios que esta brinda, sino que además los hace propensos a la estigmatización territorial (Hidalgo y Borsdorf, 2005; Molinatti y Peláez, 2017).

Lo anterior apunta a la urgencia de colocar al centro del debate urbano contemporáneo el rol de la localización en el diseño de las políticas habitacionales y urbanas. También ilustra cómo las dinámicas de periferización de la vivienda se experimentan de forma diferenciada entre los grupos sociales. Para los grupos de ingresos más bajos, residir en áreas periféricas con escasa integración urbana resulta sumamente desventajoso, confinándolos a menudo a lo que Wacquant (2007) denomina como “territorios de relegación urbana”. Por el contrario, para los grupos de ingresos superiores, la relocalización espacial usualmente implica un traslado a localizaciones próximas a sus áreas

tradicionales de residencia en el cono de alta renta, en proximidad a subcentros comerciales, de oficinas y servicios, o adyacentes a áreas suburbanas medioambientalmente privilegiadas, donde los grupos de ingresos más bajos no se agrupan con intensidad.

Finalmente, los resultados también posibilitan discutir si la segregación a pequeña escala o micro-segregación que presenta Managua (Sánchez, Gómez, Mayorga y Rocha, 2017), asociada a la colindancia entre barrios populares y barrios de alta renta, puede considerarse no solo como una evidencia clara de la ruptura del patrón tradicional de segregación latinoamericano (Sabatini, 2015), sino también como una tendencia positiva y hasta una oportunidad para revertir parcialmente la segregación residencial a través de la política pública (Urrutia Mosquera, López Ospina, Sabatini y Rasse, 2017), o realmente los resultados apuntan a un aumento de la segregación efectiva, es decir, a la existencia de una coexistencia difícil o ignorancia mutua entre grupos sociales que, a pesar de la proximidad espacial, se encuentran socialmente divididos y prácticamente incomunicados (Caldeira, 1996; Hidalgo, 2004; Capron y González, 2006).

Conclusiones

Cuantificar la segregación residencial mediante un enfoque metodológico como el propuesto en este capítulo, permite capturar eficazmente su naturaleza geográfica a pesar de las limitaciones existentes, como la carencia de datos censales actualizados. No obstante, es fundamental considerar la multidimensionalidad espacial y la multiescala de este fenómeno. De manera que sea posible ofrecer perspectivas más completas que reduzcan posibles vacíos o sesgos.

También es posible concluir que, al año 2005, Managua exhibía un patrón de segregación caracterizado por la coexistencia de rasgos del patrón tradicional de segregación latinoamericano, y cambios asociados a su proceso de transformación, entre los que se distinguen: i) el agrupamiento de los grupos de ingresos superiores en un área denominada cono de alta renta, que une el área central de Managua con la periferia en dirección NO-SE, en función de vialidades como la Carretera Norte y Carretera a Masaya; ii) el agrupamiento de los grupos de ingresos más bajos, tanto en la periferia como en áreas deterioradas cercanas al área central de la ciudad y la costa del Lago Xolotlán; y iii) una tendencia incipiente de relativa dispersión de alternativas de desarrollo residencial para los grupos de ingresos superiores en áreas adyacentes al cono de alta renta.

Al año 2018, el patrón de segregación residencial de Managua exhibía transformaciones vinculadas a las lógicas de localización espacial de la vivienda producida en el mercado formal en el periodo 2005-2018, entre los que destacan: i) el aumento de la escala de segregación para hogares de los grupos de ingresos más bajos, asociado al acceso a vivienda subsidiada y altamente

subsidiada en localizaciones periféricas desfavorables, y ii) la reducción de la escala geográfica de la segregación o acortamiento de las distancias físicas entre los grupos sociales en estudio, lo cual se muestra al año 2018 como un rasgo característico. Esto se asocia a cambios en el funcionamiento del mercado de suelo y de los mercados de suelo y vivienda, favorecidos por la política habitacional nicaragüense, cambios que potenciaron el agrupamiento de los grupos de ingresos en aglomeraciones con tendencia a la homogeneidad interna y la reducción de sus interacciones con otros grupos sociales.

Al respecto de esto último, se puede concluir que si bien Managua se caracteriza por una segregación a pequeña escala o micro-segregación, la cual al 2018 es posible asociar al acortamiento de las distancias físicas entre los grupos sociales en estudio, el considerar esta característica como positiva (es decir que habla de un espacio propicio para la conciliación espacial) o negativa (que apunta hacia la fractura social y la disputa), requeriría un estudio adicional con un alcance, enfoque y metodología distintos, que proporcionen una mejor comprensión de los efectos de dicha proximidad a nivel de campo, y den cuenta de la preferencia por vivir con “iguales”, o de la disposición a la integración social de quienes habitan estos barrios.

Referencias

- Abramo, P. (2011). *La ciudad caleidoscópica. Coordinación espacial y convención urbana: una perspectiva heterodoxa para la economía urbana*. Universidad Externado de Colombia.
- Buzai, G., y Montes, E. (2021). *Estadística Espacial: Fundamentos y aplicación con Sistemas de Información Geográfica*. Editorial Buenos Aires Impresiones.
- Caldeira, T. (1996). Fortified Enclaves: The New Urban Segregation. *Public Culture*, 8(2), 303-328. <https://doi.org/10.1215/08992363-8-2-303>
- Capron, G., y González, A. (2006). Las escalas de la segregación y de la fragmentación urbana. *Trace*, 49, 65-75.
- Domínguez, M. (2017). Las dimensiones espaciales de la segregación residencial en la Ciudad de Mérida, Yucatán, a principios del siglo XXI. *Revista Península*, 12(1), 147-188. <https://doi.org/10.1016/j.pnsla.2017.01.007>
- Fernández, R. (2004). Construcción y deconstrucción histórica de lo social en el acceso a los bienes y servicios del hábitat. *Revista INVI*, 19(50), 11-20. <https://doi.org/10.5354/0718-8358.2004.62197>
- Garrocho, C., y Campos Alanís, J. (2013). Réquiem por los indicadores no espaciales de segregación residencial. *Papeles de población*, 19(77), 269-300.
- Gómez, R., y Sánchez, P. (2021). La segregación fragmentada en la ciudad de Managua, Nicaragua. En Alvarado, C., Saldívar, A., y Ruiz, C. (Eds.), *Territorios fragmentados. Posibles realidades latinoamericanas*. Universidad Nacional

- Autónoma de México y Universidad Autónoma del Estado de Morelos. <https://doi.org/10.22201/ciga.9786073048507e.2022>
- Hidalgo, R. (2004). De los pequeños condominios a la ciudad vallada: las urbanizaciones cerradas y la nueva geografía social en Santiago de Chile (1990-2000). *EURE*, 30(91), 29-52. <https://doi.org/10.4067/S0250-71612004009100003>
- Hidalgo, R., y Borsdorf, A. (2005). La exclusión residencial y el desarrollo de la ciudad moderna en América Latina: De la polarización a la fragmentación. El caso de Santiago de Chile. *Geographica*, 48, 5-29. https://doi.org/10.26754/ojs_geoph/geoph.2005481322
- Instituto Nacional de Estadísticas y Censos (INEC). (2006). VIII Censo de Población y IV de Vivienda. Recuperado de <https://www.inide.gob.ni/docu/censos2005/CifrasCompleto.pdf>
- Ley 677 del 2009. Ley Especial para el fomento de la construcción de vivienda y acceso a la vivienda de interés social. 29 de abril de 2009. D.O. No. 80 y 81.
- Linares, S. (2013). Las consecuencias de la segregación socioespacial: un análisis empírico sobre tres ciudades medias Bonaerenses (Olavarría, Pergamino y Tandil). *Cuaderno Urbano*, 14(14), 6-30. [O](#)
- Linares, S., y Ramírez, I. (2014). Segregación espacial de minorías étnicas: Propuesta metodológica y análisis empírico de la población indígena en el Área Metropolitana de Pachuca (2000 y 2010). *Plaza Pública*, 7 (12), 158-179.
- Louf, R., y Barthelémy, M. (2016). Patterns of Residential Segregation. *PLoS One*, 11(6). <https://doi.org/10.1371/journal.pone.0157476>
- Massey, D., y Denton, N. (1988). The dimensions of residential segregation. *Social Forces*, 67(2), 281-315. <https://doi.org/10.1093/sf/67.2.281>
- Molinatti, F., y Peláez, E. (2017). La localización como factor crítico. Análisis del programa "Mi casa, mi vida". Córdoba, Argentina. *Cuadernos de Economía*, 36(71), 521-548. <https://doi.org/10.15446/cuad.econ.v36n71.55748>
- Rasse, A. (2015). Juntos, pero no revueltos. Procesos de integración social en fronteras residenciales entre hogares de distinto nivel socioeconómico. *EURE*, 41(122), 125-143. <https://doi.org/10.4067/S0250-71612015000100006>
- Reardon, S., Matthews, S., O'Sullivan, D., Lee, B., Firebaugh, G., Farrell, C., y Bischoff, K. (2008). The Geographic Scale of Metropolitan Racial Segregation. *Demography*, 45(3), 489-514. <https://doi.org/10.1353/dem.0.0019>
- Ruiz Tagle, J., y López, E. (2014). El estudio de la segregación residencial en Santiago de Chile: revisión crítica de algunos problemas metodológicos y conceptuales. *EURE*, 40(119), 25-48. <https://doi.org/10.4067/S0250-71612014000100002>
- Sabatini, F. (2015). La ruptura del patrón de segregación y su significado teórico y práctico. En Aguilar, A. y Escamilla, I. (Ed.), *Segregación urbana y espacios de exclusión. Ejemplos de México y América Latina* (pp. 25-46). México, Miguel Ángel Porrúa.

- Sabatini, F., Cáceres, G., y Cerda, J. (2001). Segregación residencial en las principales ciudades chilenas: tendencias de las tres últimas décadas y posibles cursos de acción. *EURE*, 27 (82), 21-42. <https://doi.org/10.4067/S0250-71612001008200002>
- Sabatini, F., Wormald, G., Sierralta, C., y Peters, P. (2007). *Segregación residencial en Santiago: Tendencias 1992-2002 y efectos vinculados con su escala geográfica*. Chile: Instituto de Estudios Urbanos, Pontificia Universidad Católica de Chile.
- Sánchez, P., y Gómez, R. (2021). Indicadores espaciales y no espaciales. Un enfoque complementario para el análisis cuantitativo de la segregación residencial en la ciudad de Managua. *Urbano*, 24(43), 52-61. <https://doi.org/10.22320/07183607.2021.24.43.05>
- Sánchez, P., Gómez, R., Mayorga, Y., y Rocha, A. (2017). Patrón y tendencias de la segregación residencial socioeconómica en la ciudad de Managua. Memorias del Congreso de Estudios de la Ciudad, Cuenca, Ecuador.
- Urrutia Mosquera, J., López-Ospina, H., Sabatini, F., Rasse, A. (2017). Tolerancia a la diversidad y segregación residencial. Una adaptación del modelo de segregación de Schelling con tres grupos sociales. *EURE*, 41(130), 5-24. <https://doi.org/10.4067/s0250-71612017000300005>
- Wacquant, L. (2007). *Los condenados de la ciudad. Gueto, periferias y Estado*. Siglo XXI.

02

Línea temática

Procesos
urbanos.
Habitabilidad
y transformación
socioespacial

Capítulo VII. Desigualdad socioespacial del tiempo empleado en la movilidad cotidiana de la Zona Metropolitana de Valle de México

Margarita Ruiz Camacho¹

Ricardo Gómez Maturano²

Este trabajo contó con el apoyo de los proyectos de investigación PRORED "Sistema Autónomo de Monitoreo del Tránsito Urbano para la Investigación Aplicada en Movilidad de Ciudades Intermedias" (Proyecto No. 20254782) y SIP "Monocentrismo o policentrismo en la Zona Metropolitana del Valle de México" (SIP 20250563) del

Instituto Politécnico Nacional.

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA), Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

Este capítulo aporta información sobre el tiempo que emplean los habitantes de la ZMVM en sus viajes cotidianos, tomando en cuenta el enfoque de la justicia espacial. Se trata de un estudio descriptivo, que analiza a nivel geoestadístico la Encuesta Origen Destino 2017, con el propósito de contrastar los patrones de movilidad presentes en la periferia respecto de los que se observan en área central, y en relación con el tiempo que emplean los habitantes de la ZMVM en sus viajes cotidianos, tomando en cuenta el estrato socioeconómico al que pertenecen y su ubicación espacial. Los resultados revelan que los estratos medios y altos están relacionados con el funcionamiento del modelo centro-periferia, el cual revela que, a mayor distancia, mayor tiempo empleado. En contraste, los estratos bajos que viven en la periferia no responden a dicho modelo, mostrando diferentes patrones de movilidad, tanto en viajes internos como en viajes externos.

Palabras clave: movilidad cotidiana, justicia espacial, tiempo empleado.

Abstract

This chapter provides information on the time spent by the inhabitants of the ZMVM in their daily trips, considering the spatial justice approach. It is a descriptive study, which analyzes at a geostatistical level, the 2017 Origin Destination Survey, with the purpose of contrasting the mobility patterns present in the periphery, with those observed in the central area, in relation to the time spent by the inhabitants of the ZMVM in their daily trips, taking into account the socioeconomic stratum to which they belong and their spatial location. The

1 Candidata a Doctora en Ciencias en Arquitectura y Urbanismo en el Instituto Politécnico Nacional, Sección de Posgrado. Maestra en Ciencias en Arquitectura y Urbanismo, IPN. Ingeniero Arquitecto, Escuela Superior de Ingeniería y Arquitectura IPN. Correo: mruizc2200@alumno.ipn.mx, ORCID: <https://orcid.org/0000-0002-1854-7341>

2 Profesor e investigador en el Instituto Politécnico Nacional, ESIA, Unidad Tecamachalco, SEPI. Doctor en Urbanismo, UNAM. Maestro en Ciencias en la Especialidad de Arquitectura e Ingeniero Arquitecto, IPN. Correo: rgomezma@ipn.mx, ORCID: <https://orcid.org/0000-0002-8027-8648>

results reveal that the middle and upper strata are related to the functioning of the center-periphery model, which reveals that, the greater the distance, the more time spent. In contrast, the lower strata living in the periphery do not respond to this model, showing different patterns of mobility, both in internal and external trips.

Keywords: daily mobility, spatial justice, time spent.

Introducción

La migración ocurrida en las décadas de los 40s y los 50s, dio como resultado una urbanización acelerada tanto en zonas centrales, como en sus áreas circundantes. Considerando que la población de bajos ingresos no contaba con un empleo formal, el mercado formal de vivienda excluyó a dicha población del acceso a la misma, lo que generó el establecimiento de estos sectores de población en las periferias, quienes a través de la formación de asentamientos humanos irregulares lograban el acceso a la vivienda, originándose con ello una separación entre el lugar donde vivían y el lugar donde trabajaban (Rodríguez, 2008; Cruz e Isunza, 2017).

En relación con el acceso a los servicios de transporte, dichas desigualdades socioespaciales implicaron la exclusión de los habitantes más pobres desde el área central hacia la periferia, tomando en cuenta que el suelo y la vivienda son más baratos allí. Al mismo tiempo, debido a su ubicación periférica, la lejanía respecto al centro y los tiempos de viaje aumentaron en gran medida, condicionando una gran dependencia de las personas de bajos ingresos con respecto a su entorno inmediato (Calonge, 2019).

De forma paralela, se observa que la Encuesta Origen-Destino 2017 (EOD, 2017) se encuentra conformada por una base de datos que contiene la información estadística, así como por un informe de resultados. No se observa, sin embargo, un análisis que profundice en la problemática de la movilidad cotidiana en la Zona Metropolitana del Valle de México (ZMVM), por lo que la finalidad de esta investigación es contrastar los patrones de movilidad presentes en la periferia respecto de los que se observan en el área central, y en relación con el tiempo que emplean los habitantes de la ZMVM en sus viajes cotidianos, tomando en cuenta el estrato socioeconómico al que pertenecen, y su ubicación espacial.

Observación a los estudios de movilidad neutros

Inicialmente, el estudio de la movilidad mostraba investigaciones descriptivas que se enfocaban en definirla y en relacionarla con el transporte; otros estudios abordan la congestión vehicular desde un enfoque ambiental, diferenciando las ventajas de un transporte público eficiente contra las desventajas de un transporte público ineficiente (Lizarraga, 2006; Garduño, 2009). En estos estudios descriptivos se observa una posición neutral acerca

de la movilidad, donde no se profundiza en las causas que ocasionan que este tema actualmente sea un problema en la ZMVM.

En lo sucesivo, se observan investigaciones que relacionan la movilidad con la accesibilidad. Estas investigaciones abordan el aislamiento y la inaccesibilidad, y toman en cuenta los costos y las dificultades que pueden presentarse en los desplazamientos diarios, relacionando estas desventajas con la ubicación periférica en distintas regiones en Latinoamérica (Avellaneda y Lazo, 2011; Torales, 2020).

Otros autores añaden a los estudios de movilidad la cuestión espacial y temporal, resaltando el hecho de que la movilidad no solo depende de la capacidad que tiene el individuo para moverse, sino que destacan que la movilidad depende también de los elementos territoriales asociados (Kaufmann, et al., 2004; Módenes, 2008; Gutiérrez, 2012; Casado, 2008).

En esta correlación entre las características del territorio y la movilidad, algunos autores otorgan más valor a la ubicación del lugar de trabajo, las viviendas y las unidades económicas, ya que para ellos la ubicación espacial influye determinantemente en la movilidad, resaltando que en las periferias existen territorios dispersos, donde no hay un sistema de transporte eficiente que permita la conexión con los servicios urbanos (Kralich, 1999; Gutiérrez, 2010; Torales, 2020).

Por último, en relación con los estudios de movilidad en áreas periféricas, los tiempos de viaje observados en México muestran que los trabajadores de bajos ingresos tienen los viajes más cortos debido al mayor porcentaje de ingresos que esos sectores deben gastar en transporte, desplazándose, por consecuencia, únicamente al interior del distrito donde viven (Suárez, et al., 2016). Al respecto, Calonge (2019) realiza una caracterización de los hogares según los recursos de que disponen para sus desplazamientos, mostrando hogares que pueden ampliar su horizonte territorial, y aquellos hogares que se conforman con bienes y servicios básicos ofrecidos en su entorno inmediato.

Al respecto de la justicia espacial

En relación con los estudios que preceden al concepto justicia espacial, existen investigaciones que abordan las distribuciones desiguales e injustas que se daban a partir del funcionamiento habitual de la ciudad (Lefebvre, 1968). Algunos años más tarde, Rawls (1979) plantea el ideal igualitario; aunque en este punto aún no se observaba una perspectiva espacial, sino que se utilizaba el concepto de justicia social, contemplando el beneficio de los más necesitados. De forma paralela, Harvey (1979) resalta la importancia de pensar espacialmente, e introduce el concepto de justicia social territorial para abordar las desigualdades socioespaciales que se presentan en los territorios menos aventajados.

En 1980, Soja resalta que la clase se asocia tanto con las relaciones sociales (verticales) como espaciales (horizontales) en una interacción dialéctica, relacionando la estructura horizontal con los centros dominantes de producción y las periferias dependientes. Por último, Ramírez (2003) señala que la justicia espacial está directamente relacionada con el grado de accesibilidad, así como con la lejanía, el tiempo de traslado, y el gasto económico que representa para un individuo desplazarse diariamente hacia su destino.

Movilidad cotidiana y justicia espacial

Estudios recientes introducen un enfoque donde la movilidad deja de ser vista de forma imparcial como un fenómeno aislado, diferenciándose de aquellos estudios que buscaban únicamente la descripción del concepto. En los últimos años se han realizado investigaciones en donde, de forma precisa, se relaciona el concepto de movilidad con la idea de una sociedad justa, situación que se sugiere podrá ser factible a través del acceso equitativo al transporte público, tomando en cuenta el estrato socioeconómico de cada individuo (Farber, et al., 2016; Qiao y Yeh, 2023).

En esta nueva era, donde se habla de la existencia de una movilidad desigual, se resalta la importancia de considerar tanto al espacio físico como a la estructura socioeconómica, tal como lo señalaba Harvey (1979), al implementar la idea de una estructura vertical y una estructura horizontal. Por lo tanto, existen autores que retoman el concepto de justicia espacial para plantear la idea de que los territorios más desfavorecidos se ubican en la periferia, mientras que los más favorecidos se ubican en las principales zonas de actividad económica (Hernández, 2018; Blanco y Apaolaza, 2018; Toscana y De Jesús, 2018). Por último, algunas investigaciones recientes se han dado a la tarea de establecer caracterizaciones de la ZMVM, a través del análisis de las características sociales de los individuos y tomando en cuenta la organización del territorio (Toscana y De Jesús, 2018; Valette, et al., 2022).

Análisis geoestadístico del tiempo empleado al viajar por cada estrato socioeconómico

Se consideró un enfoque cuantitativo, donde los datos recopilados corresponden al tiempo de viaje. La finalidad de ello, es medir dicho indicador y analizarlo espacialmente a través de la geografía cuantitativa (Buzai y Montes, 2021), tomando en cuenta los distritos que conforman la ZMVM, así como el estrato socioeconómico. Al respecto, Buzai y Montes (2021) indican que la geografía cuantitativa incluye los datos estadísticos no únicamente como un avance metodológico, sino como una forma de acceder a la realidad utilizando herramientas informáticas en formato digital.

Partiendo del análisis espacial de una realidad geográfica (ZMVM), se toman en cuenta los datos estadísticos que, desde lo conceptual y lo teórico,

permiten visualizar la variable movilidad cotidiana y la variable justicia espacial a partir de los Sistemas de Información Geográfica (SIG), todo ello con la finalidad de comprobar lo que afirmaba Soja (1980) acerca de que existe una homología espacial con la estructura de clases, ya que la clase se asocia tanto con las relaciones sociales (verticales) como espaciales (horizontales) de producción, en una interacción dialéctica. Ramírez (2003), por su parte, indica que la justicia espacial está directamente relacionada con el grado de accesibilidad, así como la lejanía, el tiempo de traslado y el gasto económico que representa para un individuo desplazarse diariamente hacia su destino.

Hernández Sampieri, (2016), mencionan que el método cuantitativo se caracteriza por considerar planteamientos específicos y delimitados desde el inicio, de tal manera que se hace recolección de datos por cada variable y/o concepto, en este caso, desde la movilidad cotidiana desde su dimensión basada en el tiempo (tiempo de viaje). Por otro lado, se recolectan datos acerca de la justicia espacial en relación con la estructura vertical (estrato socioeconómico) y la estructura horizontal (contorno al que pertenecen). Esos datos corresponden al año 2017.

A partir de lo anterior, se deduce que la movilidad cotidiana, como variable dependiente, está condicionada en gran medida por la ubicación espacial y el estrato socioeconómico al que pertenece el individuo, y como ya se ha observado, estos últimos son indicadores de la variable independiente, es decir, de la justicia espacial. Para este caso, se tomaron en primer lugar los datos de la variable 1 movilidad cotidiana, desde su dimensión basada en el tiempo (tiempo de viaje), con datos de la EOD 2017, a partir de su distribución espacial entendida como el “conjunto de entidades de un mismo tipo que se reparten de una determinada manera en el espacio geográfico” (Buzai y Montes, 2021, p. 33). Esto permitió observar los patrones de movilidad cotidiana de la ZMVM en relación con la dimensión basada en el tiempo, planteada por Oviedo y Titheridge (2016).

En segundo lugar, se tomaron en cuenta los datos de la variable 2 justicia espacial, a partir del estrato socioeconómico (estrato bajo, medio y alto), así como la ubicación espacial (ciudad central y los 4 contornos que conforman la ZMVM), diferenciando con ello los distintos estratos socioeconómicos (estructura vertical). Por otro lado, la estructura horizontal representada a través de los contornos que conforman la ZMVM, se encuentra basada en el modelo de círculos concéntricos de Burgues, tratándose de una interpretación del modelo original, con la peculiaridad de que dichos contornos han sido definidos tomando en cuenta su urbanización a través del tiempo y no solamente por su proximidad geográfica.

Para esta investigación se utilizan los datos tanto de la variable independiente (justicia espacial), como de la dependiente (movilidad cotidiana), mediante la asociación espacial que se da entre las “relaciones encontradas al comparar distintas distribuciones espaciales” (Buzai y Montes, 2021, p. 35)

mediante la superposición cartográfica de dos distribuciones. En este caso, en cuanto a la variable dependiente, se analizaron los datos del tiempo de viaje en relación con la variable independiente, es decir, se filtró la información separándola por estrato socioeconómico (estructura vertical), y se superpuso esta distribución con la que corresponde a la ubicación espacial (estructura horizontal).

Este análisis plantea un estudio de alcance descriptivo, que tiene como propósito realizar comparaciones entre grupos o subgrupos de personas. Según Hernández Sampieri, et al. (2006), los estudios descriptivos especifican patrones de un grupo o población. En este caso, el objetivo de esta investigación es analizar los patrones de movilidad cotidiana desde el enfoque de la justicia espacial, por lo que se describen las tendencias de cada estrato socioeconómico (estructura vertical) en materia de movilidad cotidiana, y en relación con el tiempo empleado, tomando en cuenta su ubicación espacial (estructura horizontal) dentro la ZMVM.

De manera concreta, en cuanto a la investigación descriptiva transversal, se buscó ver cómo se distribuye la información respecto al indicador tiempo de viaje perteneciente a la variable 1 movilidad cotidiana, tomando en cuenta el estrato socioeconómico (estructura vertical), correspondiente a la variable 2 justicia espacial. Una vez que se obtuvo la primera asociación espacial entre el tiempo de viaje y el estrato socioeconómico, se agregó una nueva distribución espacial correspondiente a viajes internos (dentro del mismo distrito), respecto de viajes externos (de un distrito a otro), tomando en cuenta la estructura horizontal de la variable 2 justicia espacial. Con ello se obtuvo la asociación espacial que muestra el tiempo empleado en viajes internos o externos realizados por cada estrato socioeconómico. Finalmente, a esta asociación se le sobrepuso la distribución espacial que corresponde a los contornos que conforman la ZMVM (estructura horizontal), para con ello mostrar el tiempo empleado en viajes internos o externos realizados por estrato socioeconómico en cada contorno de la ZMVM.

De esta manera, se inició la búsqueda, selección y filtro de información estadística y geográfica. En primer lugar, se descargó el mapa que contiene los distritos de la Encuesta Origen-Destino de la ZMVM 2017, a través de la siguiente liga EstudioOD-ZMVM-2017 | EOD-Hogares 2017 | Datos Generales, el cual muestra que la ZMVM comprende 16 delegaciones de Ciudad de México, 59 municipios del Estado de México y un municipio de Hidalgo. Para efectos de dicho estudio, la ZMVM fue organizada en 194 distritos: 85 en Ciudad de México, 108 en el Estado de México, y uno en Hidalgo. Posteriormente, se descargó la información estadística, la cual contiene la información de la EOD 2017, a través de la liga siguiente: Encuesta Origen Destino en Hogares de la Zona Metropolitana del Valle de México (EOD) 2017 (inegi.org.mx).

Una vez analizada la información que proporciona la plataforma de INEGI, se consideró pertinente realizar filtros a la información obtenida, con la finalidad

de generar una nueva base de datos que contenga la información del tiempo de viaje para trabajarla dentro del Programa ArcMap 10.5.

La primera indicación para generar la base de datos referente al indicador tiempo de viaje de la variable 1 movilidad cotidiana, fue generar el filtro de información a través del indicador estrato socioeconómico de la variable 2 justicia espacial: en primer lugar, el correspondiente al estrato bajo, con código válido 1 y 2, según el diccionario de variables de la EOD 2017. Posterior a ello, se aplicó el filtro correspondiente al propósito de viaje, eliminando aquellos viajes que tienen como propósito el regreso al hogar, con código válido 1, quedando únicamente las respuestas que tienen como propósito de viaje cualquier otro lugar que no sea el hogar. Una vez que ambos filtros se aplicaron, fue necesario emplear un filtro más en la base de datos, correspondiente a la duración del tiempo, eliminando aquellas respuestas que rebasan los 240 minutos de viaje, tomando en cuenta que las respuestas mayores a este rango (4 horas de viaje) se consideran información atípica que representa un porcentaje menor, lo cual podría alterar el cálculo del promedio de tiempo, quedando con ello un total de 18,051,360 viajes por analizar.

Posteriormente, se copió la información en una hoja nueva del libro de Excel. Al final de las celdas, se insertó una columna en donde se introdujo la siguiente fórmula =DURACIÓN*FACTOR, lo cual significa que se multiplicará la duración del viaje por el factor de expansión, para obtener con ello el dato del tiempo total en minutos.

Una vez que fue modificada la base de datos de Excel con los tres filtros antes descritos, se implementó la herramienta *tabla dinámica*, como lo muestra la Figura 1. Automáticamente se abrió una nueva hoja de Excel, con un cuadro de diálogo del lado derecho, que contiene los campos de la tabla dinámica.




Figura 1. Aplicación de tabla dinámica para procesamiento de datos. Fuente: obtención de información a partir de la EOD (2017) del INEGI. Elaboración propia final.

En la parte inferior se ubicaron cuatro casillas con las siguientes áreas: filtros, columnas, filas y valores.

En primer lugar, se activó la casilla *filas* y los campos ubicados en la parte superior; se eligió el campo *dto_ori* (distrito origen), y posteriormente en la casilla *suma de valores* se eligió *pon_tiempo* (tiempo total empleado en minutos), y el campo *factor* (número de encuestados representados en una sola encuesta).

Una vez que se ejecuta la tabla dinámica, aparecen tres columnas (Figura 1): la primera columna contiene las claves de cada uno de los distritos que integran la EOD 2017, la segunda contiene el tiempo total empleado en minutos, y finalmente la tercera columna contiene la cantidad de viajes realizados por el estrato bajo en cada uno de los distritos que conforman la ZMVM. De esta forma, se copia la información seleccionada y se pega en las celdas del lado derecho, mediante la opción valores. Por último, se agrega una columna para obtener el promedio de tiempo de viaje por distrito, lo cual se logra mediante la siguiente fórmula $\text{=PONDERACIÓN DEL TIEMPO/NÚMERO DE VIAJES}$.

El siguiente paso fue cargar la base de datos en el Programa ArcMap, así como lograr la unión de la base de datos con la capa de distritos de la ZMVM. Una vez que se obtuvo la tabla obtenida sobre el tiempo empleado, se visualizó la información que contenía, abriendo la tabla de atributos. Se realizó la unión de esa tabla con la capa distritos mediante *Join*.

Al seleccionar la función *Join* se abrió un cuadro de dialogo donde se introdujo la siguiente información: 1. Elegir el campo de la capa en el que se basara la combinación (Distrito); 2. Elegir la tabla a la que se desea unir esta capa (tiempo est BAJO); 3. Elegir el campo de la tabla en el que se desea basar la combinación (*dto_ori*), como lo marca la Figura 2.




Figura 2. Cuadro de diálogo de la función Join a través de ArcMap 10.5. Fuente: obtención de información a partir de INEGI, y trabajado con ArcMap 10.

Lo que siguió fue tematizar la información. De esta forma, el mapa referente al tiempo empleado al viajar del estrato bajo en cada distrito de la ZMVM fue generado, y posteriormente se realizó el mismo procedimiento para los estratos medio (código válido 3) y alto (código válido 4).

Para complementar los tres mapas generados, referentes al tiempo de viaje empleado (indicador de la variable 1 movilidad cotidiana) por estrato socioeconómico (correspondiente a la estructura vertical, indicador de la variable 2 justicia espacial), se agregó la clasificación correspondiente a los viajes intradistritales (viajes internos), así como los viajes interdistritales (externos), referentes a la estructura horizontal de la variable 2 justicia espacial.

De esta forma, mediante la fórmula =IGUAL (DTO_ORIGEN, DTO_DESTINO), y la obtención de la respuesta VERDADERO, se aplicó el filtro para obtener los viajes intradistritales (internos) y posteriormente se utilizó la función *tabla dinámica*. Una vez obtenida la tabla tiempo est BAJO INTRA, se realizó el *Join* con la capa correspondiente a los distritos que integran la ZMVM. Realizado el *Join*, se procedió a la tematización geográfica del mapa. Finalmente, mediante la fórmula =IGUAL (DTO_ORIGEN, DTO_DESTINO), y la obtención de la respuesta FALSO, se aplicó el filtro para obtener los viajes interdistritales (externos), y posteriormente se utilizó la función “tabla dinámica”. Una vez que se obtuvo la base de datos titulada tiempo est BAJO INTER, se realizó el *Join* con la capa que contiene los distritos que integran la ZMVM.

¿Quién emplea más tiempo en sus desplazamientos? ¿Importa la ubicación espacial?

Las Figuras 3, 4 y 5 muestran el tiempo promedio empleado en los desplazamientos cotidianos realizados por cada estrato socioeconómico, tomando en cuenta la ubicación residencial (estructura horizontal) en relación con los contornos que conforman la ZMVM. De esta forma, los mapas mencionados muestran la menor cantidad de tiempo empleado a través del color azul, y la mayor cantidad de tiempo empleado utilizando el color rojo.

De esta forma, la Figura 3 muestra la mayor cantidad de tiempo empleado por los estratos bajos, en aquellos distritos ubicados al poniente y surponiente de la ZMVM (50-62 minutos). En contraste con el mayor tiempo empleado por el estrato bajo, el mapa muestra residentes que viven tanto en el norte, como en el nororiente y suroriente de la ZMVM, quienes mencionan emplear una menor cantidad de tiempo al realizar sus desplazamientos diarios (29-35 minutos).

Por su parte, el tiempo empleado por el estrato medio puede observarse en la Figura 4, mostrando un patrón de movilidad diferente al estrato bajo; observándose un modelo centro-periferia, exceptuando a los habitantes que refieren emplear el menor tiempo en sus viajes (10-30 minutos) en el norponiente de la ZMVM. De esta manera, algunos distritos pertenecientes a ciudad central y primer contorno, refieren emplear de 30-42 minutos para desplazarse, y una

vez que los residentes pertenecen al segundo contorno tanto al norte como al sur de la ZMVM, el tiempo de viaje que emplean incrementa de 42-52 minutos. Posteriormente, algunos residentes del estrato medio pertenecientes a distritos del segundo y tercer contorno incrementan su promedio de tiempo de viaje de 52-70 minutos, principalmente en el oriente y en el sur. Finalmente, algunos residentes pertenecientes a los distritos ubicados en el tercer y cuarto contorno, tanto al norte, suroriente, oriente y poniente, emplean entre 70 y 122 minutos en sus traslados diarios.

De igual forma, la Figura 5 revela que el estrato alto muestra un patrón centro-periferia que excluye a los distritos que emplean menor tiempo de desplazamiento, entre 5 y 24 minutos en el norponiente y suroriente de la ZMVM, por lo que el patrón centro-periferia inicia con los residentes ubicados en ciudad central y primer contorno, quienes emplean de 24-40 minutos en sus desplazamientos diarios. Posteriormente, conforme incrementa la lejanía respecto de la ciudad central, los residentes pertenecientes al estrato alto que viven en el segundo y tercer contorno, ubicados tanto al norte, como al suroriente, refieren emplear entre 40-50 minutos en su movilidad cotidiana. Por último, residentes del tercer y cuarto contorno, emplean entre 50-120 minutos en desplazarse, principalmente en el norponiente, surponiente y suroriente de la ZMVM.

Dentro de dicho análisis, se retoma a Soja (1980), tomando en cuenta que la cartografía generada muestra la relación entre la estructura vertical (estratos socioeconómicos) y la estructura horizontal (contornos de la ZMVM), con la finalidad de identificar las desigualdades socioespaciales que se presentan en el tiempo que emplean los habitantes de la ZMVM en sus viajes cotidianos, tomando en cuenta el estrato socioeconómico al que pertenecen y su ubicación espacial.

Paralelamente, respecto de los viajes internos y externos realizados en la ZMVM, las Figuras 6 y 7 muestran diferencias en el tipo de movilidad que se presenta en estos 2 tipos de viajes realizados por el estrato bajo, considerando por un lado los viajes internos (aquellos que tienen como punto de origen y destino el mismo distrito), y por otra parte los viajes externos (aquellos que tienen como punto de origen un distrito diferente al punto de destino).

Al respecto, la Figura 6 aborda el tiempo empleado por el estrato bajo al realizar viajes internos, mostrando inicialmente que los distritos que refieren emplear en sus desplazamientos el menor tiempo (11-17 minutos), forman un cinturón en el lado oriente de la ZMVM, sobre la línea que delimita CDMX respecto del Estado de México. Asimismo, distritos pertenecientes al tercer y cuarto contorno, tanto al norte, sur, oriente y poniente de la ZMVM, refieren emplear en sus desplazamientos diarios internos de 17-32 minutos. Por último, los estratos bajos que refieren emplear el mayor tiempo al desplazarse (32-66 minutos), se ubican en ciudad central y primer contorno de la ZMVM.

Por su parte, la Figura 7 muestra el tiempo empleado en los viajes externos realizados por el estrato bajo. De esta forma, el mapa indica que existe un modelo centro-periferia, ya que conforme aumenta la distancia al centro de la ciudad, el tiempo empleado en los viajes externos también aumenta, por lo que distritos pertenecientes a ciudad central, 1o, 2º y 3o contorno, refieren emplear de 38-57 minutos en sus desplazamientos, principalmente en zona central, al norte y hacia el oriente de ZMVM.




Figura 3. Tiempo empleado al viajar por el estrato bajo. Fuente: elaboración propia con datos de la EOD (2017).




Figura 4. Tiempo empleado al viajar por el estrato medio. Fuente: elaboración propia con datos de la EOD (2017).




Figura 5. Tiempo empleado al viajar por el estrato alto. Fuente: elaboración propia con datos de la EOD (2017).




Figura 6. Tiempo empleado en viajes internos por el estrato bajo. Fuente: elaboración propia con datos de la EOD (2017).




Figura 7. Tiempo empleado en viajes externos por el estrato bajo. Fuente: elaboración propia con datos de la EOD (2017).

Del mismo modo, distritos pertenecientes al tercer y cuarto contorno emplean de 57-64 minutos para realizar viajes externos, principalmente en el norponiente, oriente y suroriente de la ZMVM. Por otro lado, residentes pertenecientes al tercer y cuarto contorno, ubicados al norte y al suroriente de la ZMVM, emplean entre de 64-74 minutos. Finalmente, el poniente, surponiente, norte y nororiente de la ZMVM, muestran distritos pertenecientes al 3o y 4º contorno que emplean de 74-101 minutos en sus viajes externos.

Discusión y reflexiones finales

De forma general, el estrato medio y alto muestran un modelo centro-periferia, situación que no se repite con el estrato bajo. Como lo señalan Qiao y Yeh (2023), las personas de bajos recursos tienden a elegir mayores tiempos de traslado a cambio de costos menores, por lo que es importante considerar que utilizar el transporte público toma más tiempo que el empleo del automóvil, ya que los trasbordos implementados para cambiar de un modo de transporte a otro, así como las paradas frecuentes, incrementan el tiempo de recorrido.

En el caso de los viajes internos que realiza el estrato bajo, y tomando en cuenta que en el área periférica de la ZMVM existe poca oferta de transporte (con precios superiores a los que se manejan en ciudad central), las personas de bajos recursos limitan sus desplazamientos al interior de los distritos donde habitan (como se muestra en la Figura 6), aunque con dicha decisión se conformen únicamente con lo que les ofrece su entorno inmediato, perdiendo incluso la oportunidad de mejorar su calidad de vida, por lo que, como indican Qiao y Yeh (2023), los habitantes que pertenecen al estrato bajo presentan actividad restringida delimitada por sus inmediaciones próximas.

En contraste con lo anterior, la Figura 6 revela que existen residentes pertenecientes al estrato bajo que viven en ciudad central y refieren emplear una gran cantidad de tiempo (32-66 minutos) en sus desplazamientos diarios, aun tratándose de viajes internos, situación que no responde al modelo centro-periferia, por lo que esta situación se vincula con la congestión vial existente en Av. Insurgentes y Av. Reforma, las cuales concentran gran parte de la actividad económica de dicha ciudad. De esta forma, pertenecer al estrato bajo y vivir en ciudad central, también revela desigualdades en el tiempo empleado en los desplazamientos diarios, ya que al depender de un sistema de transporte colectivo, el tiempo de traslado puede aumentar, sobre todo en las horas pico, cuando la demanda de transporte incrementa de manera exponencial.

Por otro lado, la Figura 7 revela un modelo centro-periferia que resalta la importancia del hecho de pertenecer al estrato bajo, vivir en el cuarto contorno y realizar viajes externos cotidianamente; ya que en este tipo de desplazamientos no solamente importa dónde vivir, sino el estrato socioeconómico, así como los modos de transporte existentes en las periferias, el costo económico, la ubicación del empleo y de equipamientos de alta especialidad. De esta forma,

se observa que el tipo de movilidad que realizan los diferentes estratos en relación con el tiempo que emplean, difiere de ser equitativa; por el contrario, es evidente que esta movilidad presenta desigualdad socioespacial, por lo que se considera importante realizar más estudios acerca de los viajes cotidianos que realizan los habitantes de la ZMVM, tomando en cuenta el enfoque de la justicia espacial con la finalidad de obtener, a través de la cartografía, las áreas que presentan mayores problemas en temas de movilidad, con la finalidad de sugerir la implementación de políticas públicas en dichas áreas.

Referencias

- Avellaneda, P., y Lazo, A. (2011). Aproximación a la movilidad cotidiana en la periferia pobre de dos ciudades latinoamericanas. Los casos de Lima y Santiago de Chile. *Revista Transporte y Territorio*, 4, 47-58. <https://www.redalyc.org/articulo.oa?id=333027082004>
- Blanco, J., y Apaolaza, R. (2018). Socio-territorial inequality and differential mobility. Three key issues in the Buenos Aires Metropolitan Region. *Journal of Transport Geography*, 67, 76-84. <https://doi.org/10.1016/j.jtrangeo.2017.07.008>
- Buzai, G., y Montes Galván, E. (2021). *Estadística Espacial: Fundamentos y aplicación con Sistemas de Información Geográfica*. 1a ed. Impresiones Buenos Aires Editorial.
- Calonge, F. (2019). Recursos de movilidad y accesibilidad urbana en los municipios del sur del área Metropolitana de Guadalajara, México. *Revista Urbano*, 38, 48–57. DOI: <https://doi.org/10.22320/07183607.2018.21.38.04>
- Casado, J. M. (2008). Estudios sobre movilidad cotidiana en México. Scripta Nova. *Revista Electrónica de Geografía y Ciencias sociales*, 11(273) [ISSN: 1138-9788].
- Cruz Muñoz, F., y Isunza, G. (2017). Construcción del hábitat en la periferia de la Ciudad de México. Estudio de caso en Zumpango. *EURE*, 43(129), 187-207. <http://dx.doi.org/10.4067/S0250-71612017000200009>
- Encuesta Origen Destino 2017 (EOD 2017), Instituto Nacional de Estadística Geografía e Informática (INEGI).
- Farber, S., Ritter, B., y Fu, L. (2016). Space-time mismatch between transit service and observed travel patterns in the Wasatch Front, Utah: A social equity perspective. *Travel Behaviour and Society*, 4, 40-48. <https://doi.org/10.1016/j.tbs.2016.01.001>
- Garduño, N. (2009). Accesibilidad y movilidad como factores de habitabilidad el caso de San Pedro Atzompa, Tecámac [Trabajo terminal Especialización en Diseño Metodologías en Estudios Urbanos, Universidad Autónoma Metropolitana] <http://hdl.handle.net/11191/6398>

- Gutiérrez, A. (2010). Movilidad, transporte y acceso: una renovación aplicada al ordenamiento territorial. *Scripta nova, Revista electrónica de geografía y ciencias sociales*, Universidad de Barcelona, 14(331), p. 86.
- Gutiérrez, A. (2012). ¿Qué es la movilidad? Elementos para (re) construir las definiciones básicas del campo del transporte. *Bitácora* 21 (2), 61-74. <https://revistas.unal.edu.co/index.php/bitacora/article/view/29076>
- Harvey, D. (1979). *Urbanismo y Desigualdad Social*. Siglo Veintiuno Editores.
- Hernández Sampieri, R., (2006). *Metodología de la Investigación*, 4o Edición. Mc Graw-Hill Interamericana.
- Hernández, D. (2018). Uneven mobilities, uneven opportunities: Social distribution of public transport accessibility to jobs and education in Montevideo. *Journal of Transport Geography*, 67, 119-125. <https://doi.org/10.1016/j.jtrangeo.2017.08.017>
- Kaufmann, V., Bergman, M., y Joye, D. (2004). Motility: mobility as capital. *International Journal of Urban and Regional Research*, 28 (3), 745-756. <https://doi.org/10.1111/j.0309-1317.2004.00549.x>
- Kralich, S. (1999). Aptitud de la red de transporte urbano para la delimitación de metrópolis en expansión. *Actas del V Seminario Internacional de la RII. Toluca: Red de Investigadores Iberoamericana sobre Globalización y Territorio*. CD-Rom.
- Lefebvre, H. (1968). *El derecho a la Ciudad*. Ediciones Península.
- Lizárraga, C. (2006). Movilidad urbana sostenible: un reto para las ciudades del siglo XX. *Economía, Sociedad y Territorio*, vol. VI, núm. 22, 283-321. <https://doi.org/10.22136/est002006260>
- Módenes, J. A. (2008). Movilidad espacial, habitantes y lugares: retos conceptuales y metodológicos para la geodemografía. *Estudios geográficos*, LXIX(264), 157-178. <https://doi.org/10.3989/eggeogr.2008.i264.83>
- Oviedo, D., y Titheridge, H. (2016). Mobilities of the periphery: Informality, access and social exclusion in the urban fringe in Colombia. *Journal of Transport Geography*, 55, 152-164. <https://doi.org/10.1016/j.jtrangeo.2015.12.004>
- Qiao, S., y Yeh, A. G. O. (2023). Mobility-on-demand public transport toward spatial justice: Shared mobility or Mobility as a Service. *Transportation Research Part D*, 123, 10396, 1-18. <https://doi.org/10.1016/j.trd.2023.103916>
- Ramírez, M. (2003). Cálculo de medidas de accesibilidad geográfica, temporal y económica generadas mediante sistemas de información geográfica. En Primer Congreso de la Ciencia Cartográfica y VIII Semana Nacional de Cartografía, Buenos Aires.
- Rawls, J. (1979). *Teoría de la Justicia*. Fondo de Cultura Económica.
- Rodríguez, J. (2008). Movilidad cotidiana, desigualdad social y segregación residencial en cuatro metrópolis de América Latina. *Revista EURE*, XXXIV(103), 49-71. <http://dx.doi.org/10.4067/S0250-71612008000300003>

- Soja, E. (1980). The socio-spatial dialectic. *Annals of the Association of American Geographers*, 70(2), 207-225.
- Suárez, M., Murata, M., y Delgado, J. (2016). Why do the poor travel less? Urban structure, commuting and economic informality in Mexico City. *Urban Studies*, 1-19. DOI: [10.1177/0042098015596925](https://doi.org/10.1177/0042098015596925)
- Torales, B. (2020). Movilidad circular residencia a trabajo como elemento de la habitabilidad urbana en Mérida, Yucatán [Tesis de Doctorado en Ciencias del Hábitat, Universidad Autónoma de San Luis Potosí, de Yucatán].
- Toscana, A., y De Jesus, R. (2018). Migración intercontorno en la Zona Metropolitana de la Ciudad de México. Un estudio desde la justicia espacial. *Política y Cultura*, primavera 2018, núm. 49, 93-120.
- Valette, J. F., Pécout, H., y Guérin Pace, F. (2022). Understanding territorial inequalities in the Mexico City Metropolitan Area through residential and daily mobility. *Trace*, 82, 113-153. <https://doi.org/10.22134/trace.82.2022.813>

Capítulo VIII. La seguridad vial de los motociclistas en la Ciudad de México en el año 2022

Raquel Andrea Delgadillo Díaz¹

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),

Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

Factores como la superficie de rodamiento no pavimentada, iluminación insuficiente y el estado de las vías aumentan los siniestros de tránsito. Además, la falta de equipo de seguridad, como el casco, agrava las lesiones en motociclistas. Ante esto, se plantea la pregunta: ¿Cómo impacta la configuración de la red vial de la Ciudad de México en los accidentes de motocicletas? Este estudio analiza las vialidades donde ocurrieron más siniestros en la Ciudad de México en el año 2022, tomando como base la teoría del dominó de Heinrich y la teoría de causalidad múltiple. Con un enfoque cuantitativo y correlacional transversal, se emplea GIS para identificar zonas de alto riesgo y patrones críticos. Esto cobra relevancia por el aumento de accidentes desde 2019. La investigación busca mejorar la seguridad vial, beneficiando a los motociclistas vulnerables y contribuyendo al desarrollo de políticas públicas que reduzcan los siniestros en la Ciudad de México.

Palabras clave: motocicletas, seguridad vial, accidentes.

Abstract

Factors such as unpaved roads, poor lighting and road conditions increase the number of traffic accidents. In addition, the lack of safety equipment, such as helmets, exacerbates injuries to motorcyclists. This begs the question: How does the configuration of Mexico City's road network affect motorcycle crashes? Based on Heinrich's domino theory and the theory of multiple causality, this study analyzes the roads where most accidents occurred in Mexico City in the year 2022. Using a quantitative and cross-sectional correlational approach, GIS is used to identify high-risk areas and critical patterns. This has become relevant due to the increase in accidents since 2019. The research aims to improve road safety, benefit vulnerable motorcyclists and contribute to the development of public policies that reduce accidents in Mexico City.

Keywords: motorcycles, road safety, accidents.

Introducción

En la Ciudad de México, los accidentes de tránsito que involucran motocicletas son frecuentes, y a menudo resultan en lesiones graves o la pérdida

1 Maestra en Ciencias en Arquitectura y Urbanismo, Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura ESIA, Unidad Tecamachalco. Correo: rdelgadillod1500@alumno.ipn.mx, ORCID: <https://orcid.org/0009-0005-8930-7416>

de vidas humanas. Estos accidentes también generan congestión vehicular significativa. El aumento en el uso de motocicletas se debe a su accesibilidad económica y su agilidad en el tráfico, aunque se trata de vehículos riesgosos debido a su ligereza y falta de protección para los usuarios.

En 2022, la Secretaría de Movilidad reportó aproximadamente 528,000 motocicletas registradas en la Ciudad de México. Los motociclistas son considerados usuarios vulnerables, con un mayor riesgo de sufrir lesiones graves o morir en accidentes. Los estudios demuestran que en las zonas urbanas ocurre un número importante de estos accidentes.

El Reporte trimestral de hechos de tránsito, de enero a marzo de 2022, muestra un incremento en los accidentes de motociclistas, con un aumento significativo en los motociclistas lesionados, en comparación con el mismo periodo de 2019. Este incremento resalta la necesidad urgente de implementar medidas para disminuir la vulnerabilidad de estos usuarios. Siendo este un tema muy importante no solo para México, sino para todo el mundo. La Organización Mundial de la Salud (OMS, s.f.) menciona que más del 90% de las defunciones por accidentes de tránsito ocurren en países de ingresos bajos y medianos, y más de la mitad de las víctimas son usuarios vulnerables como peatones, ciclistas y motociclistas. En México, la elección de la motocicleta como medio de transporte se debe a su economía y accesibilidad, especialmente en el caso de personas de ingresos medios a bajos. En una investigación sobre movilidad en México, se encontró que un porcentaje significativo de la población desea utilizar motocicletas como medio de transporte; estos datos resaltan, de acuerdo a lo mencionado por la OMS, al evidenciar que, además de que México es un país donde predominan la clase media y baja, los motociclistas son el grupo de usuarios más vulnerable debido a su clase económica.

El conductor o el entorno

La mayoría de los estudios sobre accidentes de tránsito se centran en factores humanos, como lo son la atención y la toma de decisiones, sin embargo, es importante considerar factores ambientales como la infraestructura vial y el entorno urbano. En este trabajo destaca la importancia de incluir la configuración vial en las políticas públicas para mejorar la movilidad y seguridad de los motociclistas en la Ciudad de México.

Algunos autores, como Glizer (1993), han comenzado a explorar estos factores ambientales y su impacto en la seguridad vial. A pesar de que los estudios son menos comunes en este tema, son igualmente importantes para una comprensión de las causas de los accidentes. De esta manera, se puede atacar esta problemática con estrategias de prevención más efectivas.

El análisis bibliométrico de los artículos que abordan este tema exhibe un enfoque sobre el “factor humano”; esto podría resaltar la necesidad de un enfoque en los factores ambientales, los cuales son: la calidad y distribución

de las vías y las condiciones urbanas, siendo estos factores los que impactan directamente en la vulnerabilidad de los motociclistas. Es debido a esto que es importante el análisis de estos factores, pues a través de él se podrían identificar puntos críticos en la infraestructura vial que, al ser mejorados, son capaces de reducir significativamente los accidentes. Las políticas públicas basadas en estos hallazgos pueden proporcionar un entorno más seguro para los motociclistas, reduciendo las tasas de accidentes y muertes.

La información y análisis anteriormente mostrados, llevó a realizar la hipótesis que indica que si la configuración de la red vial de la ciudad de México presenta deficiencias en su diseño, entonces aumentarán las motocicletas. Es debido a estas condiciones que incrementan los riesgos asociados con la movilidad en motocicleta:

Variable independiente: Configuración de la red vial de la Ciudad de México.

Variable dependiente: Accidentes de la movilidad en motocicletas (accidentes de motociclistas).

Esta hipótesis buscó consolidarse aplicando el objetivo general, que parte de la identificación de los puntos críticos de la accidentalidad de la movilidad en motocicleta con respecto a los diferentes tipos de vialidades en la red vial de la Ciudad de México en el año 2022. Ello, a partir del uso de sistemas de información geográfica (SIG).

¿Cómo se provocan los accidentes?

Para entender los accidentes de tránsito, es crucial conocer las teorías que los explican y que demuestran cómo han evolucionado. Por ello, se analizaron diversas teorías y enfoques en los factores que influyen en dichos accidentes; ello con el objetivo de seleccionar la teoría que mejor respalda la hipótesis planteada. La hipótesis sugiere que las deficiencias en el diseño de la red vial de la Ciudad de México aumentan la frecuencia de accidentes de motocicletas, debido a los riesgos asociados con estas condiciones.

El libro “Teorías y modelización de los accidentes” de Botta, N. (2010) es la referencia principal. En este libro podemos conocer la teoría del dominó y la de la causalidad múltiple. La teoría del dominó, desarrollada por W. H. Heinrich en 1931, compara los factores que pueden causar un accidente con piezas de dominó en línea. Si un factor ocurre, provoca una reacción en cadena que resulta en un accidente. Heinrich identifica cinco factores en los accidentes de tránsito: herencia y medio social, acto inseguro, falla humana, accidente, y lesiones. Propone que los accidentes son el resultado de múltiples factores combinados (Figura 1).




Figura 1. Diagrama de teoría efecto dominó. Nota. Tomado de Heinrich, W. H (1931). Edición: elaboración final propia.

Esta teoría fue fundamental para el desarrollo de otras teorías, como lo es el modelo de causalidad de accidentes y pérdidas de Bird Frank, E. (2009), que analiza todo el proceso del accidente y sus causas. La teoría de la causalidad múltiple es considerada como la evolución de la teoría del dominó, la cual destaca que los accidentes pueden ser causados por una combinación de múltiples factores humanos y ambientales. Los factores humanos incluyen actitudes del usuario y falta de conocimiento, entre otras. Los factores ambientales abarcan protección inapropiada, deterioro de la infraestructura, mal estado de los equipos y maniobras inseguras (Figura 2).




Figura 2. Modelo de causalidad de accidentes de Frank E. (2009). Fuente: elaboración final propia.

Basándonos en las teorías mostradas, podemos observar que los accidentes no son causados por un solo factor, sino por una serie de acciones u obstáculos que pueden combinarse de diversas maneras, resultando en accidentes. En ambas teorías se enfatiza la importancia de los factores ambientales y humanos en los accidentes de tránsito.

Metodología

La metodología cuantitativa utilizada en la investigación evalúa los puntos críticos de accidentalidad en motocicletas en la Ciudad de México durante 2022, utilizando sistemas de información geográfica (SIG).

Parte del método cuantitativo se basa en la recopilación de datos sobre accidentes de motociclistas en la Ciudad de México, obtenidos de registros oficiales del Instituto Nacional de Estadística y Geografía (INEGI), el cual es un organismo público autónomo que coordina el Sistema Nacional de Información Estadística y Geográfica, y que proporciona datos fundamentales para la planificación y desarrollo del país. Su página web ofrece acceso a mapas y cartografía, cruciales para sectores como la planificación urbana y la logística. Estos datos se analizan mediante métodos matemáticos, estadísticos y SIG, para probar la hipótesis de investigación propuesta. El análisis espacial busca determinar los puntos críticos de accidentes, y cómo los diferentes tipos de vialidades impactan en la frecuencia de estos accidentes.

Se establece así una relación entre la configuración de la red vial (variable independiente) y los accidentes de motocicleta (variable dependiente). Además, se utilizan datos numéricos y estadísticos para correlacionar ambas variables. Por lo tanto, este capítulo expone una lógica objetiva que sigue un razonamiento deductivo, partiendo de la teoría de la causalidad múltiple para probar la hipótesis mediante geografía cuantitativa, haciendo así que el diseño de la investigación no sea solo experimental y transversal, ya que está basado en datos preexistentes y recopilados en un tiempo específico, obtenidos de INEGI. Se clasifican, de este modo, las vialidades y los accidentes de motocicletas según sus características, para posteriormente unir ambas variables e identificar los puntos críticos y las vialidades más vulnerables. El objetivo principal es determinar la relación entre la variable 1 y la variable 2, y cómo las vialidades influyen en la frecuencia de accidentes de motocicletas en 2022 (Figura 3).

La variable 1, denominada red vial, la cual está compuesta por carreteras y vialidades urbanas, es constituida por datos de información muy bastos, los cuales cuentan con características como la velocidad permitida y el tipo de vialidad. Es esencial recopilar datos precisos y actualizados, como los proporcionados por el INEGI, para contar con la información adecuada. La cartografía del INEGI se actualiza regularmente, permitiendo el uso de datos recientes en investigaciones. Para este estudio, se debe descargar la información de las vías de comunicación en formato *Shapefile (shp)* del año

2022, y las divisiones geopolíticas de la Ciudad de México disponibles en la sección de mapas y geografía de su página web. Estos datos se utilizan en el programa ArcMap 10.5 para analizar la red vial de la Ciudad de México, filtrando la información relevante para la investigación. Teniendo las vialidades que conforman la red vial de la ciudad de México, estas se clasifican en vías tipo A, B, C y D, según su importancia y tamaño, basándose en criterios del libro “Geomática y procesos urbanos: Métodos y conceptos” (Herrera, et al., 2023). Las vialidades tipo A son de acceso controlado, con una velocidad máxima de 80 km/h; las tipo B son ejes viales con una velocidad máxima de 50 km/h; las tipo C son avenidas principales con una velocidad máxima de 40 km/h; y las tipo D son avenidas secundarias con una velocidad máxima de 20 km/h.

Para seleccionar estas vialidades, se utilizó el programa ArcGIS 10.5, seleccionando atributos como *VELOCIDAD* y *TIPO_VIAL*. Luego, se les asignó un área de influencia considerando el número de carriles y un ancho de tres metros por carril. Por ejemplo, la Av. Ignacio Zaragoza, una vía tipo A, tiene 14 carriles de 3 metros cada uno, dando un ancho total de 42 metros.




Figura 3. Esquema de síntesis del proceso metodológico de la investigación. Fuente: elaboración propia a partir de Hernández Sampieri, et al. (2014).

Finalmente, se aplicó un proceso de buffer en ArcGIS para cada tipo de vialidad, considerando el ancho de los carriles y el número promedio de carriles por tipo de vialidad.

Para obtener información sobre la variable 2, accidentes de tránsito, se debe acceder a la base de datos de INEGI, específicamente a la sección de accidentes de tránsito terrestre en zonas urbanas y suburbanas. En esta sección se encuentran los archivos *shp* de los accidentes, con su ubicación. Para esta investigación, se analizan los datos del año 2022, descargándolos uno por uno para evitar problemas de tamaño.

Principalmente se filtran los datos para obtener solo los accidentes de la Ciudad de México; posteriormente nos enfocamos en aquellos donde participaron motocicletas, para poder filtrar los accidentes donde participan uno o más motociclistas. Esto se realiza utilizando el parámetro *MOTOCICLET* en ArcMap, seleccionando así solo los accidentes que cuenten con este campo, para después generar una capa que esté conformada por los accidentes seleccionados.

Los datos incluyen detalles como el número de motocicletas involucradas, día, mes, año, zona (urbana o suburbana), tipo y clase de accidente, siendo este último dato de suma importancia para la investigación, ya que nos permite clasificar los accidentes en tres tipos: fatal, no fatal y solo daños.

Se utiliza la opción de *symbology* en ArcMap para tipificar la capa, seleccionando categorías y valores únicos para clasificar los accidentes. Esto permite un mejor entendimiento de los tipos de accidentes y su gravedad, considerando los accidentes fatales como graves, y los accidentes con daños como menos graves.

Llegados a este párrafo, se explica aquí cómo se produce la Correlación de la Vialidad (variable 1) y los accidentes (variable 2): al combinar ambas capas de información, se genera lo que se conoce como álgebra de mapas, donde se suman o en este caso se correlacionan los mapas. El análisis de la relación entre accidentes de motocicletas y la infraestructura vial nos permite visualizar la distribución espacial de los accidentes y su correlación con las características de las vialidades, ayudando a identificar posibles causas subyacentes. Por ejemplo, una alta frecuencia de accidentes en un tramo específico podría indicar problemas con la señalización o el diseño de la vía (Figura 4).




Figura 4. Suma de mapas de variables (álgebra de mapas). Fuente: elaboración propia a partir de ArcMap 10.5.

Este análisis también puede revelar si los accidentes ocurren en las vialidades o fuera de ellas, sugiriendo problemas con rutas alternativas o el comportamiento de los conductores en áreas menos reguladas.

Para un análisis más específico, se separan los accidentes en cuatro capas diferentes según el tipo de vialidad: tipos A, B, C y D. La selección de los accidentes se realiza mediante la herramienta *clip* en ArcMap, que ayuda a separar solo los accidentes dentro del área de influencia de las vialidades, utilizando la misma base de datos de accidentes para todas las vialidades.

Para identificar las zonas más y menos vulnerables en cada vialidad, se realizó un geoproceso de buffer adaptado para seguir la forma de las vialidades, en lugar de la forma circular habitual. Este análisis se basa en la proximidad de los accidentes, utilizando parámetros de distancia de 500 m, 1 km, 2 km, 3 km, 4 km y 5 km. Las zonas más cercanas a los accidentes son más vulnerables para los motociclistas, mientras que las más alejadas son menos vulnerables.

El geoproceso requiere la forma de las vialidades y los puntos de los accidentes. Con ambas capas cargadas, se genera una nueva área de servicio utilizando la herramienta *network analyst* en ArcMap. Para visualizar esta área, se activa la *network analyst window* y se especifican los puntos de carga desde la herramienta *load locations*, tomando como referencia la capa de accidentes en cada tipo de vialidad.

La visualización de las áreas de servicio se configura en el menú de propiedades, en la sección de *Presentaciones de análisis* o *Analysis settings*, donde se agregan los parámetros de distancia. Esto permite mostrar la distribución de los accidentes en las vialidades clasificadas, generando un mapa detallado que resalta las zonas más propensas a accidentes en cada tipo de vialidad.

Resultados

El análisis de los accidentes en diferentes tipos de vialidades de la Ciudad de México, basado en datos del INEGI, revela patrones preocupantes. En las vialidades tipo A se registraron 117 accidentes, de los cuales 5 fueron fatales (4.27%), 35.04% resultaron en lesiones y 60.68% en daños materiales. Las zonas oriente, poniente y sur presentaron la mayor concentración de incidentes, destacando la vulnerabilidad de los motociclistas (Figura 5).

En las vialidades tipo B se reportaron 253 accidentes, con 16 fatales (6.32%), 117 con lesiones y 120 con daños materiales. La mayor concentración de accidentes se observó en el centro de la ciudad, especialmente en las zonas nororiente y norponiente, sugiriendo factores de riesgo específicos (Figura 6).

En las vialidades tipo C, se registraron 216 accidentes, con 12 fallecimientos (5.56%), 89 con lesiones y 115 con daños materiales. La mayoría de los accidentes ocurrieron en la zona norponiente, caracterizada por alta densidad vehicular y tráfico intenso (Figura 7).

Finalmente, en las vialidades tipo D se registraron 139 accidentes, con 6 fallecimientos (4.32%), 87 con lesiones y 66 con daños materiales. Estos accidentes presentaron una distribución menos concentrada, pero con una notable concentración en avenidas que atraviesan el Centro Histórico de la ciudad. Este análisis subraya la importancia de identificar puntos críticos y factores de riesgo específicos en cada tipo de vialidad, para implementar medidas preventivas efectivas y mejorar la seguridad vial en la Ciudad de México (Figura 8).




Figura 5. Accidentes en motocicleta en las vialidades tipo A. Fuente: elaboración propia a partir de ArcMap 10.5.




Figura 6. Accidentes en motocicleta en las vialidades tipo B. Fuente: elaboración propia a partir de ArcMap 10.5.




Figura 7. Accidentes en motocicleta en las vialidades tipo C. Fuente: elaboración propia a partir de ArcMap 10.5.




Figura 8. Accidentes en motocicleta en las vialidades tipo D. Fuente: elaboración propia a partir de ArcMap 10.5.

Discusión

Según la Teoría de la causalidad múltiple de Botta (2010), los accidentes de tránsito no pueden atribuirse únicamente a factores humanos, sino que resultan de la interacción de múltiples factores, incluidos los ambientales. Esta teoría destaca que, aunque los factores humanos son cruciales, las condiciones del entorno también influyen significativamente en la ocurrencia de accidentes. En

esta investigación se enfatiza la importancia de los factores ambientales, ya que muchos estudios previos han minimizado su relevancia en favor de los factores humanos. Autores como Chico, M. F. H., Llamuca, J. L. L., y Ñamo, J. G. C. (2022) Hidalgo Fuentes, S. (2015) y Rísquez et al., (2017), reconocen la influencia de los factores ambientales, pero tienden a centrarse en los humanos. Este sesgo es común en países desarrollados, donde se priorizan los comportamientos de los conductores. Sin embargo, es vital considerar tanto los factores humanos como los ambientales en la seguridad vial de los motociclistas. Factores como la infraestructura vial deficiente, las condiciones climáticas adversas, la falta de señalización adecuada y los obstáculos en las vías, contribuyen a los accidentes. El Modelo de causalidad prevalente en la ciudad simplifica los accidentes a una sola causa, generalmente el factor humano, lo que limita el análisis de las complejidades involucradas. Este modelo se ve presente en los datos del INEGI, ya que se atribuye la responsabilidad principal al conductor. Se menciona esto, ya que se descubrió que, en la información presentada como causa de los accidentes, se muestra cómo todos los accidentes fueron provocados por un factor humano. Sin embargo, esto no puede ser posible, ya que si bien el humano es el responsable del vehículo, no se consideran otros factores, como las condiciones de la infraestructura vial, el clima y el estado de las calles, que también pueden influir en los accidentes.

Conclusiones

Para comprender si los factores ambientales están provocando el siniestro vial, se respondió a la pregunta: ¿cómo impacta la configuración de la red vial de la ciudad de México en los accidentes de la movilidad en motocicletas? Esto se logró identificando la frecuencia y gravedad de los accidentes de la movilidad en motocicletas en los diferentes tipos de vialidades dentro de la Ciudad de México en el año 2022. La segmentación de accidentes por vialidad es una metodología analítica que permitió una comprensión más profunda de la interacción entre la ubicación de los accidentes en motocicleta y sus causas. Contando con esta información, se pudo determinar la distribución espacial de los puntos críticos de accidentes de motocicletas en la red vial que hay en la zona de estudio. Tomando en cuenta los puntos críticos de los accidentes de la movilidad en motocicletas en la Ciudad de México, se lograron identificar las vialidades con mayor o menor vulnerabilidad en cada tipo de vialidad, para que de esta forma se evalúen los puntos críticos de la accidentalidad de la movilidad en motocicleta con respecto a los diferentes tipos de vialidades en la red vial de la Ciudad de México en el año 2022. Esto, a partir del uso de sistemas de información geográfica (SIG). Se logró comprobar la hipótesis que plantea que, si la configuración de la red vial de la Ciudad de México presenta deficiencias en su diseño, entonces aumentará la frecuencia de accidentes de motocicletas, debido a que estas condiciones incrementan los riesgos asociados con la

movilidad en este tipo de transporte. Ya que los resultados del estudio sugieren que en determinados tramos de vialidad existen deficiencias en el diseño o en la gestión del espacio vial, que representan riesgos para los motociclistas, esto se ve comprobado en la aglomeración de accidentes en tramos específicos de las vialidades estudiadas, ya que entre más cerca se encuentre un accidente de otro, esto indicará un problema en ese tramo de la vialidad, lo que pone de manifiesto la necesidad de una intervención en este tipo de sectores.

La investigación se basa en datos del INEGI sobre accidentes de motociclistas en la Ciudad de México en 2022, aunque no refleja todos los incidentes, debido a la falta de reportes oficiales. Muchos accidentes se resuelven sin intervención de autoridades, y algunos implicados no asumen su responsabilidad, especialmente en accidentes menores. Esto sugiere que la cifra real de accidentes es mayor que la reportada. La investigación valida la hipótesis inicial, pero muestra anomalías en ciertas zonas que requieren un análisis más detallado. Es crucial investigar las características comunes de las vialidades más vulnerables, para identificar factores de riesgo y formular estrategias específicas para mejorar la seguridad vial. Estos estudios futuros pueden servir como base para decisiones informadas en políticas públicas y medidas de seguridad vial en las ciudades.

Referencias

- Bird Frank, E. (2009). Modelo de Causalidad de Accidentes y Pérdidas.
- Botta, N. (2010). Teorías y modelización de los accidentes. *Red Proteger*, 3. https://d1wqtxts1xzle7.cloudfront.net/38004812/17_Teoria_Modelos_Accidentes_3a_edicion_Marzo2010-libre.pdf
- Chico, M. F. H., Llamuca, J. L. L., y Ñamo, J. G. C. (2022). Análisis de siniestros y estrategias para mejorar la seguridad vial en la ciudad de Riobamba. *Polo del Conocimiento: Revista científico-profesional*, 7(4), 81. <https://dialnet.unirioja.es/servlet/articulo?codigo=8483038>
- Glizer, I. (1993). *Prevención de accidentes y lesiones: Conceptos, métodos y orientaciones para países en desarrollo*. OPS. <https://iris.paho.org/handle/10665.2/3138>
- Herrera, M. C., Miranda, Á. F., Maturano, R. G., Pérez, I. L., Granados, J. G. M., Ortega, M. D. L. Á. M., ... y Nájera, L. V. (2023). *Geomática y procesos urbanos: Métodos y conceptos*. UNAM. <https://www.researchgate.net/publication/378492331>
- Hernández-Sampieri, R., Fernández Collado, C., y Baptista Lucio, P. (2014). *Metodología de la investigación* (6.a ed.). <https://share.google/7SquzYymwErX-gB5Fi>
- Hidalgo Fuentes, S. (2015). *Estudio descriptivo de la accidentalidad de motocicletas scooter en España (2006–2011)*. Universitat de València. <https://roderic.uv.es/handle/10550/50608>

- Heinrich, W. H. (1931). *Teorías sobre la causalidad de los accidentes: La teoría del dominó*. McGraw-Hill.
- Organización Mundial de la Salud. (s.f.). Traumatismos causados por el tránsito. Who.int. Recuperado el 19 de marzo de 2024, de <https://www.who.int/es/news-room/fact-sheets/detail/road-traffic-injuries>
- Rísquez Parra, A., Bello, L. M., García, M. A., Díaz, J. R., Hofle, J. G., Marcano, G. A., y Medina, G. J. (2017). *Factores de riesgo y lesiones frecuentes por accidentes de motocicletas relacionados con el incumplimiento de la ley de tránsito y transporte terrestre en pacientes del Hospital Dr. Domingo Luciani (2016–2017)*. Universidad Central de Venezuela. <http://saber.ucv.ve/handle/10872/17910>

Capítulo IX. Análisis espacial de los delitos de alto impacto en Panamá (2017-2023). Un enfoque geoespacial para la comprensión de la violencia urbana.

Víctor Raúl Quintero Barba¹

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),
Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

A partir de un enfoque cuantitativo y territorial, este capítulo analiza la violencia urbana en Panamá mediante la distribución espacial de los delitos de alto impacto durante el periodo 2017-2023. Utilizando herramientas de Sistemas de Información Geográfica (SIG) y datos oficiales del Ministerio Público de Panamá, se identificaron los corregimientos con mayor concentración de denuncias a nivel nacional. Además, el estudio revela una distribución delictiva desigual a nivel nacional, así como la ausencia de registros en varios de los corregimientos. Este vacío sugiere la importancia de considerar la cifra negra del delito, ya que confiar exclusivamente en cifras oficiales puede distorsionar la percepción del fenómeno. La metodología aplicada demuestra el potencial de la geomática para el análisis espacial de los delitos, facilitando la identificación de patrones territoriales. Esta investigación representa un primer acercamiento a la comprensión espacial de la violencia urbana y abre la puerta a estudios futuros.

Palabras clave: violencia urbana, análisis espacial, delitos de alto impacto.

Abstract

Using a quantitative and territorial approach, this chapter analyzes urban violence in Panama by examining the spatial distribution of high-impact crimes during the period 2017-2023. Using Geographic Information Systems (GIS) tools and official data from the Panamanian Public Prosecutor's Office, the districts with the highest concentration of reports nationwide were identified. Furthermore, the study reveals an uneven distribution of crime nationwide, as well as the absence of records in several districts. This gap suggests the importance of considering the hidden crime rate, as relying exclusively on official figures can distort perceptions of the phenomenon. The methodology applied demonstrates the potential of geomatics for the spatial analysis of crimes, facilitating the identification of territorial patterns. This research represents a first approach to the spatial understanding of urban violence and opens the door to future studies.

Keywords: urban violence, spatial analysis, high-impact crimes.

1 Maestrante en Ciencias en Arquitectura y Urbanismo (IPN), Arquitecto (Universidad de Panamá), Perito Forense (Instituto de Medicina Legal y Ciencias Forenses) y Artista Plástico (Instituto Nacional de Cultura Centro Superior Bellas Artes de Chitré). Correo: vq0990@gmail.com, ORCID: <https://orcid.org/0009-0004-4965-3210>

Introducción

En el siglo XXI, la violencia urbana se ha consolidado como uno de los fenómenos que más afectan a las ciudades, manifestándose a través de distintos tipos de delitos que impactan la seguridad y calidad de vida de la población. Según la Oficina de las Naciones Unidas contra la Droga y el Delito (UNODC, 2023), América Latina y el Caribe presentan algunas de las tasas de homicidios más altas del mundo, representando un 34% del total global de homicidios, tan solo en 2021. Esta situación ha llevado a categorizar la región como una de las más violentas del planeta.

En el caso de Panamá, la violencia urbana es un fenómeno urbano complejo que aún muestra poca exploración y atención en términos espaciales y geográficos. De hecho, a pesar de la gravedad que implica dicho fenómeno, otros estudios se enfocan en la distribución de delitos del territorio, pero son bastante pocos. Así que, ante esta ausencia de cantidad, este capítulo pretende aportar a la identificación de la violencia urbana, puntualmente en los delitos de alto impacto y su forma de manifestación en el espacio urbano. Para lograr este estudio, se parte de datos registrados sobre denuncias para identificar los patrones de concentración del delito y su relación con las características urbanas.

Los delitos incrementan la percepción de inseguridad en la población que habita un determinado territorio, ya sea urbano o rural, y además inciden en la cohesión social y el desarrollo económico de un país. Por lo que el objetivo central de este trabajo es identificar la distribución espacial de los delitos de mayor gravedad en Panamá entre los años 2017 y 2023, en una escala delimitada por corregimientos que conforman la unidad político-administrativa más detallada del país.

Como hipótesis, se plantea que la violencia urbana en Panamá no se manifiesta de forma aleatoria o uniforme, sino que muestra una concentración espacial, puntualmente en la ciudad capital. Esto dentro de un marco teórico contextual de Shaw y McKay (2010), quienes exponen la teoría de la desorganización social que vincula el crimen con la fragilidad de vínculos comunitarios; por otro lado, Cohen, et al., (2018), con la teoría de las actividades rutinarias, sugieren que los delitos aparecen cuando coinciden con un agresor motivado por una víctima disponible, y ante la ausencia de un control social efectivo. Finalmente, desde la teoría del patrón delictivo, Brantingham y Brantingham (2017) señalan que los crímenes tienden a marcar trayectorias que se asocian a la estructura y uso del entorno urbano. Por lo tanto, esta explicación causal teórica del delito permite debatir de manera crítica sobre la violencia, en una escala espacial territorial urbana.

Para el desarrollo de este capítulo, se utilizaron datos oficiales del Ministerio Público de Panamá y del Instituto Geográfico Nacional “Tommy Guardia”, los cuales fueron procesados mediante ArcGIS 10.8.2. La integración

de datos geoespaciales con estadísticas de los delitos de alto impacto, permite visualizar de manera precisa la distribución de los delitos y su relación con el entorno urbano. Este enfoque metodológico ofrece una base útil para futuras investigaciones que busquen comprender mejor la violencia urbana en su dimensión territorial. Es importante señalar que este estudio representa un primer acercamiento a la definición de la violencia urbana en Panamá. Existen múltiples variables que intervienen en este fenómeno, y en este caso, solo se aborda una de ellas: la distribución espacial de los delitos de alto impacto.

Aproximaciones conceptuales de la violencia urbana

A pesar de la falta de una sola definición que sea universalmente aceptada desde el término de “violencia urbana”, diversos autores han intentado conceptualizarla desde enfoques diversos, según sus disciplinas y contextos de análisis. Esta ausencia de consenso no impide que el término se utilice frecuentemente para hacer referencia a la violencia que ocurre en las ciudades, e incluso en muchos casos como sinónimo de violencia, crimen y homicidio.

El sociólogo Luis Antonio Machado da Silva (2004, como se cita en Saborío, 2019) comenta que “La violencia urbana es una representación discursiva que constituye lo que describe y, por tal motivo, no puede ser definida”. En otras palabras, para Machado da Silva la violencia urbana es lo que se dice que es y, por ser cambiante y situacional, no tiene sentido definirla (p. 64). En otro artículo, el autor amplía su conceptualización indicando que “La violencia urbana es una representación discursiva, producto de lo que llama “sociabilidad violenta”, que define como la “transformación de la fuerza [que pasa de ser un] medio de obtención de intereses a [un] principio de coordinación de las acciones” (Machado da Silva, 2008, como se cita en Saborío, 2019, p. 64).

Por su parte, Baumann Burgos (2005) define la violencia urbana como “el aumento exponencial de homicidios, robos, asaltos a mano armada, guerra entre traficantes de drogas y delincuencia juvenil” (p. 210). Desde esta perspectiva, la violencia urbana es vista como un fenómeno ligado a la criminalidad organizada y la marginalidad urbana.

Misse (2008), toma como caso de estudio a Rio de Janeiro, donde describe a la violencia urbana como la “acumulación social de la violencia”. De hecho, a partir de aproximaciones a nivel teórico argumenta que existe una relación de retroalimentación entre violencia que se propicia a partir de actores criminales, donde la respuesta es violenta a nivel del Estado. Por lo tanto, el ciclo en lugar de disolverse se intensifica más aun cuando convergen factores como el fortalecimiento de redes de tráfico ilícito y el origen de economías ilegales, pero que tienen una influencia política fuerte. Esto deriva en la creación de dinámicas complejas de violencia estructural y social que son difíciles de contener.

Carrión (2008), bajo esta perspectiva, hace una reflexión conceptual desde la violencia urbana destacando que este concepto se entiende a partir de tres

puntos distintos: el primero justifica que lo urbano es la causa de la violencia, el segundo que la violencia es una característica propia del entorno urbano, y el tercero equipara lo urbano con la violencia misma (p. 144). Sin embargo, estos puntos no son excluyentes, por el contrario, abren un marco de discusión desde la naturaleza interdisciplinaria de la violencia en las ciudades.

El concepto de violencia urbana, entonces, se puede entender como un fenómeno que es multidimensional, donde las manifestaciones y causas pueden variar dependiendo del contexto histórico, social y territorial en el que se gestan. Así que este capítulo retoma estos planteamientos, que sitúan el problema en el contexto de Panamá, a partir del análisis espacial como una herramienta estadística y geográfica que permite localizar la manera en que se produce la violencia, además de identificar los factores del territorio que influyen en su manifestación.

Por lo anterior, se necesita puntualizar la comprensión de los delitos de alto impacto, pues se trata de conductas criminales donde el nivel de gravedad afecta tanto a las víctimas directas como a los efectos que generan en cuanto al temor e inestabilidad en la sociedad; y representan un punto de inicio para entender la configuración de la violencia urbana a nivel de país. En Panamá, esta categoría incluye delitos tales como homicidio doloso, feminicidio, lesiones personales, secuestro, delitos sexuales, violencia doméstica, maltrato (infantil, adultos, adultos mayores), hurto, robo, delitos con drogas, delincuencia organizada, asociación ilícita, posesión o tráfico de armas y explosivos.

Metodología

Para analizar la violencia urbana en Panamá, en este capítulo se utiliza un enfoque cuantitativo, donde el foco central gira en torno a las denuncias que están relacionadas con los delitos de alto impacto, y que han sido registradas entre el 2017 y 2023. Se parte de una metodología que retoma la información estadística y espacial que parte desde la recolección, filtro y tratamiento de datos que favorecen la identificación de patrones urbanos que caracterizan esta distribución de delitos a nivel nacional.

Se parte desde la geografía cuantitativa (Buzai y Montes, 2021) junto con técnicas de análisis espacial desde el uso del programa ArcGis 10.8 para la elaboración de cartografías de zonas con mayor densidad delictiva. Por lo tanto, el uso de los Sistemas de Información Geográfica (SIG), es un recurso para el análisis urbano a gran escala, que permite visualizar las dinámicas territoriales de la criminalidad y establecer lecturas detalladas sobre la manifestación del fenómeno.

Estos estudios son de corte no experimental, y según Hernández Sampieri, et al. (2014) se trata de “estudios que se realizan sin la manipulación deliberada de variables y en los que sólo se observan los fenómenos en su ambiente natural para analizarlos” (p. 152). En este sentido, los delitos de alto impacto

serán analizados sin intervención sobre las variables, permitiendo examinar su comportamiento en su contexto real.

Además, se adopta un diseño transversal, considerando los datos como un conjunto agregado correspondiente al periodo 2017-2023. Esto permite identificar tendencias y patrones espaciales, sin evaluar la evolución temporal de los fenómenos analizados.

Ello se desarrolla bajo la premisa de Tobler (1970, como se cita en Buzai y Montes 2021). Tobler “considera que en el espacio geográfico todo se encuentra relacionado con todo, pero los espacios más cercanos están más relacionados entre sí que con los más alejados” (p. 75). El estudio aplicará técnicas de análisis espacial para identificar patrones de concentración o dispersión de los delitos de alto impacto en Panamá.

Proceso metodológico para el análisis espacial

Para esta investigación, se obtuvieron datos estadísticos y geográficos sobre delitos de alto impacto en Panamá. Se consultaron fuentes oficiales como el Instituto Geográfico Nacional “Tommy Guardia” (ignpanama.anati.gob.pa), responsable de la cartografía oficial del país, y el Ministerio Público de Panamá (ministeriopublico.gob.pa), encargado de la recolección y análisis de datos delictivos.

Los datos geográficos fueron descargados en formato *Shapefile* (Shp) desde el portal de datos abiertos del Instituto Geográfico Nacional, en donde se ha trabajado a nivel de corregimientos, lo que corresponde a la división político-administrativa más pequeña del país. Paralelamente, los datos estadísticos de las denuncias de los delitos de alto impacto en Panamá, para el período 2017-2023, fueron obtenidos mediante solicitudes al Centro de Estadísticas del Ministerio Público.

Con esta información, obtenida del Ministerio Público, se construyó una base de datos estructurada en Excel, que permitió organizar los casos denunciados por tipo de delito, así como realizar la sumatoria acumulada del periodo 2017-2023. Estos registros fueron luego asociados al nombre de su respectivo corregimiento, lo que facilitó su análisis espacial dentro del entorno geográfico.

Posteriormente, se procedió a trabajar en el entorno del software ArcGIS 10.8.2, utilizando la herramienta *Join*, la cual permite vincular información de dos capas o tablas a partir de un campo común. Se cargó la capa correspondiente a los corregimientos a nivel nacional, y se accedió a su tabla de atributos para identificar el campo con los nombres de corregimiento. Este campo fue utilizado como vínculo para unir la capa espacial con base de datos construida, integrando así los delitos registrados a su localización correspondiente.

El procedimiento anterior descrito se muestra de forma gráfica a continuación. Las ilustraciones permiten visualizar con mayor claridad una de

las etapas del proceso de geoprocresamiento, facilitando la comprensión de la metodología aplicada en este capítulo (Figura 1).




Figura 1. Tabla de atributos del Shapefile de los corregimientos de Panamá. Fuente: elaboración propia con base en la información proporcionada por el Instituto Geográfico Nacional “Tommy Guardia”.

El método es el siguiente: una vez cargado el Shapefile de los corregimientos en el software, se procede a ver la tabla de atributos, y se busca el indicador asociado al nombre de los corregimientos, que en este caso se llama **OBJECTID**. Posteriormente se procede a ingresar a la tabla de Excel, que contiene los totales y porcentajes de casos por delito. En esta tabla, se asocia el número del **OBJECTID** con el nombre correspondiente de cada corregimiento, tal como se observa en la Figura 2.

	A	B	C	D
1	OBJECTID	CORREGIMIENTOS	T_HOMI	P_HOMI
2	490	24 de Diciembre (10)	97	3.06477093
3	64	Agua de Salud	1	0.03159558
4	225	Aguadulce (cabecera)	4	0.12638231
5	6	Ailigandí	1	0.03159558
6	120	Alanje (cabecera)	1	0.03159558
7	491	Alcalde Díaz (22)	66	2.08530806
8	80	Almirante (cabecera)	8	0.25276461
9	144	Alto Boquete (6)	2	0.06319115

Figura 2. Nombre de los corregimientos asociado al OBJECTID. Fuente: elaboración propia con base en la información proporcionada por el Centro de Estadísticas del Ministerio Público de Panamá.

Después de guardar el documento de Excel en formato CSV (delimitado por comas), se procede a cargar dicha tabla, que contiene los totales y los porcentajes de casos por delito (TODO_CORREGIMIENTO.csv) en ArcGIS 10.8.2. Esto se realiza junto con el *Shapefile* de los corregimientos a nivel nacional, tal como se muestra en la Figura 3.




Figura 3. Shapefile de los corregimientos y tabla de los delitos con su respectivo identificador. Fuente: elaboración propia a partir del Shapefile de los corregimientos de Panamá (fuente: Instituto Geográfico Nacional “Tommy Guardia”) y de una tabla construida en Excel con datos del Centro de Estadísticas del Ministerio Público de Panamá.

Una vez que ambos datos están cargados, se procede a unir la tabla con el *Shapefile* utilizando la herramienta *Join*. Primero, el usuario se posiciona sobre el *Shapefile* de los corregimientos, hace clic derecho y selecciona *Join*. Automáticamente, el software reconoce la tabla de totales y porcentajes de casos por delito (TODO_CORREGIMIENTO.csv). A continuación, se asigna el campo común, en este caso *OBJECTID*, para realizar la unión con el *Shapefile* de los corregimientos. Esto se muestra en la Figura 4.




Figura 4. Unión entre el Shapefile de los corregimientos y la tabla de los totales y porcentajes de casos por delito. Fuente: elaboración propia a partir del software ArcGIS 10.8.2. La imagen muestra el procedimiento de vinculación de datos mediante la herramienta Join.

El paso posterior consiste en verificar que el proceso de unión de la información se haya realizado correctamente. Para ello, nos dirigimos al Shapefile de los corregimientos y abrimos su tabla de atributos. Deberíamos observar que toda la información se ha cargado correctamente con los datos de los delitos correspondientes a cada corregimiento (Figura 5).




Figura 5. Tabla de atributos del Shapefile de los corregimientos con la información de la tabla de totales y porcentajes de casos por delito, unida correctamente. Fuente: elaboración propia a partir del software ArcGIS 10.8.2, donde se observa la tabla de atributos tras la correcta ejecución de la herramienta Join.

Una vez que la información se ha unido correctamente, el siguiente paso consiste en categorizar y representar gráficamente los datos de los totales y porcentajes de los delitos para analizar su comportamiento. Para ello, se accede a las propiedades del *Shapefile*, y en la pestaña de simbología se selecciona la opción más adecuada para representar visualmente los datos. Este proceso permite observar cómo se distribuyen los delitos a través de los diferentes corregimientos, facilitando la interpretación de los patrones espaciales (Figura 6).




Figura 6. Representación de los datos. Fuente: elaboración propia a partir del software ArcGIS 10.8.2, donde se observa el proceso de representación de los datos mediante simbología graduada.

Resultados

En primer lugar, los resultados correspondientes a los delitos de alto impacto asociados a la violencia urbana durante el período de 2017 a 2023 incluyen únicamente aquellos casos que fueron denunciados durante dicho período ante el Ministerio Público.

Se generaron mapas temáticos, y se aplicó simbología específica en ArcGIS para identificar los patrones espaciales de concentración de delitos a nivel de corregimiento. Este enfoque permite un análisis detallado de la incidencia delictiva dentro del contexto territorial (Figuras 7, 8, 9, 10 y 11).




Figura 7. Total de delitos denunciados entre 2017 y 2023, correspondientes a Homicidio, Femicidio y Lesiones personales. Fuente: elaboración propia.




Figura 8. Total de delitos denunciados entre 2017 y 2023, correspondientes a Secuestro, Delitos contra la libertad e integridad sexual y Violencia doméstica. Fuente: elaboración propia.




Figura 9. Total de delitos denunciados entre 2017 y 2023 correspondientes a Maltrato de niños, niñas o adolescentes, Maltrato al adulto mayor y Hurto. Fuente: elaboración propia.




Figura 10. Total de delitos denunciados entre 2017 y 2023 correspondientes a Robo, Delitos relacionados con drogas y Delincuencia organizada. Fuente: elaboración propia.




Figura 11. Total de delitos denunciados entre 2017 y 2023, correspondientes a Asociación ilícita, y Posesión y tráfico de armas y explosivos. Fuente: elaboración propia.

Discusión

A partir de los resultados, se puede inferir que la distribución de los 14 delitos de alto impacto a nivel nacional no es homogénea, lo que significa que no están distribuidos de manera uniforme en todo el país. Mientras que algunos corregimientos presentan una mayor concentración de delitos, en otros la incidencia es considerablemente menor o casi nula.

Esta distribución desigual está fuertemente vinculada con diversos factores, como el grado de urbanización, las condiciones socioeconómicas y las dinámicas espaciales de cada territorio. En general, las áreas con mayor desarrollo urbano y mejor infraestructura tienden a registrar un mayor número de denuncias, mientras que en zonas rurales o con menor accesibilidad, la incidencia delictiva puede estar subestimada debido a la falta de denuncias o a la limitada presencia institucional.

Por ello, la identificación y análisis de la distribución de los delitos de alto impacto constituye un paso fundamental para el estudio de la violencia urbana en Panamá. Este proceso no solo permite dimensionar la magnitud del problema, sino también establecer las bases para un análisis más profundo sobre sus causas, patrones espaciales y dinámicas territoriales.

En la Figuras 12, 13 y 14 se presenta el total de delitos denunciados a nivel nacional durante el período 2017-2023, además de los corregimientos con la mayor cantidad de denuncias a nivel nacional.




Figura 12. Total de delitos denunciados a nivel nacional durante el período 2017-2023.

Fuente: elaboración propia.




Figura 13. Corregimientos con la mayor cantidad de denuncias a nivel nacional durante el período 2017-2023. Fuente: elaboración propia.




Figura 14. Total de corregimientos a nivel nacional donde no se registraron denuncias.

Fuente: elaboración propia.

Como se observa en la Figura 13, los datos muestran que el Corregimiento de David (Cabecera) registra la mayor cantidad de casos denunciados, con 14,697 denuncias en el período analizado. Es relevante destacar que este corregimiento no se encuentra en la capital del país, sino en la provincia de Chiriquí.

Por otro lado, los corregimientos de Pacora (13,935 denuncias) y Juan Díaz (12,821 denuncias) —que sí forman parte de la Zona Metropolitana de Panamá—, ocupan el segundo y tercer lugar en número de denuncias.

Este hallazgo evidencia que la mayor cantidad de denuncias no necesariamente se concentra en la capital del país, sino que otros factores, como la densidad poblacional, la actividad económica y la conectividad territorial, pueden influir significativamente en la distribución de los delitos denunciados.

En cuanto a la representación del total de casos denunciados a nivel nacional en los corregimientos, se observa que 59 de ellos no cuentan con denuncias registradas durante este periodo de tiempo (ver Figura 14). Esto podría atribuirse a dos factores principales: en primer lugar, en algunos corregimientos es probable que no se hayan registrado incidentes que motivaran una denuncia; en segundo lugar, es posible que en otros sí hayan ocurrido hechos delictivos, pero estos no fueron denunciados ni registrados debido a diversos factores, como la desconfianza en las autoridades, el temor a represalias o la falta de acceso a los sistemas de justicia.

Este aspecto subraya la importancia de interpretar las cifras con cautela, reconociendo las limitaciones impuestas por la cifra negra en el análisis de los delitos de alto impacto en Panamá

Reflexiones finales

Este capítulo permitió analizar la distribución espacial de los delitos de alto impacto en Panamá durante el período 2017-2023, revelando patrones de concentración delictiva y dinámicas territoriales asociadas a la violencia urbana. El uso de Sistemas de Información Geográfica (SIG) permitió identificar corregimientos con una alta concentración de denuncias por delitos de alto impacto. Entre los casos más destacados se encuentra David (cabecera), con un total de 14,697 registros; seguido por Pacora con 13,935, y Juan Díaz con 12,821, ambos pertenecientes al área metropolitana de la capital. Estos datos confirman la tendencia general de concentración delictiva en zonas urbanas, aunque también revelan que Ciudad de Panamá no es siempre el principal foco de incidencia, lo cual sugiere la existencia de dinámicas territoriales y sociales diferenciadas que también inciden en la configuración del fenómeno.

Un hallazgo especialmente relevante es la inexistencia de registros en 59 corregimientos. Esta ausencia podría explicarse, por un lado, por una baja incidencia real de delitos en dichos territorios; sin embargo, es más probable que esto se deba a barreras estructurales que dificultan o impiden el acceso a los canales de denuncia.

El temor a represalias, junto con aquella desconfianza que hay hacia las autoridades, además de la poca existencia o nula existencia de infraestructura judicial pertinente, podrían generar un subregistro importante. Por ello, este estudio evidencia la relevancia de incorporar la “cifra negra” del delito a los análisis sobre criminalidad, puesto que su exclusión de los registros oficiales puede generar un diagnóstico sesgado de la problemática y, como consecuencia, dificultar el diseño de políticas públicas eficaces.

A partir del enfoque metodológico, este capítulo resalta el valor de la geomática para abordar fenómenos sociales complejos, como la violencia urbana. El uso de los SIG permitió no solo representar espacialmente la distribución del delito, sino también generar datos estratégicos útiles para la formulación de acciones orientadas a la prevención y a la promoción de la seguridad ciudadana. De hecho, este proceso metodológico puede ser replicable en otras instituciones interesadas en incorporar la dimensión territorial dentro de sus procesos analíticos y de planificación.

Sin embargo, es importante reconocer las limitaciones que presentan este tipo de estudio, principalmente en Panamá. Al trabajar únicamente con datos provenientes de fuentes oficiales, es posible que existan omisiones, subregistros o inconsistencias que afecten la precisión del análisis. Asimismo, la utilización de corregimientos como unidad espacial y la falta de georreferenciación detallada, restringen la posibilidad de identificar patrones delictivos con mayor especificidad. A ello se suma la ausencia de variables socioeconómicas y del componente temporal, lo cual limita la interpretación de posibles cambios o tendencias a lo largo del tiempo. Por otra parte, es necesario interpretar con

cautela los mapas generados, ya que su lectura, sin ajuste por densidad poblacional o tasas específicas, puede inducir a percepciones erróneas sobre la peligrosidad de determinadas zonas.

Finalmente, este capítulo constituye un primer acercamiento al análisis geoespacial de la violencia urbana en Panamá. Se espera que investigaciones futuras profundicen esta línea, incorporando mayor desagregación territorial, análisis multivariado y comparaciones regionales, con el propósito de aportar una comprensión más amplia e integral de las dinámicas delictivas en el contexto nacional.

Referencias

- Baumann Burgos, M. (2005). Cidade, territórios e cidadania. *Dados. Revista de Ciências Sociais*, 48(1), 189–222. <https://www.redalyc.org/articulo.oa?id=21848107>
- Brantingham, P. L., y Brantingham, P. J. (2017). Environment, routine, and situation: Toward a pattern theory of crime. In *Routine activity and rational choice* (pp. 259-294). Routledge.
- Buzai, G. D., y Montes Galbán, E. J. (2021). *Estadística espacial: Fundamentos y aplicación con sistemas de información geográfica*. <https://ri.conicet.gov.ar/handle/11336/161048>
- Carrión, F. M. (2008). Violencia urbana: Un asunto de ciudad. *EURE* (Santiago), 34(103), 111–130. <https://doi.org/10.4067/S0250-71612008000300006>
- Cohen, L. E., Felson, M., Ángel, M., y Paños, C. (2018). Cambio social y tendencias en la tasa de criminalidad: Un enfoque desde las actividades cotidianas. *Revista de Derecho Penal y Criminología*, 3(20).
- Hernández Sampieri, R., Fernández Collado, C., y Baptista Lucio, M. del P. (2014). *Metodología de la investigación* (6ª ed.). McGraw-Hill.
- Misse, M. (2008). *Sobre a acumulação social da violência no Rio de Janeiro. On the Social Accumulation of Violence in Rio de Janeiro*. <https://www.redalyc.org/articulo.oa?id=74221620002>
- Oficina de las Naciones Unidas para las Drogas y el Delito. (2023). Estudio mundial sobre el homicidio 2023. https://www.unodc.org/documents/data-and-analysis/gsh/2023/Global_study_on_homicide_2023_web.pdf
- Saborío, S. (2019). Violencia urbana: Análisis crítico y limitaciones del concepto. *Revistarquis*, 8(1), 61–71. <https://doi.org/10.15517/RA.V8I1.35798>
- Shaw, C. R., y McKay, H. D. (2010). Juvenile delinquency and urban areas: A study of rates of delinquency in relation to differential characteristics of local communities in American cities (1969). In *Classics in environmental criminology* (pp. 103-140). Routledge.

Capítulo X. Importancia de la planeación urbana en la habitabilidad urbana: la vivienda saludable

Ma. de los Ángeles Martínez Ortega¹

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),

Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

La planeación urbana involucra varios factores referentes; uno de sus principales compromisos es participar directamente en la HABITABILIDAD HUMANA, entendida esta como el saber y poder vivir. Por otro lado, las variables implicadas en la evaluación de la habitabilidad urbana están vinculadas con las dimensiones de infraestructura, equipamientos y servicios. El objetivo de esta investigación fue identificar cómo el individuo percibe la habitabilidad, considerando la infraestructura, el equipamiento y los servicios en su entorno residencial, y cómo ello impacta en su vivienda y se refleja en el modo de vida cotidiano. Es un estudio mixto de corte transversal. Se realizó primeramente un estudio a nivel internacional, posteriormente a nivel nacional, para concretarlo en la Zona Metropolitana del Valle de México. Esto se constató con un muestreo con 460 casos, todos adultos. Como resultado se observó a nivel nacional la situación de habitabilidad, según la Conavi (2022). Se contabilizó un total de 36,968,871 viviendas, de las cuales el 24.3% del parque habitacional a nivel nacional, se encontraban en condición de rezago. En los resultados de estudio del caso, 53% fue femenino, y el 47% masculino, mientras el 67% está relacionado con el tema de vivienda saludable. El 88% consideró que su vivienda era adecuada y además saludable. Los resultados coinciden en que en ambos casos se aprecia una vivienda saludable o adecuada, con una condición de habitabilidad aceptable.

Palabras clave: planeación urbana, habitabilidad y vivienda.

Abstract

Urban planning involves several relevant factors, one of its main commitments being to directly contribute to human habitability, understood as the knowledge and ability to live. Furthermore, the variables involved in the assessment of urban habitability are linked to the dimensions of infrastructure, facilities, and services. The objective of this research was to identify how individuals perceive habitability, considering the infrastructure, facilities, and services in their residential environment, and how this impacts their housing and is reflected in their daily lifestyle. This is a mixed, cross-sectional study. The study was first conducted internationally, then nationally, and then specifically in the Metropolitan Area of the Valley of Mexico. This was confirmed

1 Doctora en Educación, Universidad CUGS, Maestra en Ciencias en Administración y Desarrollo de la Educación, Instituto Politécnico Nacional, ESCA Sto. Tomás. Correo: mmartinezo@ipn.mx, ORCID: <https://orcid.org/0000-0002-8483-9844>

by a sample of 460 cases, all adults. As a result, the housing situation was observed nationwide. According to CONAVI (2022), a total of 36,968,871 homes were counted, of which 24.3% of the national housing stock was in a state of disrepair. The results of the Case Study: 53% were female and 47% male, 67% were related to the issue of healthy housing. 88% considered their housing to be adequate and also healthy. The results agree that in both cases, housing is healthy or adequate, with acceptable habitability conditions.

Keywords: urban planning, habilitation and housing.

Introducción

La planeación urbana es un elemento importante en el acontecer humano. Resulta paradójico que, a pesar de que se tiene conciencia de ello en la práctica, no se han obtenido los resultados deseados. Actualmente, una preocupación constante en la sociedad es llegar al desarrollo humano sostenible, en donde se preserve el bienestar humano. En México, existen 11.7 millones de personas que tienen carencias en la calidad y espacios de su vivienda, según el CONEVAL (2025) tomado de CONEVAL (2023). Por otro lado, 22.9 millones de personas tienen carencia de acceso a servicios básicos.

Según Zicardi (2015), el término de habitabilidad ha generado un debate conceptual. Esta autora señala que la habitabilidad es:

“...una noción que encierra múltiples connotaciones y significados. No obstante, adoptando una perspectiva normativa se puede decir que este término hace referencia a la cualidad de habitable que posee una vivienda, lo que está en función de las diferentes características que reúne, entre las cuales destacan: a) las características materiales de la vivienda, b) el tamaño de acuerdo con la composición familiar, c) el acceso y la calidad de los servicios habitacionales, d) la certeza jurídica sobre la propiedad”.

El derecho a la vivienda es un aspecto muy perfilado a nivel internacional. En México, en nuestra Carta Magna se especifica en su Art. 4º. lo siguiente: “Artículo 4. Toda familia tiene derecho a disfrutar de vivienda digna y decorosa. La Ley establecerá los instrumentos y apoyos necesarios a fin de alcanzar tal objetivo” (CONEVAL, SIDS, 2019). De la misma forma, la Ley de Vivienda señala, en su artículo 2: “Se considerará vivienda digna y decorosa la que cumpla con las disposiciones jurídicas aplicables en materia de asentamientos humanos y construcción, salubridad, cuente con espacios habitables y auxiliares, así como con los servicios básicos y brinde a sus ocupantes seguridad jurídica en cuanto a su propiedad o legítima posesión, y contemple criterios para la prevención de desastres y la protección física de sus ocupantes ante los elementos naturales potencialmente” (CONEVAL, SIDS, 2019).

Esta corresponsabilidad ha trascendido a barreras espaciales, creándose instituciones y normatividades específicas a nivel internacional, tratando de cuidar todos los aspectos necesarios para el desarrollo humano integral.

Es importante resaltar el contraste de resultados de 2018 al 2025, en donde el 49.6% de los mexicanos manifestaron estar satisfechos con su vivienda; 41.4% señalaron estar moderadamente satisfechos; únicamente el 7.3% indicaron estar poco satisfechos, y un 1.7% nada satisfechos (INEGI, 2018). Considerando el entorno, 16% manifestó no estar satisfecho con su vecindario, mientras únicamente el 9% está insatisfecho con su vivienda (INEGI, 2018). Para 2024, en una escala del 0 a 10, la población encuestada señaló un nivel de satisfacción de su vivienda con un 8.6 de promedio, sin embargo, contrasta la seguridad, con un promedio de 5.4 (INEGI, 2024).

Por ello, el objetivo de este trabajo es analizar las condiciones de habitabilidad de la sociedad y el impacto que tiene su acontecer, partiendo de un soporte semántico, de su fundamentación teórica, análisis de datos, y el contraste con un estudio de caso.

Es muy importante reflexionar en el impacto de la habitabilidad urbana. Dentro de ello, resaltan algunos factores a considerar, entre los que podemos mencionar:

Salud y Bienestar

- **Salud Física.** Como lo señala Rickenbacker, et al. (2020), el hábitat urbano impacta directamente en la salud física de la población en aspectos importantes como lo son la calidad del aire, los espacios verdes y la infraestructura. El descuido de estos elementos del entorno puede repercutir de manera negativa en el bienestar ciudadano.
- **Salud Mental.** Es un aspecto que debe resaltar, pues los espacios verdes y las áreas públicas bien diseñadas pueden mejorar el bienestar mental al proporcionar espacios para la relajación y la interacción social (Juntti y Ozsezer, 2023).
- **Sostenibilidad Social: calidad de vida.** Es fundamental considerar este aspecto, ya que la habitabilidad de los entornos residenciales es crucial para la sostenibilidad social. Factores como la calidad de la vivienda, la accesibilidad a los servicios y la seguridad del barrio, influyen directamente en la calidad de vida de los residentes (Landázuri, et al., 2013).
- **Diseño y Política Urbana.**

Planificación con políticas urbanas. Esto es de gran impacto, ya que las directrices deben dirigirse a la mejora de la infraestructura, la reducción significativa de la contaminación y el incremento expansivo de las áreas verdes (Gür, 2021).

Para resaltar la importancia del impacto de la habitabilidad humana, se especifican algunos de los principales factores (ver Figura 1).



Figura 1. Factores de la Habitabilidad Humana. Fuente: elaboración propia con datos de: Rickenbacker, et al. (2020), Juntti y Ozsezer (2023), Landázuri, et al. (2013) y Gür (2021).

Se vinculó a las variables de Planeación Urbana, y Habitabilidad Urbana (independientes), con la habitabilidad humana (dependiente). Ello impacta en la propuesta de una vivienda saludable (Figura 2).



Figura 2. VARIABLES. Fuente: elaboración propia. <https://onu-habitat.org/index>

Apreciación Teórica

La planificación urbana, también llamada planificación urbana y regional, es un campo multidisciplinario en el que los profesionales trabajan para mejorar el bienestar de las personas y las comunidades mediante la creación de lugares más convenientes, equitativos, saludables, eficientes y atractivos, tanto ahora como en el futuro (Kochtitzky, et al., 2006). Lo impactante de estos autores es que vinculan este tema con la salud pública.

Primeramente, se realizó un análisis bibliométrico, a través del Scopus, para conocer las diferentes investigaciones que vinculan la planeación urbana con la Habitabilidad Urbana, y cómo esta impacta directamente en la Habitabilidad humana. En ese estudio la mayoría de las fuentes encontradas se referían a cuestiones de salud, por lo que se decidió enfocarse en la búsqueda de documentos científicos que hubieran realizado estudios sobre las tres variables consideradas en esta investigación: la planeación urbana, la habitabilidad urbana como variable independiente, y la habitabilidad humana como variable dependiente.

Se entiende como habitabilidad urbana, preferentemente, a la capacidad de un entorno urbano para brindar los diferentes satisfactores a las necesidades y deseos de su comunidad, garantizando una alta calidad de vida y, desde luego, su bienestar, para por último generar un desarrollo sostenible. Esto va más allá de la sola edificación de su vivienda, pues involucra la interacción de factores físicos, sociales, económicos y ambientales.

Complementando esta apreciación, para tener condiciones precisas de habitabilidad se debe tener en cuenta la relación directa de la vivienda con el entorno, enfatizando la infraestructura, equipamiento y servicios necesarios para lograr una conectividad y movilidad eficaz (SEDATU, 2021).

Es necesario crear condiciones de habitabilidad de los espacios públicos a través de condiciones básicas materiales y de infraestructura (Ley de Asentamientos Humanos, Ordenamiento Territorial y Desarrollo Urbano, 2016). Para ello, se debe resaltar la cualidad de habitable que tiene un espacio construido, en función de normas legales. Desafortunadamente, desde la semántica normativa solo se mencionan sistemas de habitabilidad, sin una clara definición de esta. La Norma Mexicana NMX-AA-164-SCFI-2013 señala, al respecto, los elementos de la Edificación sustentable, sus criterios y los requerimientos ambientales mínimos

En cuanto a la infraestructura urbana, estudiosos como Allen la definen como un sistema de continuidad, facilitando la conectividad y la accesibilidad al uso de diferentes tipos de transporte, generando una movilidad eficiente (Allen, 1999). Otros autores expertos en el tema especifican que una eficaz conectividad y accesibilidad, apoyadas con una infraestructura óptima, facilitan el desarrollo y crecimiento urbano (Santos y De las Rivas, 2008).

A partir de la revisión conceptual de habitabilidad, esta es entendida como una correlación entre la vivienda y el entorno urbano (Landázuri, et al., 2013) donde, como parte del entorno urbano son considerados los equipamientos, infraestructura y servicios con el fin de proporcionar un servicio colectivo (Casals, et al., 2013) que cumpla con la satisfacción de las necesidades de las familias que habitan las viviendas.

Como una orientación específica, para fundamentar la investigación se tomaron como referencia varias teorías que han centrado su objetivo en la habitabilidad urbana, elementos fundamentales, estrategias y propuestas señaladas.

Se inició con un importante referente, la Teoría de Calidad de Vida, ya que centra su atención en la evaluación de la percepción del bienestar del individuo con relación a lo vivenciado en su entorno urbano y dentro de su vivienda, tanto subjetivo como objetivo, considerando algunos indicadores, como pueden ser: acceso a servicios, seguridad, empleo, movilidad, infraestructura, equipamiento y medio ambiente, entre otros, como lo señalan Marans, R. y Stimson, R. (2011). Como un reforzador al derecho a Ser y Estar bien, se tomaron como referencia las propuestas de Lefebvre, (1968) y Harvey, (2008) manifestadas en la teoría del Derecho a la Ciudad, en donde resalta el derecho colectivo a transformar y apropiarse de la ciudad de forma respetuosa, equitativa y democrática, donde se enfatice la corresponsabilidad de la comunidad.

A nivel global, se complementa la fundamentación en la teoría del Desarrollo Urbano Sostenible, (ONU-Hábitat, 2016), que con el afán de seguir construyendo ciudades ecológicas, equitativas y económicamente viables, va integrando de manera puntual la sostenibilidad en Planeación Urbana, puntualizando los indicadores de infraestructura, movilidad y energía. Para fortalecer la semántica, se consideró la teoría del Nuevo Urbanismo (Duany, Plater Zyberk, y Speck, 2001), en donde se fortalece la idea del diseño de ciudades compactas, caminables, de usos mixtos, y algo muy rescatable: donde se ejerce la interacción social y el uso del transporte público como principal servicio de movilidad.

Por otro lado, se encuentra la teoría de la Ciudad Compacta, principalmente estudiada por Jenks, M., Burton, E., y Williams, K. (1996), quienes con el propósito principal de reducir la dependencia del uso del automóvil y fortalecer el cuidado del medio ambiente, proponen la densificación y el uso eficiente del suelo, evitando la innecesaria expansión urbana. En una tendencia de desarrollo humano, se busca el apoyo en la Teoría de la Resiliencia Urbana, en donde Meerow, S., Newell, J., y Stults, M. (2016) unen esfuerzos para promover una dinámica social y ambiental para diseñar y co-crear ciudades resilientes, capaces de vivir, resistir, y recuperarse a través de una adaptación sinérgica con su entorno: cambio climático, pandemias, colapsos económicos, entre otros factores.

Por último, y no menos importante, se consideraron las propuestas de Benedict, M. A., y McMahon, E. (2006), manifestadas en la teoría de Ciudades Verdes-Infraestructura Verde, en donde se resalta la invitación del individuo a tomar conciencia del deterioro ambiental y el impacto en la salud humana. Por ello es que se propone incrementar un vínculo estrecho con la naturaleza en el entorno urbano, para que ello impacte principalmente en una visión recreativa (Figura 3).



Figura 3. Dimensiones de la Habitabilidad Urbana. Fuente: elaboración propia, con datos de ONU-Hábitat (2020); Observación Gral. N.º 4 – ONU (1991), BID (2013); OCDE (2012), IPCC (2022); INECC (México, 2020), CEPAL y ONU-Hábitat (2017); Lefebvre (1968); Harvey (2008) y BID (2013); CEPAL (2021).

Al respecto, se incluyen tres conceptos fundamentales para este estudio, en compañía de su respectiva definición:

- Rezago habitacional: enfatiza la desigualdad y exclusión de lo que serían los señalamientos que se incluyen en la habitabilidad interna y externa de la vivienda. También consideran aspectos cruciales en la identidad y libertad del usuario para habitar su vivienda y entorno (SEDATU-CONAVI, 2025).
- Vivienda: según la Ley de Vivienda (2024), es el papel del Estado impulsar y organizar las actividades inherentes a la materia, por sí mismo y con la participación de los sectores social y privado. La vivienda es un espacio geográfico necesario para el desarrollo nacional.
- Vivienda Adecuada: según SEDATU (2024), señalada por la Conavi (2022, p. 13), la vivienda adecuada es el lugar específico que puede habitar un individuo, que cumpla con las siguientes condiciones: ventilación e iluminación natural, dimensiones adecuadas para el número de integrantes, seguridad, infraestructura, equipamiento y servicios necesarios para su bienestar. Se considera una vivienda adecuada la concepción más allá del espacio físico delimitado por cuatro paredes y

un techo, como parte de un marco holístico en el que se convierte en un elemento central del desarrollo sostenible (SEDATU, 2024, tomado de ONU-Hábitat, 2018).

Seguimiento metodológico

Se utilizó un método mixto o híbrido, con una proyección deductiva (cuantitativa), e inductiva (cualitativa). Con el análisis metainferenciado, se pudo lograr un entendimiento más profundo y mayor del fenómeno estudiado (Hernández Sampieri y Mendoza, 2018).

Con el procedimiento deductivo, a través del análisis cuantitativo de diferentes fuentes se pudieron abstraer cuestiones semánticas y soporte teórico sobre la problemática abordada. Se analizaron datos de INEGI, CONAVI, SEDUVI, México ¿cómo vamos?, y CONEVAL.

Posteriormente se realizó un estudio de caso puntual para identificar la abstracción de la juventud referente a la percepción de su habitabilidad urbana a través de una visión propia de cómo es su vivienda. Para tal propósito, se realizó una encuesta de 460 elementos. Cabe enfatizar que las preguntas realizadas se fortalecieron con algunas cuestiones semánticas y/o normativas, para que fueran un referente. Las variables consideradas se presentan en la Figura 4.




Figura 4. Análisis de variables. Fuente: elaboración propia.

Para fundamentar el proceso metodológico y el análisis de resultados, se tomó como referencia el marco de la geografía cuantitativa, con el procedimiento específico del análisis espacial, guiados por la orientación de Buzai y Montes (2021), los cuales como estudiosos del tema especifican que los Sistemas de Información Geográfica (SIG's), son una importante herramienta que permite estudiar la escala humana en una realidad estratificada, donde a través del fundamento teórico se puede explicar la abstracción de los datos obtenidos. Con el apoyo del programa ArcGIS se realizó un mapeo para visualizar los datos, tanto de las diferentes fuentes analizadas, como de los datos del estudio de caso. Para visualizar los datos, se ejecutó el siguiente procedimiento:

Se promediaron los valores obtenidos, creando una tabla con el nombre de cada Alcaldía y Municipio con su valor promedio, obteniendo un total de 33 municipios y 16 alcaldías. La presentación de los datos se realizó a través de los Sistemas de Información Geográfica.

Estos valores se exportaron a un archivo .csv (valores separados por comas), para utilizarlos más adelante en un SIG. Se obtuvieron los archivos *Shapefile*, de los límites municipales para la zona de estudio, desde el Marco Geoestadístico, sistema desarrollado por INEGI.

Finalmente, se abrieron los archivos *Shapefile* dentro de un SIG. Dentro de cada uno de estos elementos se efectuó una unión con el archivo .cvs trabajado con anterioridad, cuidando que los nombres de los campos, tanto del *Shapefile* como del .cvs, coincidieran en ortografía. Una vez realizada la unión de información, los promedios del archivo .cvs se agregaron al archivo *Shapefile* en una nueva columna, permitiendo su representación gráfica desde el SIG.

Resultados

Considerando el primer objeto de estudio, se tomaron como referencia los datos del Índice de Progreso Social (IPS), el cual mide el desempeño social en las diferentes entidades, considerando tres dimensiones: Necesidades Humanas básicas, Fundamentos del Bienestar y Oportunidades; estos desgregados en 49 indicadores sociales y ambientales. Se tomaron valores de 0 a 100, en donde cero (0) es el menor progreso posible, y cien (100) el máximo (México ¿cómo vamos?, 2024). Como se puede observar en la Figura 5, en un seguimiento de 2015 a 2023, contrastando los resultados de la zona de estudio, CDMX incrementó su índice de 68.7% al 74.9%, y el Estado de México del 61.1% al 65%. La CDMX se mantuvo siempre por encima del promedio a nivel nacional; no así el Estado de México, ya que su resultado fue muy variable, y actualmente se encuentra a 8 décimas por debajo del promedio.




Figura 5. Índice de progreso social a nivel Nacional. Fuente: elaboración propia con base en información del Índice de Progreso Social de México, ¿cómo vamos? (2023).

Parte de la situación prevaleciente en la zona estudiada, la CDMX, encabeza la lista con un 74.9%, por encima del porcentaje a nivel Nacional (65.8). Sin embargo, ello no significa que la apreciación de habitabilidad sea algo decoroso (Figura 6).




Figura 6. Índice de progreso Social a nivel Nacional. Fuente: elaboración propia con base en información del Índice de Progreso Social de México, ¿cómo vamos? (2023).

Contrastando estos datos con la CONAVI (2022), para el año 2022 se contabilizó un total de 36,968,871 viviendas, en donde el 24.3%, (8,977,409 viviendas) se encontraban en condición de rezago.

Es importante señalar que además de rezago habitacional, existe una condición latente de vivienda precaria. Los materiales utilizados, además, no abordan su carácter integral en torno a la definición de vivienda adecuada. El estudio contrasta también los resultados de la zona estudiada (ZMVM).

Comparando los resultados de 2018 al 2025 en relación a la satisfacción con su vivienda, casi la mitad de los mexicanos encuestados reportaron sentirse satisfechos con ella (49.6%); y moderadamente satisfechos un 41.4%; paradójicamente, 7.3% reportaron poca satisfacción, y solo el 1.7% se mostró nada satisfecho (INEGI, 2018).

En cuanto a una evaluación externa, un 16% de los habitantes no está satisfecho con su vecindario, y un 9% está insatisfecho con su vivienda (INEGI, 2018). Para 2024, en una escala del 0 a 10, la población encuestada señaló un nivel de satisfacción de su vivienda con un 8.6 de promedio; sin embargo, contrasta la seguridad, con un promedio de 5.4 (INEGI, 2018).

Con relación a la zona estudiada, como se observa en la Figura 7, la CDMX presentó un 5.9% de rezago, y el Estado de México más del doble, con un 13.7%.

Para contrastar los resultados de la zona estudiada, se consideró el Índice de Desarrollo Social (IDS), entendido como la medida agregada que resume ocho

(8) indicadores: vivienda, educación seguridad, salud, adecuación sanitaria, energía, telecomunicaciones, bienes durables y educación de los individuos, según datos de INEGI (2020).




Figura 7. Rezago habitacional en la ZMVM. Fuente: elaboración propia con datos de CONAVI (2022), SIESCO, datos de la ENIGH 2020 y 2022.

Como ejemplo, se contrastó el mapa de la CDMX (oficial), con la encuesta aplicada. Analizando los resultados, hay una diferencia de lo que señala el IDS y lo que contestaron lo encuestados. Paradójicamente, el reporte oficial señala la parte sur de la CDMX con un índice bajo y muy bajo.

Por su parte, los encuestados definieron la salud de su vivienda en un estado entre 3 y 4 (de una escala del 1 al 5, donde 1 es nada saludable y 5 es muy saludable), considerando aceptable la salud de su vivienda, tanto en la zona sur, como en el resto de las alcaldías (ver Figura 8 y Figura 9).




Figura 8. Índice de Desarrollo Social CDMX. Fuente: INEGI (2020).




Figura 9. Mapa de encuesta. Fuente: elaboración propia.

Pasando al análisis de datos de la encuesta realizada en el caso de estudio de la ZMVM, de un cuestionario de 15 ítems, el presente estudio se centra en 3 preguntas troncales: (4, 10 y 15).

De acuerdo con la Figura 10 (punto 4), el 95% la considera saludable su vivienda.




Figura 10. Salud de vivienda. Fuente: elaboración propia.

Como se observa en la Figura 11, el obstáculo que más se señala es el costo para realizar las mejoras, así como la información sobre cómo hacerlo, junto con las limitaciones en la infraestructura y los servicios; además del tiempo para implementar los cambios.




Figura 11. Obstáculos en el mantenimiento de vivienda. Fuente: elaboración propia.




Figura 12. Importancia de la Salud de la vivienda. Fuente: elaboración propia.

La mayoría de los entrevistados son conscientes de la salud de la vivienda en que habitan (Figura 12). Para contrastar los datos, se mapearon los resultados de la pregunta 4 (Figura 10), referente a la apreciación de los usuarios de la salud de su vivienda. Como se percibe en las Figuras 13 y 14, en el número 1 (menos saludable), únicamente 3 personas ubicaron su vivienda en ese nivel dentro del norte u oriente de la CDMX. En el nivel 2, hubo 16 respuestas, ubicándose en oriente y norte. Luego aparece el nivel 3, con 95.1% en oriente y sureste. En el nivel 4 hubo 197 respuestas, correspondientes al oriente y noroccidente; y en el nivel 5 se hallan 115 respuestas con respecto al nor-oriente. En las Figuras 14 y 15, muestra la evaluación que realizaron los encuestados es contrastante, ya que predomina una evaluación de 3 a 5, siendo el 4 el más representativo. Es de observar que el nivel 5 se ubica principalmente al norte de CDMX y Toluca.




Figura 13. Vivienda Saludable (Nivel 1-4). Fuente: elaboración de la exalumna de la MACAU, Irma López Pérez.




Figura 14. Vivienda Saludable (Nivel 5). Fuente: elaboración de la exalumna de la MACAU, Irma López Pérez.




Figura 15. Vivienda Saludable global. Fuente: elaboración de alumno de la MCAU Víctor M. Sánchez Vega.

Discusión

Un estudio realizado por una investigadora de la UNAM, de igual manera pretendió analizar la habitabilidad de algunos municipios contrastándolos con la CDMX de la ZMVM, incluyendo algunos indicadores en función de la percepción de la vivienda y el espacio construido. Dicho estudio coincide, al igual que esta investigación, en realizarlo con una mirada mixta, tomando datos duros de la encuesta intercensal, y complementándolos con entrevistas. Se ratifica la importancia de conocer la percepción de la población sobre la habitabilidad. El estudio considera tres dimensiones físico-espaciales, en donde se especifica que se cuenta con una vivienda. Al igual que este estudio, hay coincidencia también en que se debe contar con elementos para visualizar un hogar, y con sus condiciones estructurales y tamaño, en donde se debe tener claro los integrantes de la familia y las relaciones que se crean dentro del hogar (Márquez y Pardo, 2024). En cuanto al espacio público, se cuenta con equipamiento necesario, sin considerar la calidad y el mantenimiento. Algo muy importante, y que es necesario considerar en estudios posteriores, es el aspecto socioeconómico. Dentro de la vivienda se encuentran pequeños negocios, para apoyar en el gasto familiar. Ante ello se ratifica la necesidad de hacer ejercicios a escala más pequeña para entender su realidad, visualizando las diferencias del centro y las periferias, e ir más allá de datos estadísticos.

Por otro lado, Zicardi (2015) realiza un estudio como reflexión, para que la producción de la vivienda tenga una visión más ecléctica para aquellos que se involucran en la producción habitacional; una vivienda que además de considerar aspectos del déficit cuantitativo, introduce aspectos y elementos que garanticen privilegios de habitabilidad, desde el punto de vista cualitativo, para los usuarios (en este caso los mexicanos de todos los sectores), para que esto llegue a la política pública (social). Actualmente, en teoría se debe considerar esto, aunque en la práctica se continúan reproduciendo parques habitacionales que no garantizan una buena calidad de vida para sus ocupantes.

Salinas Arreortua y Pardo Montaña (2020) analizan cómo la política de vivienda social en la periferia oriente y norte de la ZMVM ha deteriorado las condiciones reales de habitabilidad, pese al discurso oficial de mejora. Un estudio realizado por Pedrotti y Cota (2024) presenta un estudio reflexivo sobre los diferentes problemas de habitabilidad en el ámbito urbano, directamente en lo relacionado con la salud. Se trata de un caso de estudio en la Zona Metropolitana de Toluca. Pedrotti señala cómo esta problemática impacta en la vivienda, en los hogares y grupos sociales, y propone un reposicionamiento de las condiciones de habitabilidad como consecuencia directa de la pandemia por el Covid-19, solicitando reflexionar sobre la ciudad y su uso adecuado. Es de resaltar la reflexión que hace sobre lo estructural, coyuntural, lo deseable, y sobre todo y de manera objetiva, lo posible.

Conclusiones

La habitabilidad urbana influye significativamente en la habitabilidad humana, afectando diversos aspectos de la salud, el bienestar y la calidad de vida.

Se tomó como referencia el objetivo, que fue identificar cómo el individuo percibe la habitabilidad considerando la infraestructura, el equipamiento y servicios en su entorno residencial, y cómo ello impacta en su vivienda y se refleja en su modo de vida cotidiano. Resulta un importante compromiso social realizar un análisis más específico, contrastando de una forma meticulosa los datos oficiales con la investigación cualitativa, en donde se percibe de manera directa el sentir de los habitantes, en esa búsqueda de Ser y Estar bien, logrando una congruencia entre lo estructural, lo deseable y lo real, como maneja Zicardi (2015). Por otro lado, es necesario voltear de manera directa y reflexiva hacia lo que la norma y la política establecen, y la realidad (Salinas, 2020), ya que el nivel de habitabilidad deseado está lejos de alcanzarse, y se presenta apenas como un ideal.

En resumen, la habitabilidad urbana tiene un profundo impacto en la habitabilidad humana, influyendo en la salud, el bienestar y la equidad social. Una planificación urbana eficaz, y políticas inclusivas, son esenciales para mejorar la habitabilidad de los espacios urbanos y garantizar que todos los residentes se benefician de mejores condiciones de vida.

Agradecimientos

Agradecimiento especial al apoyo de IPN, a través del Proyecto 20240362 “Infraestructura y servicios, elementos importantes en la Planeación Urbana”, del cual deriva este capítulo.

Referencias

- Allen, S. (1999). *Points+lines: diagrams and projects for the city*. New York: Princeton Architectural Press.
- Banco Interamericano de Desarrollo [BID]. (2013). *Índice de Ciudades Emergentes y Sostenibles (ICES)*. <https://publications.iadb.org>
- Benedict, M. A., y McMahon, E. T. (2006). *Green Infrastructure: Linking Landscapes and Communities*. Island Press.
- Buzai, G., y Montes, E. (2021). *Estadística Espacial: Fundamentos y aplicación con Sistemas de Información Geográfica*.
- Casals, M., Arcas, J., y Cuchí, A. (2013). Aproximación a una habitabilidad articulada desde la sostenibilidad. Raíces teóricas y caminos por andar. *Revista INVI*, 28(77). <http://dx.doi.org/10.4067/S0718-83582013000100007>
- CEPAL. (2021). *Panorama Social de América Latina*. <https://cepal.org>

- Comisión Económica para América Latina y el Caribe [CEPAL] y ONU-Hábitat. (2017). *Observatorio de Ciudades de América Latina y el Caribe*. Naciones Unidas. <https://observatoriociudades.cepal.org>
- CONAVI. (2022). Sistema Estadístico de la Comisión Nacional de Vivienda. <https://siesco.conavi.gob.mx/siesco/rezago.aspx>. (2025).
- CONAVI. (2025). Primer Informe de Autoevaluación
- CONEVAL. (2019). Sistema de Información de Derechos Sociales (SIDS).
- Consejo Nacional de Evaluación de la Política de Desarrollo Social [CONEVAL]. (2023). *Medición de la pobreza en México 2022*. <https://www.coneval.org.mx>
- Consejo Nacional de Evaluación de la Política de Desarrollo Social [CONEVAL]. (2025). *Indicadores de pobreza y carencias sociales en México*. <https://www.coneval.org.mx>
- Duany, A., Plater Zyberk, E., y Speck, J. (2001). *Suburban Nation: The Rise of Sprawl and the Decline of the American Dream*. North Point Press.
- Gür, M. (2021). Theories, Techniques, Strategies for Spatial Planners and Designers: Planning, Design, Applications. The Analysis of Urban Health in Bursa Based on Resident Perceptions. Bursa Uludag University, Faculty of Architecture, Department of Architecture, Bursa, Turkey.
- Harvey, D. (2008). *The Right to the City*. *New Left Review*, 53.
- Hernández Sampieri, R., y Mendoza, C. (2018). *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Interamericana (versión digital).
- Instituto Nacional de Ecología y Cambio Climático [INECC]. (2020). *Informe del estado del medio ambiente en México*. <https://www.gob.mx/inecc>
- Instituto Nacional de Estadística y Geografía [INEGI]. (2018). Módulo Básico de Bienestar Autorreportado (BIARE).
- Instituto Nacional de Estadística y Geografía [INEGI]. (2020). *Marco Geoestadístico Nacional* [Base de datos]. <https://www.inegi.org.mx/app/biblioteca/ficha.html?upc=889463807469>
- Instituto Nacional de Estadística y Geografía [INEGI]. (2021). Encuesta Nacional de Ingresos y Gastos de los Hogares 2020. (ENIGH) Nueva Serie. Descripción de la base de datos. https://www.inegi.org.mx/contenidos/productos/prod_serv/contenidos/espanol/bvinegi/productos/nueva_estruc/889463901242.pdf
- Instituto Nacional de Estadística y Geografía [INEGI]. (2022). Encuesta Nacional de Ingresos y Gastos de los Hogares (ENIGH) 2022. Manual del Entrevistador. https://www.inegi.org.mx/contenidos/productos/prod_serv/contenidos/espanol/bvinegi/productos/nueva_estruc/889463904779.pdf
- Instituto Nacional de Estadística y Geografía [INEGI]. (2024). BIARE.
- Jenks, M., Burton, E., y Williams, K. (1996). *The Compact City: A Sustainable Urban Form?* E & FN Spon.

- Juntti, M., y Ozsezer Kurnuc, S. (2023). Factors influencing the realisation of the social impact of urban nature in inner-city environments: A systematic review of complex evidence. *Ecological Economics*, 211. <https://doi.org/10.1016/j.ecolecon.2023.107872>
- Kochtitzky, Ch., Frumkin, H., Rodríguez, R., Dannenberg, A., Rayman, J., Rosa, K., Gillig, R, y Kanter, T. (2006). Planificación urbana y salud pública en los CDC. *MMWR. Morbidity and mortality weekly report*, 55. ISSN: 1545861X.
- Landázuri, A., Mercado, S., y Terán S. (2013). Sostenibilidad de los entornos residenciales. *Suma Psicológica*. UNAM. DOI: [10.14349/sumapsi2013.1463](https://doi.org/10.14349/sumapsi2013.1463)
- Lefebvre, H. (1968). *Le droit à la ville*. Anthropos.
- Ley de Asentamientos Humanos, Ordenamiento Territorial y Desarrollo Urbano (2016). Cámara de Diputados del H. Congreso de la Unión.
- Ley de Vivienda. (2024). Cámara de Diputados del H. Congreso de la Unión.
- Marans, R. W., y Stimson, R. J. (Eds.). (2011). *Investigating Quality of Urban Life*. Springer.
- Márquez Díaz, S., y Pardo Montaña, A. M. (2024). De la medición a la percepción. Condiciones de habitabilidad en la periferia de la Zona Metropolitana del Valle de México. *Territorios*, (50). <https://doi.org/10.12804/revistas.urosario.edu.co/territorios/a.12247>
- Meerow, S., Newell, J. P., y Stults, M. (2016). Defining urban resilience: A review. *Landscape and Urban Planning*, 147, 38–49.
- México, ¿cómo vamos? (2023). Índice de Progreso Social. mexicocomovamos.mx/indice-de-progreso-social/
- México, ¿cómo vamos? (2024). Índice de Progreso Social. mexicocomovamos.mx/indice-de-progreso-social/
- Norma Mexicana. NMX-AA-164-SCFI-2013
- ONU-Habitat (2018). Vivienda y ODS en México. Programa de las Naciones Unidas para los Asentamientos Humanos.
- ONU-Hábitat. (2016). New Urban Agenda. Quito: ONU-Hábitat. <https://habitat3.org>
- ONU-Hábitat. (2020). *Urban Indicators Guidelines and New Urban Agenda*. United Nations Human Settlements Programme. <https://unhabitat.org>
- Organización de las Naciones Unidas [ONU]. (1991) Comité de Derechos Económicos, Sociales y Culturales. *Observación General N.º 4: El derecho a una vivienda adecuada*. <https://www.ohchr.org>
- Organización para la Cooperación y el Desarrollo Económico [OCDE]. (2012). *Compact City Policies: A Comparative Assessment*. OECD Publishing. <https://www.oecd.org/gov/compact-city.htm>
- Pedrotti, C. I., y Cota Díaz, E. C. (2024). Habitabilidad de la vivienda urbana y covid-19: Lo estructural, lo coyuntural, lo deseable y lo posible desde una metrópoli mexicana. *Territorios*, (50), 1-30. <https://doi.org/10.12804/>

- Rickenbacker, H., Vaden, J., y Bilec, M. (2020). Engaging Citizens in Air Pollution Research: Investigating the Built Environment and Indoor Air Quality and Its Impact on Quality of Life. *Journal of Architectural Engineering*. DOI: [10.1061/\(ASCE\)AE.1943-5568.0000439](https://doi.org/10.1061/(ASCE)AE.1943-5568.0000439)
- Robles, M., Gutiérrez, L., y Mendoza, R. (2020). Habitabilidad y revitalización urbana: la unidad familiar básica como un instrumento clave para evaluar el potencial de regeneración urbana. Alpuche, M. (Coord.). Estudios sobre habitabilidad y bienestar en la ciudad. Universidad de Sonora.
- Salinas, L., y Pardo, M. (2020). Política de vivienda y habitabilidad en la periferia de la Zona Metropolitana del Valle de México. <http://dx.doi.org/10.4067/S0718-34022020000200051>
- Santos, L., y De las Rivas, J. (2008). Ciudades con Atributos: Conectividad, Accesibilidad y Movilidad. *Ciudades* 11, pp. 13-32. DOI: [10.24197/ciudades.11.2008.13-32](https://doi.org/10.24197/ciudades.11.2008.13-32)
- Secretaría de Desarrollo Agrario, Territorial y Urbano [SEDATU]. (2024). Guía para la Incorporación de la vivienda adecuada en instrumentos prospectivos y multiescalares para el desarrollo urbano. https://www.gob.mx/cms/uploads/attachment/file/936039/Guia_para_la_incorporacion_de_la_vivienda_adecuada_en_instrumentos_prospectivos_urbanos_para_los_distintos_niveles_de_gobierno.pdf
- Secretaría de Desarrollo Agrario, Territorial y Urbano [SEDATU]. CONAVI. (2025). Informe de Autoevaluación. https://www.conavi.gob.mx/Inf_Aut/2025/Primer_Informe_de_Autoevaluacion_2025.pdf
- Secretaría de Desarrollo Agrario, Territorial y Urbano [SEDATU]. (2021). El Sistema Nacional de Información e Indicadores de Vivienda (SNIIV).
- The Intergovernmental Panel on Climate Change [IPCC]. (2022). *Sixth Assessment Report–Urban Systems*. Intergovernmental Panel on Climate Change. <https://www.ipcc.ch>
- Zicardi, A. (2015). Cómo viven los mexicanos. Análisis regional de las condiciones de habitabilidad de la vivienda. Encuesta Nacional sobre las Condiciones de Habitabilidad de la Vivienda. UNAM.

Capítulo XI. Regeneración urbana y análisis territorial: propuesta para la zona Roma, Condesa y Doctores

Luis Armando Soto Martínez¹

Universidad Nacional Autónoma de México. Facultad de Arquitectura, Ciudad Universitaria. CDMX.

Resumen

Este capítulo desarrolla una propuesta metodológica orientada a la identificación de proyectos de regeneración urbana en la zona Roma-Condesa-Doctores, en la Ciudad de México. A través del uso combinado de análisis espacial, multicriterios y observación del territorio, se propone una estrategia que considera variables sociales, económicas, ambientales y de movilidad. El objetivo central es mejorar la funcionalidad del espacio público mediante intervenciones que respondan a las condiciones reales del entorno urbano y favorezcan la cohesión social, el equilibrio territorial y la calidad de vida. Se localiza un nodo estratégico que, por su ubicación y dinámica, puede articular flujos y usos diversos en la zona. La propuesta parte del reconocimiento de la estructura urbana existente y de la lectura crítica del contexto, apostando por procesos de transformación urbana integrales, sostenibles y viables. El capítulo contribuye con herramientas útiles para la toma de decisiones en el diseño y planificación de proyectos urbanos con base territorial.

Palabras clave: espacio público, regeneración urbana, proyecto urbano.

Abstract

This chapter presents a methodological approach aimed at identifying urban regeneration projects in the Roma-Condesa-Doctores area of Mexico City. By combining spatial analysis, multicriteria evaluation, and field observation, the proposal incorporates social, economic, environmental, and mobility-related variables. The core objective is to enhance public space functionality through interventions that respond to the real conditions of the urban environment while promoting social cohesion, territorial balance, and quality of life. A strategic node is identified, whose location and dynamics allow for the articulation of various flows and land uses in the area. The approach builds on a detailed understanding of the existing urban structure and a critical reading of the context, advocating for urban transformation processes that are comprehensive, sustainable, and feasible. The chapter contributes tools for decision-making in the design and planning of urban projects grounded in the specific characteristics of the territory.

Palabras clave: espacio público, regeneración urbana, proyecto urbano.

1 Candidato a Maestro en Urbanismo en el área Urbano Regional por el Posgrado en Urbanismo de la Universidad Nacional Autónoma de México (UNAM) y Licenciado en Arquitectura por la Universidad La Salle, Ciudad de México. Correo: lasm.fa@unam.mx

Introducción

La geomática es una disciplina fundamental en el análisis y comprensión del espacio geográfico, esto, por su capacidad y herramientas para recolectar, integrar y analizar datos espaciales y no espaciales, permitiendo abordar problemas complejos, y facilita la toma de decisiones que ayudan a promover un desarrollo sostenible y resiliente en las distintas escalas: global, nacional, regional, local e interurbana.

En la escala global se monitorean los efectos producidos por el cambio climático, así como las condiciones ambientales y la realización de estudios geopolíticos; en la escala nacional se monitorea y da seguimiento a los recursos naturales, áreas naturales protegidas, cuerpos de agua, infraestructuras, etc., además de poder visualizar y desarrollar políticas nacionales derivadas de los análisis geoespaciales. A escala regional es de mucha utilidad, al monitorear y evaluar las cuencas hidrográficas, evaluar los tipos de suelos y su productividad, los riesgos naturales, las zonas vulnerables, así como el desarrollo de planes de ordenamiento ecológico territorial y de desarrollo urbano regional; en la escala local, se lleva a cabo el manejo de los parques urbanos, de las infraestructuras y servicios públicos, así como la elaboración de los programas de desarrollo urbano y los análisis de los grandes proyectos urbanos o de gran impacto urbano y/o ambiental; donde dichos análisis son más puntuales y muy definidos.

Con base en una metodología mixta, se abordará en este capítulo la escala interurbana de manera práctica, utilizando técnicas y herramientas de la geomática, como lo son la recolección de información, su sistematización, interpretación y representación cartográfica a través del Sistema de Información Geográfica (SIG). Con base en la metodología, la experiencia y percepción propia, se propone un proceso para la realización del análisis urbano que permita y sustente la determinación y posibilidad de un proyecto de regeneración urbana a través de la intervención del espacio público, consiguiendo mayor vinculación e integración del contexto y entorno inmediato, mejorando la movilidad y el aprovechamiento de la zona.

El crecimiento desordenado y la obsolescencia de los espacios públicos en las ciudades traen problemas en la funcionalidad, contribuyendo a la fragmentación social, el deterioro en la infraestructura, el aumento en la desigualdad y un impacto ambiental poco favorable. Ante esta problemática, la regeneración urbana es una opción, siendo un proceso integral que retoma y transforma áreas urbanas y espacios públicos degradados, subutilizados o en declive, para intervenirlos, recuperarlos y mejorar su funcionalidad y sostenibilidad.

De acuerdo con Roberts y Sykes (2000), la regeneración urbana no solo es una “renovación física”, abarca diversos aspectos, como los sociales, económicos, culturales, tradicionales y ambientales (Carmon, 1999), además de las dinámicas urbanas de manera integral (Colantonio y Dixon, 2011). Para

el caso de estudio de la zona Condesa-Roma-Doctores, se expone el proceso que se puede seguir para llegar a determinar los espacios públicos susceptibles a regenerarse dentro de un contexto urbano, los cuales proporcionan una mejor funcionalidad, habitabilidad y calidad de vida a sus residentes, visitantes y población flotante que transita y trabaja en la zona.

Para la selección de una metodología de análisis, el primer paso es la determinación del área a diagnosticar, para que su ubicación geográfica, sus características y condiciones dentro de la ciudad permitan un primer criterio de los análisis a realizar, dando la pauta a la selección de la metodología más adecuada, según el objetivo que se desea alcanzar, en este caso, la determinación de proyectos de regeneración urbana. El área por diagnosticar se ubica al sur de la alcaldía Cuauhtémoc en la Ciudad de México, la cual se conforma por las siguientes colonias: Condesa, Hipódromo, Hipódromo Condesa, Roma Norte, Roma Sur, Centro Urbano Benito Juárez, Doctores y Buenos Aires, con características y dinámicas diversas, las cuales conforman el perímetro que se muestra en la Figura 1.

Metodología y resultados

Para este tipo de estudio, la metodología implementada es de Evaluación Multicriterio para los análisis correspondientes, ya que permite abordar los problemas urbanos con precisión y eficiencia, combinando datos espaciales con criterios sociales, económicos, funcionales y ambientales, que ayuden a priorizar la zona susceptible a regenerar, la cual permita su resiliencia y adaptación a las dinámicas urbanas y necesidades actuales. También se tendrá una aproximación a la metodología de Análisis de Escenarios, donde de manera muy general se ayude a establecer criterios de vínculos en el contexto; esta metodología se deberá utilizar más a fondo después de determinar si dentro del área de estudio es factible proponer un proyecto de regeneración urbana, creando escenarios posibles, al ser desarrollado e implementado el proyecto específico de regeneración.

Con la metodología de Evaluación Multicriterio, se combinaron los datos espaciales con los criterios sociales, económicos y ambientales, observando los patrones de movilidad, accesibilidad, usos del suelo y cercanía a equipamientos y servicios. Se realizaron análisis para determinar las dinámicas urbanas del área a diagnosticar, extrayendo la información que sustenta y ayuda en la determinación de un área factible al establecimiento de un proyecto de regeneración que la dinamice, potencie sus elementos y características físicas, ambientales y funcionales, y genere sinergias entre todas las colonias que conforman dicho contexto con elementos vinculadores e integradores.



Figura 1. Zona de Estudio. Fuente: elaboración propia con base en Mapa de Colonias, Secretaría de Desarrollo Urbano y Vivienda SEDUVI, CDMX. Imagen de Google Earth, 22 de febrero de 2024.

En el acercamiento a la metodología de Análisis de Escenarios, se visualizó de manera general a los supuestos, en las dinámicas urbanas y transformaciones, que pueden resultar al intervenir el espacio público con una propuesta de proyecto de regeneración. Esto para formar los supuestos que, en su caso, puedan utilizarse en la etapa de desarrollo del proyecto específico para su validación a través de los análisis correspondientes, como pueden ser los escenarios de transformación del entorno inmediato y contexto urbano, aprovechamiento e implementación de infraestructuras, y modificación en los flujos peatonales y vehiculares; ello con la intervención y optimización de las

redes de transporte y el impacto el entorno edificado y ambiental, así como el mejoramiento de los vínculos e interacciones entre las colonias que conforman el contexto urbano en cuestión.

Para este fin y con base en la información del Instituto Nacional de Estadística, Geografía e Informática, INEGI, de los datos abiertos de movilidad y habitabilidad con que cuenta el Gobierno de la Ciudad de México, y con el apoyo del Sistema de Información y Evaluación del Desarrollo Urbano, SIEDU (que tiene como objeto registrar y procesar la información en materia de desarrollo urbano para la toma de decisiones y la definición de políticas públicas), se realizarán y analizarán los siguientes mapas generados con el Sistema de Información Geográfica:

- Movilidad: vialidades primarias y de acceso controlado, medios de transporte público (Metro, Metrobús, Trolebús, RTP) e infraestructura vial ciclista.
- Accesibilidad: intensidad y/o área de influencia por medio de transporte e infraestructura vial ciclista.
- Índice de Habitabilidad del Espacio Público: Dirección de Patrimonio Cultural Urbano y de Espacio Público.
- Equipamientos: determinar las zonas de concentración y atención por equipamientos.
- Densidad de Población: análisis de la concentración y rangos de población. Censo de Población.
- Densidad de Unidades Económicas: determinar el nivel de concentración de unidades económicas en la zona de estudio.
- Empleos Netos: concentración de personas trabajando en las unidades económicas.

Regeneración urbana

Como parte de los mecanismos para alcanzar ciudades sostenibles, ONU Hábitat (2016) promueve la regeneración urbana participativa (RUP) en un proceso incluyente; el principal objetivo de estas intervenciones de regeneración es la reintegración de un área donde se tienen en cuenta diferentes niveles, deficiencias, decadencia o carencias, y se busca mejorar su conectividad tanto en su entorno inmediato, contexto, y resto de la ciudad. La configuración del espacio público, y la red de infraestructura y equipamientos bajo la coherencia de su configuración, buscan garantizar la integración de la zona en estudio para ser regenerada (Roberts y Sykes, 2000).

En un ejercicio interesante, el Ayuntamiento de Madrid, con el apoyo del Programa de Naciones Unidas para los Asentamientos Humanos ONU-Habitat, organizó una Jornada del Grupo de Expertos sobre Regeneración Urbana, con el objetivo de avanzar en la agenda global sobre la cuestión de la regeneración

y mejora de las condiciones de vida en los tejidos urbanos consolidados, con principal interés en que estos procesos sean participativos e incluyentes en sus resultados. Se retoma, de esta jornada, la definición sobre regeneración urbana (Monclús y Díez Medina, 2016).

ONU Hábitat (2016) señala:

“La regeneración urbana ha sido una herramienta fundamental para la transformación y desarrollo de las ciudades de finales del siglo XX. Consiste en la remodelación de áreas urbanas consolidadas en el centro de la ciudad y se utiliza como un mecanismo para invertir un proceso de decadencia económica, demográfica y social a través de una intervención que en muchos casos viene marcada por una fuerte acción pública”.

Los principales elementos de la transformación en la regeneración urbana son los espacios públicos, parques, plazas, vialidades y equipamientos; la regeneración del espacio público permite mejorar la conectividad, los espacios abiertos, la oferta de vivienda, los servicios básicos y la infraestructura, promoviendo la integración y diversificación de diferentes usos urbanos en su contexto; también ha demostrado ser una estrategia efectiva para combatir la delincuencia, el tráfico de drogas y la inseguridad mediante políticas y proyectos que aborden tanto el aspecto social como el urbano, como la Estrategia CPTED², la cual se integra paralelamente en el desarrollo de las propuestas de diseño del espacio público en el proyecto de regeneración urbana (Colantonio y Dixon, 2011; Carmon, 1999). Estos proyectos de regeneración urbana enfrentan retos significativos, pero las oportunidades y los beneficios que ofrecen son clave para promover el desarrollo sostenible con inclusión social, siempre buscando mejorar la calidad de vida y una planificación cuidadosa, lo que garantizará su éxito a largo plazo.

En este contexto, la regeneración urbana se convierte en una herramienta esencial para recuperar los espacios, ayudando a transformar las zonas con distintos niveles de deterioro en entornos funcionales, atractivos y vinculados; contribuye, además, a mejorar la calidad de vida con las intervenciones en los espacios públicos, en infraestructura y servicios; disminuye la desigualdad y favorece el aumento del bienestar de las personas. El fortalecimiento del tejido social, a través de la inclusión e interrelación de las distintas comunidades en el proceso, se da fomentando un sentido de pertenencia y cohesión. Al promover la cohesión social, al mejorar las condiciones de vida, y con el fomento de la inclusión social, se acortan las brechas de las desigualdades

2 La estrategia de Prevención del Delito a través del Diseño Ambiental, CPTED (por sus siglas Crime Prevention Through Environmental Design, 2025), es una de las estrategias más utilizadas para la prevención del crimen (o acciones no favorables) en los espacios públicos, con una filosofía que integra la gestión ambiental para mejorar la calidad de vida y la seguridad natural. Nació en Canadá en la década de 1960 y se utiliza tanto en el ámbito público como privado.

urbanas, propiciando el encuentro social en los espacios públicos y en los espacios de participación ciudadana. También se estimula la economía local, y con la regeneración de las zonas deterioradas o subutilizadas se incrementa la actividad económica, generando oportunidades de empleo, fomentando emprendimientos y atrayendo nuevas inversiones; al mismo tiempo, se mitiga el impacto y deterioro ambiental, introduciendo nuevas soluciones sostenibles, como infraestructuras verdes, movilidad sustentable y eficiencia energética principalmente. La regeneración urbana ayuda a mitigar los efectos del cambio climático y mejora el entorno natural, de la zona a intervenir, y el del resto de la ciudad (Méndez, 2010; Castells, 2000).

A pesar de estos beneficios, los proyectos de regeneración urbana, durante su proceso de implementación, ejecución y/o una vez concluidos, enfrentan diversos desafíos que deben ser considerados desde la concepción de la propuesta del proyecto, con la finalidad de mitigar sus efectos negativos, destacando principalmente la gentrificación, ya que los procesos de mejora en el espacio público y su sinergia pueden desplazar a comunidades vulnerables debido al aumento del costo de vida y de la propiedad; esto se debe, entre otros factores a un financiamiento insuficiente, pues es frecuente que los recursos necesarios para proyectos de regeneración puedan ser limitados, especialmente en países latinoamericanos, por lo que es necesario tomar las consideraciones pertinentes para que los proyectos no queden sin terminar; la falta de participación ciudadana, en estos procesos, y la ausencia del involucramiento de la sociedad, pueden llevar a soluciones que no reflejen las necesidades reales de los habitantes, por lo que es fundamental la difusión y creación de espacios de participación ciudadana. Con la resistencia al cambio, algunos de los proyectos pueden enfrentar oposición debido a intereses políticos, sociales, económicos o culturales; la sostenibilidad, por su parte, debe garantizar que los cambios sean posibles a largo plazo, por lo que se requiere una planificación cuidadosa y enfoques innovadores (Serrano, 2015; De Mattos, 2010).

De igual manera, la regeneración urbana cuenta con numerosas oportunidades que contribuyen a transformar las ciudades de manera positiva, desde el enfoque holístico, donde la integración de los factores sociales, económicos, culturales y ambientales permiten un desarrollo equilibrado y la innovación tecnológica, proponiendo soluciones digitales, como los sistemas inteligentes de gestión urbana, permitiendo una mayor eficiencia en el uso y aprovechamiento de los espacios públicos, y mejorando la calidad de vida de las personas, así como colaboraciones público-privadas, buscando que los proyectos conjuntos entre gobiernos, empresas y comunidades maximicen los recursos y obtengan resultados más satisfactorios. Es necesario considerar también la adaptación, allí donde las zonas pueden enfrentar de manera más resiliente los eventos que se presentan ante el cambio climático (Batty, et al., 2012).

Selección del nodo de regeneración, su contexto y análisis

Una vez determinada la zona de estudio, se realiza un recorrido de campo donde se exploran sus características físicas y funcionales, así como la vinculación con el resto de la ciudad, identificando los espacios en deterioro o con potencial para su aprovechamiento y su función dentro de la estructura urbana. Se estudia si los espacios cumplen o responden a las necesidades actuales, el grado de su deterioro, o si están desaprovechados, con la finalidad de proponer la recuperación, transformación o modificación que ayude a la regeneración urbana de la zona.

En este caso, se detectaron una serie de espacios públicos en la cabecera norte de lo que quedó del Conjunto Urbano Benito Juárez, el cual se identificará como el Nodo de Regeneración, ubicado entre las calles de Antonio M. Anza, Orizaba-Toluca, Jalapa y la cerrada de Campeche, colindando en el extremo suroriente con el Jardín López Velarde como se muestra en la Figura 2.



Figura 2. Nodo de la Regeneración. Fuente: elaboración propia con base en Imagen Google Earth, abril de 2023.

El nodo se analizará como el elemento central que organice, articule y vincule su espacio con el entorno inmediato³ y su contexto⁴, aprovechando su

3 Espacio adyacente a una zona o poligonal urbana, el concepto abarca elementos como banquetas, vialidades, camellones, frentes de manzana o paramentos y predios aledaños con usos o destinos específicos.

4 El contexto urbano es una noción amplia de territorio en torno al elemento estudiado, que engloba las múltiples dimensiones que lo conforman y afectan desde los aspectos físicos y funcionales; en este caso, nos referimos a la zona de estudio.

ubicación estratégica dentro de la estructura urbana; esto aunado a los temas de movilidad, accesibilidad, el índice de habitabilidad del espacio público, los equipamientos, la densidad de población, la densidad de unidades económicas y los empleos netos como criterios que validen la pertinencia de realizar un proyecto puntual de regeneración urbana en el nodo sugerido, que active, conecte y dinamice toda la zona de estudio y facilite su vinculación con el resto de la ciudad.

Movilidad

Para el presente estudio, se analizan los medios de transporte público (Metro, Metrobús, Trolebús, RTP) e infraestructura vial ciclista, con base en los Datos Abiertos de la CDMX, cargados en el SIEDU, Secretaría de Planeación, Ordenamiento Territorial y Coordinación Metropolitana, CDMX (Figura 3).



Figura 3. Movilidad. Fuente: elaboración propia con base en: SIEDU, (s.f.), de la Secretaría de Planeación, Ordenamiento Territorial y Coordinación Metropolitana, CDMX.

Observamos, dentro de la zona de estudio, la amplia cobertura de vialidades de acceso controlado, primarias y secundarias que la estructuran, además de medios de transporte como el Metro, Metrobús, Trolebús y RTP, así como infraestructura ciclista, lo que denota una amplia movilidad que permite los desplazamientos dentro de la zona de estudio a través de los medios de transporte motorizados y no motorizados sobre la infraestructura ciclista (Figura 4).



Figura 4. Accesibilidad. Fuente: elaboración propia con base en: SIEDU, (s.f.), de la Secretaría de Planeación, Ordenamiento Territorial y Coordinación Metropolitana, CDMX.

El nodo cuenta con ubicación estratégica que permitirá, con su propuesta de regeneración, articular y dinamizar los desplazamientos hacia el resto de la zona y fuera de ella, y viceversa. En el tema de movilidad se percibe una factibilidad para su propuesta.

Accesibilidad

Se realizó el cruce entre el mapa de movilidad, con las vialidades de acceso controlado y primarias y la intensidad o área de influencia por medio de transporte e infraestructura vial ciclista. Tomando los Datos Abiertos de la CDMX cargados en el SIEDU (s.f.).

Los distintos medios de transporte, con sus respectivas áreas de influencia, proporcionan una accesibilidad alta al interior de la zona de estudio, principalmente a lo largo del corredor conformado por la Av. de Los Insurgentes y sus principales nodos viales al cruce con la Av. Chapultepec, Eje 2 sur Yucatán, Eje 3 sur Baja California, y Viaducto, seguido del corredor conformado por el Eje 1 poniente Cuauhtémoc, en cada una de las estaciones de Metrobús y Metro Centro Médico. Estos dos corredores estructuran la zona de norte a sur. A lo largo del Eje 2 norte, el Trolebús articula la zona de oriente a poniente, atravesando el centro de la zona de estudio.

El nodo cuenta con una accesibilidad alta por la cobertura del transporte público en la zona.

Índice de habitabilidad del espacio público

Este índice fue desarrollado por la Dirección de Patrimonio Cultural Urbano y de Espacio Público, de la Secretaría de Desarrollo Urbano y Vivienda (SEDUVI, 2022), y se compone de indicadores agrupados en diversas dimensiones que evalúan integralmente la calidad y uso de los espacios públicos y su habitabilidad en la Ciudad de México (Figura 5). Estas dimensiones son⁵:

- Usos y prácticas: evalúa las actividades que se realizan en el espacio público, y cómo estas fomentan la interacción social y el sentido de comunidad.
- Accesibilidad: analiza la facilidad con la que las personas pueden llegar y utilizar el espacio, considerando aspectos como la proximidad y las barreras físicas o sociales.
- Seguridad: considera la percepción y realidad de seguridad en el espacio, incluyendo factores como iluminación, vigilancia y diseño, que prevengan conductas delictivas.

5 Índice de habitabilidad del espacio público de la Ciudad de México. Memoria descriptiva de la metodología. Procedimientos de cálculo, replicación del índice y actualización de las capas de información. 8 de junio del 2022.

- Ambiental: examina la calidad ambiental del espacio, incluyendo elementos como áreas verdes, limpieza y sostenibilidad.
- Identitaria: valora la relevancia cultural e histórica del espacio, y cómo este contribuye a la identidad local y al sentido de pertenencia de la comunidad.



Figura 5. Índice de habitabilidad del espacio público. Fuente: elaboración propia con base en: SIEDU, (s.f.), de la Secretaría de Planeación, Ordenamiento Territorial y Coordinación Metropolitana, CDMX.

Equipamientos

La finalidad fue determinar las zonas de concentración por ubicación y atención de los principales equipamientos según datos de INEGI, 2020 y SIEDU, (s.f.) (Figura 6).




Figura 6. Índice de habitabilidad del espacio público. Fuente: elaboración propia con base en SIEDU, (s.f.), de la Secretaría de Planeación, Ordenamiento Territorial y Coordinación Metropolitana, CDMX.

En la zona de estudio se ubican el Centro Médico Siglo XXI, el Hospital General, el Hospital Infantil y el Hospital General de Zona UMF 26; los Mercados Hidalgo, Medellín, Michoacán y Morelia; los Parques México, España y Lázaro Cárdenas, los Jardines López Velarde, Pushkin, Dr. Ignacio Chávez, y de las Artes Gráficas; las Plazas Río de Janeiro, Luis Cabrera, así como la Fuente de las Cibeles; espacios que atraen a grandes cantidades de personas en distintos horarios. A esto se suma que la estructura vial conecta fuera de la zona de estudio con otros grandes equipamientos, principalmente el Bosque de Chapultepec al norponiente, el Mercado Juárez y la Biblioteca México al norte. El nodo sugiere ser un punto de conexión y vinculación con los equipamientos al interior y exterior de la zona de estudio, aprovechando las vialidades primarias que cuentan con secciones viales amplias y arbolado, permitiendo desplazamientos internos y externos.

Densidad de Población

Identificación de la concentración y rangos de población. Censo de Población, INEGI, 2020. SIEDU, CDMX:

La zona de estudio cuenta con una población de 124,249 hab, de los cuales 64,095 son mujeres y 58,566 son hombres, en una superficie de 857 ha y una densidad de población de 145 hab/ha; se observa mayor densidad al oriente del Eje 1 poniente Cuauhtémoc, en las colonias Obrera y Buenos Aires, una zona de transición al centro, en la parte sur de la colonia Roma Norte y Colonia Roma Sur; y al poniente se localizan las densidades más bajas de población en las colonias Condesa, Hipódromo Condesa y Roma Norte.

El nodo se ubica al centro de la zona central de transición, permitiendo ser el elemento bisagra o integrador entre las zonas oriente y poniente, aprovechando a su vez la concentración de personas que no residen en la zona, pero trabajan, la visitan o la utilizan dentro de sus recorridos y desplazamientos, conectándolas o conduciéndolas a sus lugares de trabajo o a diversas actividades temporales (Figura 7).

Densidad de unidades económicas

Se determina el nivel de concentración de unidades económicas en la zona de estudio. El mapa muestra de manera clara la gran cantidad de unidades económicas por hectárea, principalmente en las colonias Roma Norte, Roma Sur, gran parte de la Hipódromo y Condesa, al poniente en el Eje 1 Cuauhtémoc, y al oriente en las colonias Obrera y Buenos Aires. Se observa la posición del nodo, siendo la “puerta de entrada sur” a la colonia Roma Norte por la calle de Orizaba que, a su cruce con la Av. Álvaro Obregón, conforman el corazón de esta colonia, vinculándose con las Plazas Río de Janeiro y Luis Cabrera, conectándose a la Av. Chapultepec, a media cuadra de la Glorieta de Los Insurgentes. La importancia de la información en la Figura 8 no solamente es la densidad de las unidades

económicas, sino también la movilidad de las personas que trabajan y acuden a esas unidades económicas, su movilidad y las dinámicas que se generan. Allí radica la importancia del nodo por su ubicación, como espacio que inicia vinculaciones hacia el norte por Orizaba y al norponiente por Yucatán.




Figura 7. Densidad de Población 2020. Fuente: elaboración propia con base en: Censo de Población (INEGI, 2020)




Figura 8. Densidad de Unidades Económicas 2021. Fuente: elaboración propia con base en: INEGI (2020).

El mapa muestra de manera clara la gran cantidad de unidades económicas por hectárea, principalmente en las colonias Roma Norte, Roma Sur, gran parte de la Hipódromo y Condesa, al poniente en el Eje 1 Cuauhtémoc, y al oriente de las colonias Obrera y Buenos Aires.

Se observa la posición del nodo, siendo la “puerta de entrada sur” a la colonia Roma Norte por la calle de Orizaba que, a su cruce con la Av. Álvaro Obregón, conforman el corazón de esta colonia, vinculándose con las Plazas Río de Janeiro y Luis Cabrera, conectándose a la Av. Chapultepec a media cuadra de la Glorieta de los Insurgentes.




Figura 9. Empleos Netos 2021. Fuente: elaboración propia con base en: INEGI (2020).

Empleados Netos

Concentración de personas trabajando en las unidades económicas. Este mapa refuerza las dinámicas que se originan por la densidad de unidades económicas, mostrando la cantidad de personas que son empleadas en la zona de estudio y su contexto, siendo importante resaltar que se trata de empleados no residentes, por lo que hay que sumar también a la población flotante que acude a esas unidades económicas, y a las personas que solo visitan la zona o transitan por ella para conectarse con algún otro punto de la ciudad.

El nodo se ubica al centro de la zona de estudio, rodeado de empleados, compradores, personas que demandan servicios, y personas en tránsito por la zona, que requieren trasladarse a otro punto de la ciudad atravesando el lugar. Personas que cobran importancia de la ubicación de nodo, ya que su entorno inmediato y su contexto, zona de estudio y fuera de ella, generan dinámicas urbanas, las cuales pueden ser favorecidas al proponer en esa poligonal del nodo un proyecto de regeneración urbana que las detone, y que produzca lo mismo a su contexto.

Este mapa refuerza las dinámicas que se originan por la densidad de unidades económicas, mostrando la cantidad de personas que son empleadas en la zona de estudio y su contexto, siendo importante resaltar que se trata de empleados, no de residentes, por lo que hay que sumar también a la población flotante que acude a esas unidades económicas, así como las personas que solo visitan la zona o transitan por ella para conectarse con algún otro punto de la ciudad⁶.

Discusión

El reconocimiento de la ciudad, centro de población, asentamiento humano o zona de estudio, es fundamental para el entendimiento de la estructura y dinámicas urbanas; esto, con la finalidad para este caso, de delimitar la zona de estudio a diagnosticar, lo que nos permite la pertinencia de ubicar al interior espacios para proponer un proyecto de regeneración; por ello, es necesario contar con experiencia urbana, la cual deriva de los conocimientos teóricos, pero sobre todo llevar a cabo la implementación práctica, lo que deja un aprendizaje y conocimiento significativo, el cual ayuda a definir de manera más clara los límites según las características observadas, y las condiciones físicas y funcionales del contexto donde se realizará la delimitación.

Al delimitar la zona de estudio y reconocer sus espacios públicos con potencial por su ubicación y condiciones propias, se sugiere un “lugar” definido como “nodo”, el cual ha sido delimitado y localizado al norte del Centro Urbano Benito Juárez, teniendo así la referencia para la realización de los análisis correspondientes, teniendo como resultados:

La Movilidad (Figura 3), que está cubierta por los sistemas de transporte público Metro (Líneas 1, 2, 3, 7, 8 y 9), Metrobús (Líneas 1, 2, 3 y 4), Trolebús (Líneas 1, 2 y 6), RTP, y el sistema de infraestructura ciclista, así como gran cantidad de estaciones del sistema Ecobici.

6 El nodo se ubica al centro de la zona de estudio, rodeado de empleados, compradores, personas que demandan servicios, y personas en tránsito por la zona que requieren trasladarse a otro punto de la ciudad atravesando la zona de estudio, y que cobran importancia de la ubicación del nodo, ya que su entorno inmediato y su contexto, zona de estudio y fuera de ella, generan dinámicas urbanas, las cuales pueden ser favorecidas al proponer, en esa poligonal del nodo, un proyecto de regeneración urbana que las detone, y haga lo mismo a su contexto.

Derivado de la movilidad, y sumando las vialidades de acceso controlado y primarias, así como las áreas de influencia de los distintos sistemas de transporte, se cuenta con una Accesibilidad Alta (Figura 4), principalmente ante el número de sistemas dentro de la zona de estudio, permitiendo la llegada y salida de personas, bien conectadas con el resto de la ciudad.

Referente al Índice de habitabilidad del espacio público (Figura 5), se cuenta con espacios consolidados, como los Parques México y España, los Jardines López Velarde (al suroriente del nodo), las Plazas Popocatepetl, Río de Janeiro, Luis Cabrera, y las glorietas de Los Insurgentes y la Fuente de Las Cibeles; en consolidación, los jardines de Las Artes, Pushkin, Dr. Ignacio Chávez y la Plaza Morelia; por lo que la oferta de estos espacios es muy adecuada para su ocupación y disfrute por parte de los residentes, trabajadores y visitantes.

La zona de estudio cuenta principalmente con Equipamientos (Figura 6) relevantes en el subsistema de Salud: Centro Médico Siglo XXI, Hospital General y Hospital Infantil; en el subsistema de abasto, con dos de los Mercados representativos en la ciudad: Hidalgo y Medellín; en el subsistema de recreación se encuentran los Parques México y España, los jardines López Velarde, Pushkin, Dr. Ignacio Chávez, y de las Artes Gráficas, y las Plazas Río de Janeiro, Luis Cabrera, así como la Fuente de las Cibeles, existiendo equipamientos de menor impacto.

Se observa una Densidad de Población (Figura 7) de 145 hab/ha en la zona de estudio, con tres franjas delimitadas por las vialidades primarias en el sentido norte sur, donde la franja oriente es la de mayor densidad, teniendo al poniente la de menor densidad, y la zona central de transición entre ambas. Es aquí donde se localiza el Nodo de Intervención para la propuesta de Proyecto de Regeneración Urbana.

La Densidad de Unidades Económicas (Figura 8) en su mayoría es alta, mayor a 15 unidades económicas por hectárea, principalmente en la zona central y oriente. Lo que representan estas densidades por unidad económica, es la utilización del suelo mayormente por comercios y servicios que por vivienda o una mezcla, predominando los primeros. Esto hace necesario visualizar el número de empleados por unidad económica.

Al revisar el número de Empleados Netos (Figura 9), se observa que en casi la totalidad del área de estudio hay más de 2,601 empleados o más por hectárea, lo que indica la dinámica que vive la zona al recibir diariamente 18 veces más personas de las que actualmente residen allí. La dinámica urbana principal es la movilidad de personas para satisfacer sus necesidades comerciales, de servicios y equipamientos de salud, principalmente, por lo que se deben crear las mejores condiciones para recibir, mover y proporcionar espacios dinámicos, legibles y de estancia temporal durante su ocupación, ya sea por trabajo, visita o residencia (ya que todos suman a la cifra total de personas al día que “viven” en la zona).

Conclusiones

La zona sur de la Alcaldía Cuauhtémoc es dinámica y concentradora de actividades comerciales, de servicios y equipamientos especializados en Salud, con espacios de recreación y colindante con el mayor parque urbano de la ciudad, del país y Latinoamérica: el Bosque de Chapultepec, cuya ubicación, cercanía y estructura urbana de la zona de estudio, hace factible su rápida conexión con el resto de la zona de estudio y el poniente de la Ciudad de México, gracias a la infraestructura vial y ciclista, así como de los medios de transporte y la permeabilidad de su traza urbana.

La ubicación del Nodo de Regeneración (Figura 10), es ideal para funcionar como un “elemento de vinculación” con su entorno inmediato, el contexto y con el resto de la ciudad, vinculándose de manera clara y directa a la estructura urbana en las líneas azul claro observadas en el mapa, en un patrón organizado por el eje norte-sur por la Av. Orizaba, y su continuación Toluca, que en su cruce con la Av. Álvaro Obregón estructura la zona de estudio en la parte norte; de oriente a poniente por la Av. Yucatán y Antonio M. Anza, así como las calles de Coahuila y Campeche, de manera directa desde este nodo y de manera suplementaria con todo el poniente de la zona de estudio, complementado a las vialidades primarias, Dr. José Ma. Vértiz, Eje 1 Poniente Cuauhtémoc, las Avenidas Monterrey, Medellín y Los Insurgentes, principalmente de norte a sur.

Este análisis brinda un acercamiento a la zona sur de la Alcaldía Cuauhtémoc, en específico del nodo propuesto, donde se puede formular un proyecto de regeneración que impacte positivamente en su entorno inmediato, en su contexto y en el resto de la ciudad, y que ayude principalmente a vincular dos grandes zonas con características diferentes, desde el Eje 1 Poniente Cuauhtémoc hacia el oriente, con las colonias Doctores y Buenos Aires; y al poniente, con las colonias Roma Norte, Roma Sur, Centro Urbano Benito Juárez, Condesa, Hipódromo e Hipódromo Condesa. Además de la infraestructura vial que forma parte de la estructura urbana, los parques, jardines y plazas complementan dicha estructura, junto con la cercanía del Bosque de Chapultepec, para consolidar y generar circuitos aprovechando estas áreas verdes reconocidas e importantes dentro de la zona de estudio.

Se espera que la propuesta del Proyecto de Regeneración se centre en la movilidad de los residentes, empleados y visitantes al entrar y salir de la zona de estudio, y en su vinculación con el resto de la ciudad, principalmente creando espacios caminables, con una habitabilidad adecuada que propicie recorridos donde las personas puedan realizar sus desplazamientos con buenas condiciones físicas y ambientales, brindando espacios de encuentro que promuevan la cohesión social y el esparcimiento, y donde la conexión del nodo de regeneración con su entorno inmediato facilite su conexión y vinculación con el contexto y resto de la ciudad.




Figura 10. Potencial Nodo de Regeneración. Fuente: elaboración propia con base en: SIEDU (s.f.).

Referencias

- Batty, M., Axhausen, K., Giannotti, F., Pozdnoukhov, A., Bazzani, A., Wachowicz, M., ... y Portugali, Y. (2012). Smart cities of the future. *The European Physical Journal Special Topics*, 214(1), 481–518. <https://doi.org/10.1140/epjst/e2012-01703-3>
- Carmon, N. (1999). Three generations of urban renewal policies: *Analysis and policy implications*. *Geoforum*, 30(2), 145–158. [https://doi.org/10.1016/S0016-7185\(99\)00012-3](https://doi.org/10.1016/S0016-7185(99)00012-3)
- Castells, M. (2000). *The rise of the network society* (2nd ed.). Blackwell.

- Colantonio, A., y Dixon, T. (2011). *Urban regeneration and social sustainability: Best practice from European cities*. Wiley-Blackwell.
- CRIME PREVENTION THROUGH ENVIRONMENTAL DESIGN. (2025). CPTED International Association. <https://cpted.net/>
- De Mattos, C. A. (2010). Globalización, transformación urbana y políticas públicas en América Latina. *EURE*, 36(109), 27–40. <https://doi.org/10.4067/S0250-71612010000100002>
- Instituto Nacional de Estadística y Geografía (INEGI). (2020). *Directorio Estadístico Nacional de Unidades Económicas (DENUE)*. <https://www.inegi.org.mx/app/mapa/denue/>
- Instituto Nacional de Estadística y Geografía (INEGI). (2020). *Censo de Población y Vivienda 2020: Resultados definitivos*. <https://www.inegi.org.mx/programas/ccpv/2020/>
- Méndez, R. (2010). *La regeneración urbana: viejos problemas y nuevas perspectivas*. Madrid: Fundación Alternativas.
- Monclús, J., y Díez Medina, C. (2016). Urban regeneration and public space: The Barcelona model. *Urban Geography*, 37(8), 1163–1182. <https://doi.org/10.1080/02723638.2016.1139869>
- ONU-Hábitat. (2016). Jornadas de trabajo sobre regeneración urbana. Ayuntamiento de Madrid, Área de Gobierno de Desarrollo Urbano Sostenible.
- Roberts, P., y Sykes, H. (2000). *Urban regeneration: A handbook*. SAGE.
- Secretaría de Planeación, Ordenamiento Territorial y Coordinación Metropolitana. (s. f.). *Sistema de Información y Evaluación del Desarrollo Urbano (SIEDU)*. Gobierno de la Ciudad de México. <https://siedu.cdmx.gob.mx>
- Secretaría de Desarrollo Urbano y Vivienda (SEDUVI). (2022, 8 de junio). *Índice de habitabilidad del espacio público de la Ciudad de México*. Sistema de Información y Evaluación del Desarrollo Urbano (SIEDU). <https://siedu.cdmx.gob.mx>
- Serrano, J. A. (2015). Regeneración urbana y políticas públicas: reflexiones desde América Latina. *Revista INVI*, 30(85), 101–128. <https://doi.org/10.4067/S0718-83582015000300005>

03

Línea temática

Transformaciones
ambientales
urbanas y tecnologías
geoespaciales
para el análisis
territorial

Capítulo XII. Geografías del impacto urbano en el Bosque de Agua. Diagnóstico territorial basado en SIG y Teledetección

Cristy Monserratt Sánchez Ramos¹

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),

Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

El objetivo de este apartado es el análisis de las relaciones espaciales entre el estado de la cobertura vegetal y el grado de superficies antropogénicas en la región central de México, específicamente en el Bosque de Agua. Este trabajo es de tipo cuantitativo, y se realiza mediante el uso de los SIG y la teledetección; se centró en la implementación de los índices espectrales de EVI, BSI y NDBI en imágenes Sentinel-2 del año 2024, además de la interacción entre la plataforma de Google Earth Engine (GEE) y el software de QGIS. Los hallazgos más relevantes demuestran la existencia de un núcleo forestal, conservado con una clara disminución del arbolado hacia la periferia de este territorio, evidenciando procesos de fragmentación ecológica y expansión urbana. Los resultados sugieren enfocar esta problemática hacia una reevaluación de las políticas urbanas-ambientales presentes en este territorio, y evidenciar las geografías de la desigualdad que provocan tales condiciones.

Palabras clave: análisis espacial, urbano, cobertura vegetal, socioambiental.

Abstract

The objective of this section was the analysis of the spatial relationships between the state of vegetation cover and the degree of anthropogenic surfaces in the central region of Mexico, specifically in the Bosque de Agua. This work is of quantitative type, through the use of GIS and remote sensing, focused on the implementation of EVI, BSI and NDBI spectral indices in Sentinel-2 images of the year 2024, in addition to the interaction between the Google Earth Engine (GEE) platform and QGIS software. The most relevant findings show the existence of a preserved forest core with a clear decrease of trees towards the periphery of this territory, evidencing processes of ecological fragmentation and urban expansion. The results suggest focusing this problem towards a re-evaluation of the urban-environmental policies present in this territory and highlighting the geography of inequality that causes such conditions.

Palabras clave: espacio público, regeneración urbana, proyecto urbano.

Introducción

Desde mediados del siglo XX, el crecimiento de las áreas urbanas se ha intensificado, ampliando la extensión de las ciudades y, al mismo tiempo,

1 Maestra y Doctorante en Ciencias en Arquitectura y Urbanismo, Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura, ESIA, Unidad Tecamachalco Correo: rgomezma@ipn.mx, ORCID: <https://orcid.org/0000-0002-9571-5126>

transformando sus periferias a través de nuevos patrones de ocupación del suelo. Sin embargo, estos cambios en el territorio se ven reflejados más allá de los perímetros urbanos y se extienden más lejos de las zonas rurales. Las transformaciones del suelo se hacen más evidentes en hábitats naturales, donde sus sistemas ecológicos son impactados, cada vez más, por la urbanización (ONU, 2019; CEPAL, 2020; SEMARNAT, 2017).

Desde el 2007, más del 50% de la población reside en áreas urbanas a nivel mundial y las proyecciones indican que este fenómeno aumentará para los siguientes años. Reflexionar sobre el proceso de urbanización y sus efectos es primordial, dado el contexto actual de crisis ambiental en el que nos encontramos, debido a que son precisamente las áreas urbanas las responsables de consumir alrededor del 60% de los diversos recursos naturales en el planeta (ONU, 2019).

Hoy en día, América Latina y el Caribe es la región más urbanizada del mundo, y al mismo tiempo posee una desigualdad endémica que se acrecienta, por lo que supone un caso aún más alarmante (CEPAL, 2020). Tan solo en México, desde el año 2020 el 79% de la población vive en alguna zona urbana (INEGI, 2020) y su tasa anual de deforestación promedio fue de 208,850 ha durante el periodo de 2001-2021 (CONAFOR, 2022).

De esta manera, el crecimiento poblacional y la expansión urbana se han visto reflejados en transformaciones en el territorio mexicano, específicamente en áreas que albergan sistemas ecológicos. A nivel nacional, a principios de los años 2000 se perdió una gran cantidad de zonas de vegetación natural, a una velocidad de 248,000 ha por año. Posteriormente, entre 2011 y 2014 se pasó a una pérdida de 138,000 ha por año (SEMARNAT, 2017).

Diferentes trabajos (Müller, et al., 2013; Bazant, 2011; Bekele, et al., 2025) han consignado diferentes efectos del crecimiento urbano en procesos como: la deforestación, la fragmentación del territorio, los incendios forestales, las plagas, las enfermedades, la creciente demanda de recursos naturales, el desplazamiento de comunidades, entre otros. Tales efectos interconectados logran agravar los impactos negativos socioambientales.

Desde años atrás, se vuelve evidente que los procesos urbanos han generado profundas transformaciones espaciales socioambientales, que se han caracterizado por un patrón recurrente de degradación ecológica y brechas socioeconómicas más desiguales (O'Connor, 2003). Este fenómeno desencadena una serie de impactos interconectados que agudizan la crisis ambiental. Desde la visión de Casal y López (2021, como se cita en Pino, 2024), los conflictos socioambientales toman un papel fundamental, dado que son al mismo tiempo disputas territoriales donde los recursos naturales (suelos, agua, bosque, etc.) son entidades geográficamente situadas, es decir, son determinadas por su ubicación y su contexto en el mundo.

En tal sentido, el objetivo de este trabajo fue el análisis de las relaciones espaciales del estado de la cobertura vegetal (CV) frente al grado de superficies antropogénicas. El área de estudio se enfoca en la región central de México, específicamente en el Bosque de Agua. La metodología propuesta es de tipo cuantitativo y, tomando en cuenta el objetivo, se centra en la implementación de tres índices, los cuales son: Índice de Vegetación Mejorado (EVI), el Índice de Diferencia Normalizada Construida o también conocida como el Índice de Diferencia Normalizada Edificada (NDBI), y el Índice de suelo Desnudo (BSI).

Análisis espacial del impacto urbano en el bosque

El análisis medioambiental mediante los SIG retoma el marco metodológico de la geografía cuantitativa, la cual es sustentada en un enfoque lógico-matemático y deductivo que permite modelizar sistemáticamente los procesos en el espacio (Poveda Sotelo, et al., 2022). Así, el avance de la tecnología en torno a la teledetección ha llevado a la innovación de las formas y capacidades para monitorear procesos ecosistémicos (Figura 1). Este contexto ha permitido superar algunas limitaciones de los enfoques tradicionales (Cabello, et al., 2012).




Figura 1. Comportamiento espectral diferencial de acuerdo a la condición de las hojas.

Fuente: Dražić, et al. (2021).

Desde los métodos remotos existen diversos indicadores para la evaluación y caracterización de la vegetación, resultado del procesamiento de imágenes satelitales. Los índices de vegetación (IV) se basan en el principio de

la reflectancia diferencial de las hojas en las diferentes bandas espectrales, lo que permite mejorar la identificación de la calidad de la vegetación (Figura 1). Usualmente, para las dos bandas básicas dentro de las diferentes fórmulas matemáticas de los IV se utiliza la longitud de onda roja ($0,6\text{--}0,7\text{ }\mu\text{m}$), por la sensibilidad a los pigmentos fotosintéticos; y el infrarrojo cercano ($0,7\text{--}1,1\text{ }\mu\text{m}$), ya que proyecta alta reflectancia debido a la estructura de las hojas (Huete, et al., 2002; Trancoso, 2013).

El presente trabajo adoptó un enfoque cuantitativo, no experimental de tipo transversal (Hernández, 2014), centrado en el análisis espacial mediante la descripción y comparación de índices ambientales. La obtención de datos se realizó a través de fundaciones, catálogo de imágenes de Google Earth Engine (GEE) y portales gubernamentales, con la interacción del software de QGIS como Sistema de Información Geográfica (SIG).

Este enfoque permitió analizar el estado del área de interés en 2024, e identificar las áreas con mayor impacto negativo. El proceso metodológico se estructuró en dos fases secuenciales: la primera fue la construcción de una imagen satelital base, que abarcara toda el área estudiada. Dada su escala regional se optó por la plataforma Google Earth Engine.

En la segunda fase se utilizó el dato base, obtenido en la primera etapa, en el programa de QGIS. Se analizó el caso de estudio a partir de tres índices esenciales para el objetivo de este trabajo. El índice de Vegetación Mejorado (EVI), el Índice de Diferencia Normalizada Construida o también conocida como el Índice de Diferencia Normalizada Edificada (NDBI), y el Índice de Suelo desnudo (BSI). Estos indicadores permitieron la comparación entre el área de cobertura vegetal y el grado de áreas construidas en esta área.

Área de estudio

El área de estudio se ubica en la región central de México, en el territorio conocido como Bosque de Agua, zona estratégica para la provisión de servicios ambientales, especialmente hídricos, que comprende un área de 255,000 ha (FUNBA, 2011). Administrativamente, esta área trasciende los límites estatales, abarcando parte de tres estados, los cuales son: Estado de México, Ciudad de México y Morelos.

Primera fase del proceso

Inicialmente, se optó por determinar el área de estudio, utilizando el polígono propuesto por la Fundación Biónsfera del Anáhuac, A.C. (FUNBA, 2011). Este dato que contenía el polígono, se descargó en formato *KML*; posteriormente, se pasó al formato *shape* para su manipulación y referencia para los procesos siguientes. Después, se cargó este dato dentro de la plataforma de GEE desde el apartado de *Assets*, en sus extensiones de *dbf*, *prj*, *shp* y *shx* (ver Figura 2).




Figura 2. Proceso de la obtención del polígono del área de interés. Fuente: elaboración propia, sobre la plataforma de Google maps.

GEE constituye una plataforma para el análisis geoespacial, un servidor innovador de computación en la nube, diseñada para el procesamiento a gran escala de imágenes satelitales y de un conjunto de datos geoespaciales. Se ha convertido en una herramienta significativa dentro de las investigaciones geoespaciales cuantitativas, a través de los estudios de sistemas terrestres a múltiples escalas, y a partir de programación de *JavaScript* y *Python* (GEE, s.f.).

Dadas las características de GEE, se optó por generar un código en esta plataforma, donde el flujo de trabajo se centró en el procesamiento de imágenes Sentinel-2. Tales imágenes son tomadas del catálogo de GEE, y se remiten a la base de datos desarrollada por la Agencia Espacial Europea (ESA) como parte del programa de Copernicus. Las imágenes Sentinel-2 son un conjunto de imágenes multispectrales de alta resolución, amplia franja de cobertura y una resolución temporal de 5 días. Además, su instrumento multispectral (MSI) S2 muestra 13 bandas espectrales (GEE, s.f.). Para la obtención de una imagen conformada solo por el área de interés, el código consta de seis partes fundamentales:

- Primeramente, se llama al archivo que contiene la geometría correspondiente a la zona de interés (BA1). Por lo que esta capa funciona como elemento delimitador espacial a todos los procesos subsecuentes.
- Posteriormente, se lleva a cabo una selección y filtrado de datos de la colección de Sentinel-2, espacialmente a partir del polígono del área de estudio y, temporalmente, del mes de marzo del 2024. Hasta este punto, se obtuvieron 522 imágenes tipo ráster.
- A continuación, se realiza una evaluación de condiciones atmosféricas, específicamente con el porcentaje de nubes. Por lo que se implementa la función de Scene Classification Layer (SCL), que calcula el porcentaje de

cobertura nubosa, identificando los píxeles correspondientes a nubes con valores de 3 a 9, además de calcular el porcentaje medio solo dentro del área de estudio, depurando las imágenes con más del 10% de nubosidad.

- La cuarta parte del código se calculó a través de la media de los valores en cada uno de los píxeles, técnica que mitiga la presencia de valores atípicos o inconsistentes.
- Después, las líneas de código unifican la resolución espacial, es decir, las bandas se procesan diferencialmente según su resolución nativa, obteniendo una coherencia espacial en el área de estudio.
- Finalmente, el conjunto de bandas es integrado en una sola imagen multibanda. Así, el resultado es una imagen con información espectral en múltiples longitudes de onda, ajustada espacialmente al área de interés. La exportación incluye parámetros de resolución de 10 metros por píxel, y conserva la extensión de la geometría del bosque (BA1) y el formato de TIFF (Tagged Image File Format). Tal formato permite su manejo en sistemas de información geográfica (SIG), como QGIS o ArGIS, para los procesos posteriores (Figura 3).




Figura 3. Código conformado de seis partes fundamentales para la obtención de la imagen multibanda. Fuente: elaboración propia, sobre la plataforma de GEE.

Segunda fase del proceso

Inicialmente para esta fase, se retoma la imagen multibanda ajustada espacialmente al área de interés en la plataforma de QGIS, para la exploración del ráster. La indagación se llevó a cabo a través de las diferentes combinaciones de las bandas (Tabla 1), para la identificación visual de las principales características que componen a este territorio (Figura 4).

Tabla 1. Composiciones de bandas y sus aplicaciones de análisis territorial.

Composiciones RGB	Aplicaciones de análisis territorial en Sentinel-2
Color natural	4, 3, 2
Zonas urbanas	12, 11, 4
Vegetación general	8, 4, 3
Análisis de vegetación	11, 8A, 4
Vegetación sana	8A, 11, 2
Uso de suelo	8A, 11, 4

Fuente: elaboración propia con base en Composiciones RGB de imágenes satelitales. Metellanes, 2019.




Figura 4. Exploración de la imagen multibanda. Fuente: elaboración propia, sobre el sistema de QGIS.

La información visualizada se obtuvo de la plataforma de GEE, en la fase anterior. Dada la escala del área de estudio, la descarga se realizó en cuatro archivos *TIF*. Por lo que el siguiente paso fue realizar una combinación de estos cuatro elementos mediante la herramienta *Combinar*, que se encuentra por medio de la secuencia de pestañas *Ráster-Miscelánea-Combinar*. Lo que llevó a un nuevo cuadro de opciones, donde se seleccionaron los cuatro formatos *TIF*, y subsecuentemente se pasó a la acción *Ejecutar*, lo que derivó en una sola imagen multibanda (Figura 5).




Figura 5. Combinación de los cuatro archivos en formato tif del área de estudio sobre el sistema de QGIS, mediante la herramienta de Combinar. Fuente: elaboración propia, 2025.

Posteriormente, la imagen se delimitó al polígono del bosque (*Shape BA1*) a través de la herramienta de *Cortar ráster por capa de máscara*, que se localiza siguiendo la secuencia de pestañas *Ráster-Extracción-Cortar ráster por capa de máscara*, donde la *capa de entrada* fue la imagen multibanda, que es la combinación de los cuatro elementos *TIF*; y la *capa de máscara* fue el *Shapefile*

nombrado BA1, que contiene el polígono georreferenciado del área de interés. De esta manera, se obtuvo la imagen multibanda únicamente del polígono del Bosque, que sirvió de base para la obtención de los índices seleccionados para este estudio (Figura 6).




Figura 6. Delimitación de la imagen multibanda al polígono del bosque sobre el sistema de QGIS, mediante la herramienta de Cortar ráster por capa de máscara. Fuente: elaboración propia, 2025.

El primer elemento obtenido para el análisis espacial fue EVI (por sus siglas en inglés *Enhanced Vegetation Index*). Este representa un indicador espectral utilizado para evaluar el estado de la vegetación en zonas con alta densidad de biomasa. El EVI integra correcciones atmosféricas mediante la inclusión de la banda azul del espectro electromagnético, además de corregir los ruidos atmosféricos y del suelo, por lo que es particularmente efectivo en regiones

donde exista una elevada carga de aerosoles, o en condiciones de alta humedad atmosférica. Los valores del Índice de Vegetación Mejorado teóricamente oscilan entre -1 y 1, y dentro de esta escala la vegetación saludable se concentra en el intervalo de 0.2 a 0.8 (Kuri, 2023; Leonardo, 2021). La fórmula del EVI integra tres factores espectrales clave, y es la siguiente:

$$EVI = G \times \frac{(NIR - RED)}{(NIR + C1 \times RED - C2 \times BLUE + L)}$$

Donde:

$G = 2.5$ (Factor de ganancia)

$C1 = 6$ (Corrección para la banda roja)

$C2 = 7.5$ (Corrección para la banda azul)

$L = 1$ (Factor de ajuste del suelo)

$NIR = B8$ (Infrarrojo cercano)

$RED = B4$ (Rojo)

$BLUE = B2$ (Azul)

En segundo lugar, el BSI (por sus siglas en inglés Bara Soil Index) fue diseñado para identificar zonas con suelo desnudo. Este indicador espectral hace uso de las diferencias de las firmas espectrales entre áreas con cubierta vegetal, y suelos donde la vegetación es escasa o no existe y el suelo está expuesto. El Índice de Suelo Desnudo expresa valores de -1 a 1, donde los valores que son mayores a cero pertenecen a suelo desnudo; los valores menores a cero reflejan zonas con cobertura general, es decir, en su estado natural o cultivada; y los valores que resulten cero indican áreas de transformación o mezcla espectral (Leonardo, 2021). La fórmula utilizada para este índice es:

$$BSI = \frac{(SWIR + RED) - (NIR + BLUE)}{(SWIR + RED) + (NIR + BLUE)}$$

Donde:

$SWIR = B11$ (Infrarrojo de onda corta)

$NIR = B8$ (Infrarrojo cercano)

$RED = B4$ (Rojo)

$BLUE = B2$ (Azul)

El tercer indicador fue NDBI (por sus siglas en inglés Normalized Difference Built-up Index). Este es un indicador espectral que se estructura con el propósito de la detección de áreas con superficies edificadas, o en proceso de construcción frente a los suelos naturales, vegetación, cuerpos de agua y suelos desnudos. Es especialmente utilizado para la comparación del crecimiento de las ciudades. El Índice de Diferencia Normalizada Edificada expresa sus valores de -1 a 1. De este modo, los números negativos corresponden a áreas naturales, y los

números positivos más próximos a 1 corresponden a áreas construidas (Zha, et al., 2003). La formulación matemática de este indicador es:

$$NDBI = \frac{(SWIR - NIR)}{(SWIR + NIR)}$$

Donde:

SWIR = B11 (Infrarrojo de onda corta)

NIR = B8 (Infrarrojo cercano)

Basado en esta información, dentro de QGIS se aplicaron las tres fórmulas a la imagen multibanda. Para el primer indicador se recurrió a la secuencia de herramientas de *Ráster-Calculadora ráster*. Como paso siguiente, dentro de la ventana emergente se introdujo la primera fórmula, lo que derivó en una nueva capa en formato *tif*. A dicha capa se le configuraron los parámetros de visualización y su simbología (Figura 7). Se realizó la misma secuencia de procesos para la obtención de los siguientes indicadores y sus respectivas fórmulas. Tras los procesos anteriores, se obtuvo la representación gráfica de los tres índices, EVI, NDBI y BSI.




Figura 7. Implementación de las fórmulas de los tres índices (EVI, NDBI y BSI) sobre el sistema de QGIS, mediante la herramienta de Calculadora ráster. Fuente: elaboración propia, 2025.

Finalmente, al concluir estas fases metodológicas se obtuvo la situación del estado del bosque del mes de marzo de 2024, a través de los tres índices (EVI, NDBI y BSI) dentro del territorio. Todo ello permitió el objetivo principal de este trabajo, que es la comparación de la situación de la cobertura vegetal ante las zonas con los niveles más altos de asentamientos humanos, a partir de identificar áreas construidas.

Resultados

El mapa resultante de la distribución del EVI (Figura 8) refleja una gradiente de valores que van del -0.96 al 0.96 en este territorio, permitiendo identificar diferentes magnitudes de salud y cobertura vegetal. Los valores más altos, es decir, mayores a 0.2 (tonos verdes oscuros) se concentran predominantemente en el núcleo del bosque, que indican coberturas vegetales densas y continuas, además de una gran capacidad fotosintética. Tales características son propias de ecosistemas forestales bien conservados.

Adicionalmente, el gradiente de valores de EVI evidencia una disminución progresiva a partir del núcleo del bosque hacia la periferia del polígono, zonas que son al mismo tiempo las áreas más próximas a las zonas metropolitanas. Así, el área de mayor arbolado contrasta con las áreas de asentamientos humanos (urbanas y rurales) dentro del polígono, donde los valores descienden del 0.2 al último valor negativo. En esta transición progresiva coexisten parches de vegetación secundaria, sistemas agropecuarios, zonas de pastizales, entre otros usos, hasta llegar a las concentraciones humanas. En el mapa se puede identificar esta transición en las tonalidades que van de verdes claros a amarillos (Figura 8).

El análisis del mapa de BSI, expuesto en la Figura 9, expone una variabilidad espacial con valores que oscilan entre 0.81 a -0.58. Las zonas con alta exposición al suelo son los valores con signo positivo (en la Figura 9 se visualizan con tonalidades de amarillos). Estos niveles se presentan con mayor frecuencia en el área sur de este territorio, y con menor cantidad del lado este del territorio, adyacente al área urbana de la CDMX. Por el contrario, del lado norte es donde se tienen principalmente valores negativos, esto indica mayores coberturas en su estado natural o cultivado (Figura 9).

En la Figura 10 se muestra la distribución de los niveles del NDBI, donde el rango es de 0.86 a -0.65. Las zonas con niveles más cercanos a uno se sitúan de forma mayoritaria en el sur del bosque, y las podemos visualizar en colores rojizos. Este rango de coloraciones representa grados con mayores superficies construidas, las cuales podemos ubicar en el centro de las tres principales metrópolis que rodean este territorio. En cambio, en el norte de este bosque sobresalen colores verdosos que representan áreas naturales conservadas; sin embargo, a pesar de su marcada preponderancia de paisajes naturales, también coexisten varios parches de áreas con construcciones (manchas en rojo).




Figura 8. Resultado del índice EVI 2024. Fuente: elaboración propia, con la utilización de GEE y QGIS.




Figura 9. Resultado del índice BSI 2024. Fuente: elaboración propia, con la utilización de GEE y QGIS.




Figura 10. Resultado del índice NDBI 2024. Fuente: elaboración propia, con la utilización de GEE y QGIS.

Discusión y conclusiones

El presente capítulo permitió caracterizar el Bosque de agua a través de la aplicación de los índices espectrales de EVI, BSI y NDBI. Tales elementos revelan patrones espaciales complementarios que permitieron comprender el proceso de transformación del caso de estudio y su relación con las zonas aledañas. Los hallazgos demuestran un núcleo forestal conservado, con una clara disminución del arbolado hacia la periferia de este territorio, evidenciando procesos de fragmentación ecológica y expansión urbana. Resulta evidente que el factor humano es determinante en la densidad y calidad de entornos ecológicos.

EVI reflejó que la mayor densidad de bosque se encuentra en su núcleo, a una distancia más lejana con respecto a los núcleos urbanos de mayor extensión. Sin embargo, con la aplicación de los índices espectrales de BSI y NDBI se identificó que este núcleo no es homogéneo. Al menos para marzo de 2024, en el sur de este territorio se presentaba una marcada presencia de suelo desnudo, y un grado más alto de áreas con construcciones (mayor presencia de valores positivos de BSI y NDBI). Este patrón refleja procesos de sustitución de cobertura vegetal por usos antrópicos como agricultura, urbanización o nuevas redes viales.

El análisis a partir de estos datos evidenció cómo este territorio sufre una presión creciente en los bordes de este ecosistema, donde la vegetación se fragmenta (EVI medio o bajo) y el suelo se expone (BSI alto), terminando en áreas de asentamientos humanos. Ello habla de afectaciones graves, ya que cuando el cambio de cobertura termina en urbanización, las afectaciones persisten por mucho tiempo, y en la gran mayoría de los escenarios son irreversibles.

Dado el enfoque seleccionado, a través del uso de datos de SIG y teledetección, los resultados obtenidos proporcionaron información relevante sobre el patrón espacial de este territorio, que es prioritario para la conservación en México, donde resaltan las diferencias geográficas de una vegetación sana y saludable, y una creciente urbanización.

Finalmente, es importante señalar que contar con estudios sobre evaluaciones de variables ambientales, como lo es la gestión y protección de los recursos forestales, es esencial ante la crisis ambiental que enfrentamos. En tal sentido, este tipo de estudios permite identificar posibles desafíos territoriales en el ámbito ambiental, así como el grado de incidencia de las urbes, además de enfocar esta problemática hacia una revaluación de las políticas urbanas-ambientales presentes en este territorio, y evidenciar la geografía de la desigualdad que provocan tales condiciones.

Referencias

Bazant, J. (2011). Interdependencia de la expansión urbana y el medio ambiente circundante. *Cuadernos de vivienda y urbanismo*, 4(8), 198–223.

- Bekele, B., Wei, W., Tsegaye, L., Tilahun, M., Girma, T., y Ketema, H. (2025). Urban expansion-induced land use land cover changes and the subsequent changes in ecosystem service and land surface temperature in the central highland of Ethiopia. *Environmental and Sustainability Indicators*, 26, 100626. <https://doi.org/10.1016/j.indic.2025.100626>
- Cabello, J., Alcaraz Segura, D., y Lourenço, P. (2012). Funcionamiento de los ecosistemas de la Red de Parques Nacionales de España: detección de impactos recientes y desarrollo de un sistema de seguimiento y alerta a partir de herramientas de teledetección. In *Proyectos de investigación en parques nacionales: 2008-2011* (pp. 45–69).
- Comisión Económica para América Latina y el Caribe. (2020). *La tragedia ambiental de América Latina y el Caribe* (1st ed.). United Nations.
- Comisión Nacional Forestal. (2022, December 30). Gobierno de México. Retrieved 2015, from [https://www.gob.mx/conafor/prensa/se-reduce-en-26-la-tasa-anual-de-deforestacion#:~:text=Con%20base%20a%20la%20metodolog%C3%ADa,\(66.65%20millones%20de%20hect%C3%A1reas\)](https://www.gob.mx/conafor/prensa/se-reduce-en-26-la-tasa-anual-de-deforestacion#:~:text=Con%20base%20a%20la%20metodolog%C3%ADa,(66.65%20millones%20de%20hect%C3%A1reas)).
- Dražić, N., Ikanović, J., y Dražić, G. (2021). Smart Sensor Monitoring in Energy Crop Biomass Production. SINTEZA 2021. <https://doi.org/10.15308/Sinteza-2021-102-106>
- Fundación Biósfera del Anáhuac. (2011). FUNBA. Retrieved February 1, 2025, from <https://funba.org/>
- Google Earth Engine. (n.d.). Platform. Earth Engine. Retrieved April 2, 2025, from <https://earthengine.google.com/platform/>
- Hernández, R. S. (2014). *Metodología de la investigación* (6th ed.). McGraw-Hill Interamericana de España S.L.
- Huete, A., Didan, K., Miura, T., Rodriguez, E., Gao, X., y Ferreira, L. (2002). Overview of the radiometric and biophysical performance of the modis vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195–213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Instituto Nacional de Geografía y Estadística. (2020). Censo de Población y Vivienda 2020 (2020) [Data set]. Subsistema de Información Demográfica y Social. <https://www.inegi.org.mx/programas/ccpv/2020/>
- Kuri, J. (2023, May 19). Índices de vegetación. Geospectral. Retrieved February 4, 2025, from <https://geospectral.com.mx/blogs/agras-1/indices-de-vegetacion?srsId=AfmBOookvVRqcksc07jTx04A215EFebVgDVyNVUS8DHA9TcmYRb8vHE>
- Leonardo, F. (2021, January 11). Lista de índices espectrales en Sentinel 2 y Landsat. Retrieved February 4, 2025, from <https://acolita.com/lista-de-indices-espectrales-en-sentinel-2-y-landsat/>
- Matellanes, R. (2019, August 19). Composiciones RGB de imágenes satélite. Geo innova. Retrieved April 2, 2025, from <https://geoinnova.org/blog-territorio/composiciones-rgb-de-imagenes-satelite/>

- Müller, N., Ignatieva, M., Nilon, C. H., Werner, P., y Zipperer, W. C. (2013). Patterns and trends in urban biodiversity and landscape design. In *Urbanization, biodiversity and ecosystem services: Challenges and opportunities* (pp. 123–174). Springer Netherlands. https://doi.org/10.1007/978-94-007-7088-1_10
- O'Connor, J. (2003). Desarrollo desigual y combinado y crisis ecológica. *Ambiente & Sociedade*, 6(2), 9–23. <https://doi.org/10.1590/s1414-753x2003000300002>
- Organización de las Naciones Unidas. (2019). Informe de los Objetivos de Desarrollo Sostenible 2019 (Departamento de Asuntos Económicos y Sociales (DESA), e-ISBN: 978-92-1-047889-2, ISSN: 2521-6899, e-ISSN: 2521-6902) [Informe]. Lois Jensen. https://unstats.un.org/sdgs/report/2019/The-Sustainable-Development-Goals-Report-2019_Spanish.pdf
- Pino Hidalgo, R. (2024). Los pueblos originarios en la Ciudad de México: Una multiplicidad de injusticias sociales, espaciales y ambientales. *Scripta Nova. Revista Electrónica de Geografía y Ciencias Sociales*, 28(2). <https://doi.org/10.1344/sn2024.28.42123>
- Poveda Sotelo, Y., Bermúdez Cella, M. A., y Gil Leguizamón, P. (2022). Evaluación de métodos de clasificación supervisada para la estimación de cambios espacio-temporales de cobertura en los páramos de Merchán y Telecom, cordillera oriental de Colombia. *Boletín de Geología*, 44(2), 51–72. <https://doi.org/10.18273/revbol.v44n2-2022002>
- Secretaría de Medio Ambiente y Recursos Naturales. (2017). Informe de la Situación del Medio Ambiente en México [Informe]. <https://apps1.semarnat.gob.mx:8443/dgeia/informe18/tema/cap1.html>
- Trancoso, R. (2013). Análise comparativa de índices de vegetação por categoria territorial nos estados do pará e do mato grosso. <https://doi.org/10.13140/2.1.2171.7766>
- Zha, Y., Gao, J., y Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from tm imagery. *International Journal of Remote Sensing*, 24(3), 583–594. <https://doi.org/10.1080/01431160304987>

Capítulo XIII. Gentrificación de los climas urbanos y su impacto socioambiental en Bogotá y Barranquilla. Análisis desde la geomática y la percepción remota

Marielena Medina Ruiz¹

J. Guadalupe Martínez Granados²

Este capítulo, contó con el apoyo del Proyecto de investigación SIP 20251201 "Hacia un modelo de cohesión y articulación social para la regeneración de urbana de conjuntos de vivienda deteriorada" del Instituto Politécnico Nacional.

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA), Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

Este capítulo analiza la gentrificación climática en una ciudad interior de Colombia, como lo es Bogotá, y en una ciudad costera como lo es Barranquilla, evidenciando cómo las desigualdades socioeconómicas se reflejan en el acceso desigual a vegetación y confort térmico. A través de imágenes Landsat 8 y su análisis en ArcMap 10.5, se correlacionan NDVI, LST y estratos socioeconómicos. Los resultados muestran que las zonas de altos ingresos concentran vegetación y temperaturas más bajas, mientras que las áreas vulnerables presentan calor excesivo y poca infraestructura verde. El estudio concluye que este fenómeno refuerza la injusticia socioambiental y destaca la urgencia de políticas urbanas que incluyan a todas las comunidades en escenarios de resiliencia climática.

Palabras clave: percepción remota, temperatura superficial, geomática.

Abstract

This chapter analyzes climate gentrification in an inland city of Colombia, Bogotá, and a coastal city, Barranquilla, showing how socio-economic inequalities are reflected in unequal access to vegetation and thermal comfort. Using Landsat 8 imagery and analysis in ArcMap 10.5, the study correlates NDVI, LST, and socio-economic strata. The results indicate that high-income areas concentrate vegetation and lower surface temperatures, while vulnerable zones experience excessive heat and limited green infrastructure. The study concludes that this phenomenon reinforces socio-environmental injustice and highlights the urgency of urban policies that include all communities in climate resilience planning.

Palabras clave: remote sensing, surface temperature, geomatics.

1 Maestra y Doctorante en Ciencias en Arquitectura y Urbanismo, Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura, ESIA, Unidad Tecamachalco. Correo: urbmariedmed26@gmail.com, ORCID: <https://orcid.org/0000-0001-9366-1956>

2 Ph.D en el Instituto Politécnico Nacional, sección de posgrado. Doctor en Urbanismo, Facultad de Arquitectura, UNAM. Maestro en Urbanismo UNAM. Licenciado en Sociología Facultad de Estudios Superiores, Acatlán-UNAM. Correo: jogugra@hotmail.com, ORCID: <https://orcid.org/0000-0001-6345-5166>

Introducción

La gentrificación de los climas urbanos (GC) es un fenómeno reciente que redefine cómo el cambio climático afecta a las áreas urbanas. Está asociado al desplazamiento de comunidades de bajos ingresos que residen en zonas con menor exposición a riesgos ambientales, hacia áreas más vulnerables a eventos climáticos severos. De hecho, este proceso se ve acelerado por el incremento en la frecuencia e intensidad de fenómenos como las olas de calor, las inundaciones y las tormentas, que suelen afectar de manera desproporcionada a las poblaciones más desfavorecidas (Anguelovski, et al., 2016; Gould y Lewis, 2018). Mientras tanto, las personas con mayores recursos económicos tienden a reubicarse en zonas mejor preparadas para afrontar estos efectos, lo que agrava la segregación urbana y las desigualdades (Chang, 2024).

Pero ¿por qué es importante seguir estudiando las ciudades desde el clima urbano? Porque este tipo de estudios implican dar un seguimiento al impacto que tiene en las ciudades en el contexto latinoamericano, ya que el continente se enfrenta a retos específicos debido a su acelerado crecimiento urbano y a la alta informalidad, por ejemplo en la vivienda (Smith, et al., 2021). Investigar el clima urbano, incluyendo la presencia de olas de calor, la distribución de áreas verdes y superficies impermeables, permite comprender de manera preliminar cómo los fenómenos climáticos intensifican las desigualdades preexistentes y contribuyen a prever posibles desplazamientos poblacionales (Walker, 2023).

Para el caso de Colombia, este fenómeno se manifiesta de manera emergente, comenzando a influir en las dinámicas urbanas de sus principales ciudades. El cambio climático ha exacerbado los patrones de desplazamiento y de exclusión social y económica, forzando a poblaciones de bajos ingresos a vivir en zonas con mayores riesgos ambientales. Al mismo tiempo, las áreas con infraestructura mejor adaptada a efectos del clima son accesibles solo para quienes cuentan con mayor capacidad económica (Escobar, 2014). Ciudades como Bogotá y Barranquilla ilustran esta desigualdad, donde fenómenos como las islas de calor urbano, deslizamientos e inundaciones impactan de manera desproporcionada a las comunidades de menores ingresos, exponiéndolas a condiciones de mayor vulnerabilidad (Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM, 2021).

La ciudad de Bogotá tiene una temperatura promedio que oscila entre 14 y 16 °C, debido a su altitud (2,640 metros sobre el nivel del mar). Presenta un clima templado y frío durante el año, con ligeras variaciones estacionales. La temperatura máxima promedio suele rondar los 19-20°C, mientras que la mínima baja hasta los 7-9°C en promedio. Durante los últimos años ha presentado impactos en cuanto a la exposición de calor, afectando de manera especial a los sectores del sur, donde predominan comunidades de bajos ingresos. Estas zonas tienen alta densidad de construcción y escasa vegetación, lo que aumenta el estrés térmico y los problemas de salud asociados al calor.

En cambio, las áreas más acomodadas, principalmente en el norte, cuentan con mejor acceso a infraestructura verde y servicios para mitigar los efectos del cambio climático. Esta polarización entre áreas adaptadas y no adaptadas fomenta el desplazamiento de poblaciones vulnerables hacia la periferia, exponiéndolas a mayores riesgos ambientales (Santamouris, 2020).

La ciudad de Barranquilla cuenta con una temperatura de 27 a 29°C durante el año. De hecho, al estar ubicada en la costa caribeña de Colombia, tiene un clima tropical cálido, con temperaturas diarias máximas que oscilan entre 31 y 34°C, y mínimas alrededor de 23 a 25°C. La alta humedad también contribuye a una sensación térmica elevada. Sin embargo, esta ciudad presenta afectaciones del clima urbano, como es el aumento del nivel del mar y fenómenos extremos como huracanes y tormentas, que impactan especialmente a los barrios populares cercanos a la costa. Estos eventos obligan a las comunidades vulnerables a reubicarse en sectores más elevados, donde la infraestructura es precaria y el riesgo de inundaciones sigue siendo alto. Al mismo tiempo, las zonas de alto valor económico, como la Vía 40 en Barranquilla, reciben mayores inversiones en infraestructura adaptativa, mientras que los sectores desfavorecidos carecen de estos recursos. Esto crea una exclusión en la adaptación al cambio climático, exacerbando la desigualdad social (Novillo, 2018; Lobera y Olivero, 2021).

En Bogotá y Barranquilla, la injusticia socio-ambiental se refleja en que las comunidades más vulnerables carecen de acceso a espacios verdes, infraestructura adecuada y protección contra riesgos ambientales. Además, los habitantes de menor ingreso soportan una mayor carga de contaminación, riesgo de inundaciones y deslizamientos, mientras que las áreas de mayor desarrollo o interés turístico reciben más inversión en adaptación climática y servicios. Por lo tanto, se plantea como hipótesis que la actividad inmobiliaria está convirtiendo el clima urbano en un bien comercial y exclusivo, lo que puede llevar, a futuro, a un desplazamiento o no de población de estratos socioeconómicos bajos. Este fenómeno da lugar a procesos de gentrificación climática, donde solo ciertos sectores pueden acceder a los beneficios de un entorno urbano adaptado a condiciones climáticas favorables.

Es así como este capítulo presenta un estudio exploratorio sobre el impacto que tiene la gentrificación de los climas urbanos y la injusticia socioambiental en una ciudad interior (Bogotá) y una ciudad costera (Barranquilla). Como objetivo, se pretende identificar este fenómeno en el año 2023 a través de dos aspectos. Primero, determinar el índice de vegetación diferenciado clasificado (NDVI); y en segundo término, determinar la distribución de temperatura superficial (LST) de los casos de estudio, en una correlación con los estratos socioeconómicos.

¿Cómo facilitan la geomática y la percepción remota el análisis del impacto socioambiental de la gentrificación?

Para aproximarse a un posible impacto de la GC en Latinoamérica, la geomática y la percepción remota permiten tener acceso a datos espaciales y temporales detallados sobre patrones de las variables características del clima urbano, como lo son la temperatura y la distribución de vegetación en áreas urbanas. Esto, a través de Sistemas de Información Geográfica (SIG) y sensores remotos. La percepción remota es una técnica de adquisición de información sobre la superficie terrestre sin contacto directo, mediante el uso de sensores instalados en satélites. Estos capturan datos de distintos rangos espectrales (como luz visible, infrarrojo y microondas), y permiten monitorear cambios en el medio ambiente, identificar patrones de uso del suelo y analizar recursos naturales (Lillesand, et al., 2015).

Al procesar y analizar esta información, los investigadores pueden obtener una visión detallada de fenómenos geoespaciales a diferentes escalas, lo cual es fundamental en campos como la ecología, la planificación urbana y el manejo de desastres (Jensen, 2009). En este caso, se trabajó con imágenes satelitales descargadas de la página de la USGS *EarthExplorer* en: <https://earthexplorer.usgs.gov/>, puntualmente del satélite Landsat 8, ubicando geográficamente cada una de las ciudades.

El satélite *Landsat 8*, lanzado en 2013 bajo la gestión conjunta de la NASA y el Servicio Geológico de los Estados Unidos (USGS), proporciona imágenes de alta resolución que permiten monitorear de manera detallada la superficie terrestre, y está equipado con los sensores *Operational Land Imager* (OLI) y *Thermal Infrared Sensor* (TIRS); adicionalmente capta información en distintas bandas espectrales, incluyendo el espectro visible, así como el infrarrojo cercano y térmico. Esta capacidad multiespectral permite estudiar cambios ambientales y de uso del suelo, facilitando investigaciones en áreas como la deforestación, el crecimiento urbano y el cambio climático (Irons, et al., 2012). Cada imagen generada por Landsat 8 ofrece una resolución espacial de 30 metros en las bandas multiespectrales, y de 100 metros en las térmicas, lo cual resulta adecuado para obtener un nivel de detalle útil sin perder la cobertura geográfica.

Por lo tanto, se empleó este método en el cálculo de la distribución de la temperatura superficial (LST). Dentro de este conjunto de subprocesos, uno corresponde al de la distribución del índice de vegetación diferenciado NDVI (para la capa de vegetación de las ciudades), lo cual permite esta integridad de información y la ventaja de trabajo con las bandas espectrales. Esto se detalla en las siguientes etapas metodológicas:

-Descarga de ráster

Inicialmente se hace un filtro por fecha, ubicación y tipo de datos, seleccionando el conjunto de ráster adecuado. Posteriormente, se delimita el área de interés en el mapa del mundo interactivo, en este caso las ciudades de Bogotá, Medellín, Barranquilla y Cartagena, eligiendo a su vez las bandas o capas necesarias, considerando un porcentaje de nubosidad sobre el 20% máximo, que incluyen archivos ráster en formato .TIF y metadatos en .XML o .TXT. Finalmente, estos archivos se importan a software GIS como ArcGIS, para su análisis geoespacial.

-Tratamiento de ráster

Se realizó una investigación para identificar las bandas más adecuadas en el cálculo de la temperatura superficial (LST) y el índice de vegetación (NDVI). Aquí se seleccionaron las bandas 4, 5 y 10 (correspondientes al infrarrojo cercano), que son fundamentales para calcular el NDVI, pues favorecen el análisis de la salud de la vegetación porque miden la reflectancia en esas longitudes de onda. La banda 10, por otro lado, es la térmica que permite estimar la temperatura superficial, ya que captura la radiación térmica emitida por la superficie terrestre.

Una vez seleccionadas, se cargaron al programa ArcMap 10.5, donde se utilizaron herramientas del comando Image Analysis para realizar un geoproceso de clip o recorte espacial, limitando el área de estudio, y asegurando que cada banda se pueda procesar de forma independiente sin alterar los datos originales. Con ello, se pudieron generar nuevas capas editables para su análisis y posterior cálculo de índices, mientras las bandas originales fueron eliminadas del proyecto para evitar alteraciones accidentales, por lo que solo se trabajó con las capas editables listas para los análisis espaciales (Figura 1).




Figura 1. Ráster base mediante Clip. Fuente: USGS Earth Explorer y ArcMap 10.5.

- Geo procesos y aplicación de fórmulas

El cálculo de la Temperatura Superficial Terrestre (LST) se realizó siguiendo las fórmulas proporcionadas por el USGS, utilizando las herramientas de ArcToolbox, específicamente en la sección *Spatial Analyst Tools* mediante la función *Raster Calculator* de *Map Algebra*, que permite aplicar operaciones matemáticas sobre imágenes satelitales.

El primer paso consistió en obtener la radiancia espectral en el Tope de la Atmósfera (TOA), que es la energía que llega al sensor desde la superficie terrestre; aunque esto se realiza antes de eliminar los efectos atmosféricos, lo que lo convierte en un punto de partida esencial para cualquier análisis basado en imágenes satelitales. Para ello se aplicó la siguiente ecuación:

a) Cálculo de TOA (*Top of Atmospheric*) radiancia espectral con la fórmula:

$$TOA = ML * Q_{cal} + AL$$

En esta fórmula, **ML** representa el factor de re-escalamiento multiplicativo de la banda, el cual se localiza adjunto en los metadatos descargados en la imagen satelital, específicamente en la línea que indica *Radiance_mult_band_X*, donde “x” corresponde al número de la banda 10. Por otro lado, **Qcal** se refiere a los valores digitales que son capturados en la banda. **AL**, y corresponde al factor de rescalamiento aditivo ubicado en los metadatos, identificado como *radiance_add_band_x* (Figura 2).

```

QUANTIZE_CAL_MIN_BAND_11 = 1
END_GROUP = LEVEL1_MIN_MAX_PIXEL_VALUE
GROUP = LEVEL1_RADIOMETRIC_RESCALING
RADIANCE_MULT_BAND_1 = 1.2679E-02
RADIANCE_MULT_BAND_2 = 1.2984E-02
RADIANCE_MULT_BAND_3 = 1.1964E-02
RADIANCE_MULT_BAND_4 = 1.0089E-02
RADIANCE_MULT_BAND_5 = 6.1740E-03
RADIANCE_MULT_BAND_6 = 1.5354E-03
RADIANCE_MULT_BAND_7 = 5.1752E-04
RADIANCE_MULT_BAND_8 = 1.1418E-02
RADIANCE_MULT_BAND_9 = 2.4129E-03
RADIANCE_MULT_BAND_10 = 3.3420E-04
RADIANCE_MULT_BAND_11 = 3.3420E-04
RADIANCE_ADD_BAND_1 = -63.39649
RADIANCE_ADD_BAND_2 = -64.91878
RADIANCE_ADD_BAND_3 = -59.82210
RADIANCE_ADD_BAND_4 = -50.44536
RADIANCE_ADD_BAND_5 = -30.87005
RADIANCE_ADD_BAND_6 = -7.67710
RADIANCE_ADD_BAND_7 = -2.58759
RADIANCE_ADD_BAND_8 = -57.09027
RADIANCE_ADD_BAND_9 = -12.06471
RADIANCE_ADD_BAND_10 = 0.10000
RADIANCE_ADD_BAND_11 = 0.10000
REFLECTANCE_MULT_BAND_1 = 2.0000E-0
REFLECTANCE_MULT_BAND_2 = 2.0000E-0
REFLECTANCE_MULT_BAND_3 = 2.0000E-0

```

Figura 2. Búsqueda de metadatos para la radiancia espectral (TOA). Fuente: USGS EarthExplorer y Arcmap 10.5.

Por lo tanto, el TOA se traduce en los siguientes datos aplicados en ArcMap 10.5 mediante *Raster Calculator* en *Map Algebra*, donde se multiplicaron los valores que tiene la banda 10 por el factor multiplicativo, y luego se sumó el factor aditivo, como lo expresa la Figura 3.

$$TOA = 0.0003342 * "Band 10" + 0.1.$$

Este cálculo es fundamental para convertir los valores de la banda térmica, inicialmente registrados como valores digitales, en valores de radiancia física en el tope de la atmósfera, necesarios para continuar con los pasos posteriores en el cálculo de la Temperatura Superficial Terrestre (LST).




Figura 3. Fórmula aplicada de TOA Fuente: USGS EarthExplorer y Arcmap 10.5.

b) Conversión del TOA a temperatura de brillo.

El segundo paso consistió en la conversión de la radiancia TOA a temperatura de brillo BT, donde se trabaja con una temperatura aparente que un objeto emitiría como un cuerpo negro perfecto, es decir un objeto que absorbe toda la energía que recibe. Este procedimiento se realiza utilizando la siguiente fórmula:

$$BT = \frac{K2}{\ln\left(\frac{K1}{L\lambda} + 1\right)} = 273.15$$

Las constantes K1 y K2, propias de la banda térmica seleccionada (Banda 10 en las imágenes Landsat 8 o 9), se obtienen directamente del archivo de metadatos (MTL) proporcionado junto con los datos satelitales descargados del USGS, donde se identifican como $K1_CONSTANT_BAND_x$ y $K2_CONSTANT_BAND_x$, siendo x el número de la banda correspondiente. Por su parte, $L\lambda$ hace referencia a la radiancia espectral TOA, calculada previamente, resultante de convertir los valores digitales de la banda térmica en valores físicos de radiancia, mientras que $\ln$ indica la función logarítmica natural, esencial en la fórmula que permite convertir la radiancia en temperatura de brillo, un paso fundamental

en la estimación de la temperatura. No obstante, esta temperatura inicial por defecto está en grados Kelvin, así que es necesario ajustar, al sumar el valor del cero absoluto, aproximadamente -273.15°C para obtener la temperatura en grados Celsius (Figura 4).

```
REFLECTANCE_ADD_BAND_8 = -0.100000
REFLECTANCE_ADD_BAND_9 = -0.100000
END_GROUP = LEVEL1_RADIOMETRIC_RESCALING
GROUP = LEVEL1_THERMAL_CONSTANTS
K1_CONSTANT_BAND_10 = 774.8853
K2_CONSTANT_BAND_10 = 1321.0789
K1_CONSTANT_BAND_11 = 480.8883
K2_CONSTANT_BAND_11 = 1201.1442
END_GROUP = LEVEL1_THERMAL_CONSTANTS
GROUP = LEVEL1_PROJECTION_PARAMETERS
```

Figura 4. Fórmula aplicada de TOA Fuente: USGS EarthExplorer y Arcmap 10.5.

En ArcMap 10.5, esta fórmula se aplica en el *Raster Calculator* utilizando los valores de K1 y K2 provenientes de los metadatos y la capa de radiancia TOA previamente calculada, generando un nuevo ráster que representa la temperatura de brillo para cada píxel dentro del área de estudio. Este paso es crucial, ya que la temperatura de brillo es la base para realizar ajustes adicionales que permitan calcular con precisión la temperatura superficial real, al considerar factores como la emisividad de la superficie (Figura 5). Así pues, obtenemos la fórmula:

$$BT = (1321.0789 / \ln ((774.8853 / \text{"\%TOA\%"} + 1)) - 273.15.$$




Figura 5. Fórmula aplicada de temperatura de brillo Fuente: USGS EarthExplorer y Arcmap 10.5.

c) Cálculo del índice de vegetación diferenciado NDVI.

El NDVI (Índice de Vegetación de Diferencia Normalizada) se utiliza para evaluar el estado de la vegetación al comparar la reflectancia captada en el infrarrojo cercano (Banda 5) y el rojo (Banda 4). Este índice se calcula restando la reflectancia de la Banda 4 a la de la Banda 5, y dividiendo el resultado entre la suma de ambas. En términos prácticos, las superficies con vegetación sana reflejan más en el infrarrojo cercano y absorben más en el rojo, lo que genera valores de NDVI cercanos a 1, mientras que valores cercanos a -1 indican ausencia de vegetación o presencia de agua. Para aplicar esta fórmula en ArcMap 10.5, se utilizó el *Raster Calculator* y el comando *Float()*, que convierte los valores enteros en decimales, garantizando mayor precisión en el cálculo. La sintaxis aplicada fue:

$$NDVI = \frac{Float(Banda\ 5 - Banda\ 4)}{Float(Banda\ 5 + Banda\ 4)}$$

A partir de lo anterior, se generó un ráster donde cada píxel refleja un valor de NDVI, lo que facilita la identificación de áreas con distintos niveles de cobertura vegetal, como se muestra en la Figura 6.




Figura 6. Fórmula aplicada NDVI. Fuente: USGS EarthExplorer y Arcmap 10.5.

d) Cálculo de proporción de la vegetación (PV).

Es un paso importante en el estudio y análisis de coberturas vegetales, pues estima la fracción de vegetación que está presente en cada píxel de la imagen satelital. Para ello se utiliza la siguiente fórmula:

$$P_v = \left(\frac{NDVI + NDVI \min}{NDVI \max - NDVI \min} \right)^2$$

El NDVI corresponde al valor del calculado para cada píxel; el NDVI min es el valor mínimo correspondiente a las áreas que tienen menos vegetación. El NDVI máx, por lo tanto, se asocia a las superficies de mayor densidad vegetal. Con esta fórmula, se logra estandarizar los valores de dicho índice dentro de un rango de 0 a 1, y al llevarlos al cuadrado se da mayor peso a las áreas con valores de NDVI más altos. Finalmente, el P_v es la proporción de vegetación en cada celda del ráster, lo que favorece el análisis de la distribución de vegetación de forma más precisa. No obstante, para el geo proceso en ArcMap, la fórmula se agrega desde el *Raster Calculator* de *Map Algebra*, pero con la función *Square ()*, que eleva al cuadrado la expresión. En este proceso se crea un nuevo ráster, donde los píxeles reflejan fracciones de cobertura vegetal, facilitando la caracterización de superficies con distintos niveles de vegetación, como se aprecia en la Figura 7.




Figura 7. Fórmula aplicada P_v . Fuente: USGS EarthExplorer y Arcmap 10.5.

e) Cálculo de emisividad.

Este paso es importante para llegar a la estimación de la temperatura superficial terrestre, pues representa esta capacidad de dicha superficie para emitir la energía térmica a modo de radiación. Así, la emisividad depende de aquellas características que tenga la superficie, como el tipo de cobertura junto con su temperatura, calculándola de la siguiente manera:

$$\varepsilon = 0.004 \times P_v + 0.986$$

Donde P_v representa la proporción de vegetación obtenida previamente, 0.004 es un coeficiente que relaciona la cobertura vegetal con la emisividad, y 0.986 es un valor de ajuste derivado de mediciones experimentales. A mayor cobertura vegetal, mayor es la emisividad, debido a que las áreas vegetadas tienden a emitir más energía térmica que las zonas sin vegetación o urbanizadas. Este cálculo se realiza en ArcMap 10.5 mediante la Calculadora Ráster en *Map*

Algebra, ingresando la fórmula directamente, para generar un ráster donde cada píxel refleja su emisividad (Figura 8).




Figura 8. Fórmula aplicada E. Fuente: USGS EarthExplorer y Arcmap 10.5.

f) Cálculo de la temperatura superficial de la tierra (LST)

El último proceso es el análisis térmico de imágenes satelitales, proporcionando un mapa detallado de la temperatura de la superficie terrestre. Para ello se emplea la siguiente fórmula:

$$LST = \frac{BT}{1 + \left(0.00115 \frac{BT}{1.4388}\right) \times \ln(\epsilon)}$$

Aquí, **BT** es la temperatura de brillo trabajada en el paso anterior, que se calcula a partir de la radiancia espectral del TOA. El 0.00115 es la constante espectral específica para el satélite del cual se descargó el ráster, junto con la banda utilizada que es la 10 de Landsat. La otra constante espectral es 1.4388, relacionada con la longitud de onda efectiva de la banda térmica.

Por último, $\ln(\epsilon)$ representa el logaritmo natural de la emisividad (ϵ), que se calcula previamente, y ajusta la temperatura de brillo para considerar las propiedades de emisión de la superficie.

La fórmula corrige la temperatura de brillo contemplando la emisividad que tiene la superficie, permitiendo calcular con mayor precisión la temperatura real de la superficie terrestre. Es decir, el proceso convierte la radiancia medida por el satélite en una estimación de la temperatura física, teniendo en cuenta las distintas coberturas del suelo, tales como las áreas urbanas, el agua y o la vegetación, entre otros factores que emiten radiación de forma diferente. Ahora, para el geoprocesamiento esta fórmula (Figura 9) se aplica en *raster calculator* en *Map Algebra*, donde cada elemento de la ecuación se ingresa usando las capas trabajadas en los pasos anteriores (**BT** y ϵ).




Figura 9. Fórmula aplicada LST. Fuente: USGS EarthExplorer y ArcMap 10.5.

Resultados

El análisis del NDVI del 2023, para la ciudad de Bogotá, evidencia una distribución desigual de la vegetación, con una marcada ausencia en el centro urbano, donde predominan las superficies construidas. La vegetación mixta se observa principalmente en el norte y noroccidente, asociada a parques y corredores ecológicos, mientras que los cerros orientales concentran la cobertura vegetal más densa, actuando como un pulmón natural de la ciudad. En contraste, el suroccidente presenta vegetación dispersa, influenciada por actividades industriales; y la periferia occidental mantiene áreas de vegetación moderada, vinculadas a terrenos agrícolas (Figura 10).

Frente a la LST en la Figura 11, se muestra una distribución heterogénea de calor en el año 2023, con las temperaturas más altas concentradas en el centro, norte y occidente de la ciudad, donde la alta densidad urbana y la falta de vegetación intensifican el fenómeno de isla de calor. En contraste, las zonas periféricas, especialmente en el oriente y suroccidente, presentan temperaturas más bajas gracias a la presencia de áreas verdes, como los cerros orientales y corredores ecológicos, evidenciando la relación directa entre la vegetación y la mitigación térmica, en un entorno urbano cada vez más caluroso.

Para Barranquilla, el NDVI de 2023 muestra una distribución sectorizada de la vegetación marcada, donde gran parte del área urbana se caracteriza por vegetación mixta, representada en tonalidades marrones, lo que sugiere la presencia dispersa de árboles, jardines y pequeños espacios verdes en un entorno predominantemente construido. Los corredores viales y las áreas cercanas al perímetro urbano muestran una ligera mejora en la cobertura vegetal, evidenciada en tonos verdes claros que indican un volumen bajo de vegetación. Las zonas con mejor vegetación, identificadas en verde oscuro, se concentran principalmente en los bordes de la ciudad, especialmente hacia el suroccidente y en áreas cercanas al río Magdalena (Figura 12).

La LST Barranquilla para el 2023, presenta un panorama térmico variado, con concentraciones de calor que se distribuyen de manera heterogénea a lo

largo de la ciudad. Las zonas con temperaturas más altas, representadas en tonalidades rojizas y anaranjadas que alcanzan hasta 33 °C, se concentran principalmente en los sectores centrales y en áreas densamente urbanizadas, donde la cobertura vegetal es limitada y predominan las superficies impermeables, como edificaciones y vías asfaltadas, que absorben y retienen calor durante el día. Hacia las periferias y en ciertos corredores lineales se observan zonas más frescas, representadas en tonos azules, con temperaturas cercanas a los 26 °C (Figura 13).




Figura 10. NDVI Bogotá 2023. Fuente: elaboración propia con imágenes USGS y procesamiento en ArcMap 10.5.




Figura 11. LST Bogotá 2023. Fuente: elaboración propia con imágenes USGS y procesamiento en ArcMap 10.5.





Figura 12. NDVI Barranquilla 2023. Fuente: elaboración propia con imágenes USGS y procesamiento en ArcMap 10.5.



Discusión y reflexiones finales

La relación entre la vegetación urbana (NDVI), las temperaturas superficiales (LST) y los estratos económicos en Bogotá y Barranquilla durante 2023, pone de manifiesto la injusticia socioambiental que caracteriza a ambas ciudades.

En Bogotá, una ciudad interior con un clima templado, las zonas de altos ingresos concentran la vegetación y presentan menores temperaturas superficiales, mientras que las comunidades de bajos recursos, ubicadas principalmente en el sur y suroccidente, enfrentan altas temperaturas y poca cobertura vegetal, exacerbando su vulnerabilidad ambiental.

La ubicación costera de Barranquilla la expone a riesgos adicionales, como el aumento del nivel del mar y fenómenos climáticos extremos, afectando de manera desproporcionada a los sectores de bajos ingresos, mientras que, en Bogotá, los riesgos se concentran en la exposición al calor y la falta de vegetación en zonas marginales.

Esta comparación resalta que, aunque ambas ciudades enfrentan injusticias socioambientales similares, las particularidades geográficas y climáticas influyen en los tipos de riesgos y vulnerabilidades, haciendo indispensable un enfoque de planificación urbana que considere estas diferencias para garantizar la justicia ambiental y la equidad en el acceso a entornos sostenibles (Figuras 14 y 15).

El análisis mediante geomática y percepción remota evidencia que la distribución desigual de vegetación y calor en Bogotá y Barranquilla no solo es un reflejo de las condiciones geográficas, sino también de las dinámicas socioeconómicas que determinan quiénes acceden a entornos urbanos más frescos y saludables. Las diferencias observadas entre una ciudad costera y una interior, subrayan cómo el contexto climático influye en los riesgos ambientales, pero también cómo los factores económicos perpetúan la segregación espacial. Las comunidades con mayores recursos disfrutan de espacios adaptados y resilientes, mientras que los sectores de bajos ingresos enfrentan las consecuencias de la falta de infraestructura verde y la exposición constante al calor extremo.

Este panorama resalta la necesidad urgente de implementar políticas inclusivas que prioricen la justicia ambiental, reconociendo las realidades locales y garantizando que todas las comunidades, sin importar su nivel socioeconómico, puedan enfrentar los desafíos climáticos de manera equitativa.

El trabajo evidencia que la gentrificación climática en estas ciudades colombianas no solo transforma los paisajes urbanos, sino que también redefine quiénes pueden habitar y prosperar en ellos, haciendo esencial un enfoque de planificación que no solo busque mitigar los efectos del cambio climático, sino también corregir las injusticias socioambientales históricas.




Figura 14. Correlación con estratos Bogotá. Fuente: elaboración propia con imágenes USGS y procesamiento en ArcMap 10.5.




Figura 15. Correlación con estratos Bogotá. Fuente: elaboración propia con imágenes USGS y procesamiento en ArcMap 10.5.

Referencias

- Anguelovski, I., Shi, L., Chu, E., Gallagher, D., Goh, K., Lamb, Z., Reeve, K., y Teicher, H. (2016). Equity impacts of urban land use planning for climate adaptation: Critical perspectives from the global north and south. *Journal of Planning Education and Research*, 36(3), 333-348.
- Chang, C. (2024). Urban Green-Space: Environmental Justice & Green Gentrification. *Applied and Computational Engineering*, 61, 193-199.
- Escobar, A. (2014). Territorios de diferencia: lugar, movimientos, vida, redes. Editorial Universidad del Cauca.
- Gould, K., y Lewis, T. (2016). *Gentrificación verde: Sostenibilidad urbana y la lucha por la justicia ambiental*. Routledge.
- Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM). (2021). Informe sobre el estado del clima y su impacto en Colombia. Bogotá: IDEAM.
- Irons, J. R., Dwyer, J. L., y Barsi, J. A. (2012). The next Landsat satellite: The Landsat data continuity mission. *Remote sensing of environment*, 122, 11-21. <https://doi.org/10.1016/j.rse.2011.08.026>
- Jensen, J. R. (2009). *Remote sensing of the environment: An earth resource perspective 2/e*. Pearson Education India.
- Lobera-Peña, E., y Olivero-Verbel, J. (2021). Índice de vulnerabilidad en dos barrios de Cartagena de Indias. *Gestión y Ambiente*, 24(1), 91194-91194.
- Lillesand, T., Kiefer, R. W., y Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley y Sons.
- Novillo Rameix, N. (2018). Cambio climático y conflictos socioambientales en ciudades intermedias de América Latina y el Caribe. *Letras Verdes, Revista Latinoamericana de Estudios Socioambientales*, (24), 124-142.
- Smith, J., Brown, D., y Rodríguez, P. (2021). Urban resilience and climate adaptation strategies in Latin American cities. *Climate and Development*, 13(7), 608-619.
- Santamouris, M. (2020). Recent progress on urban overheating and heat island research. Integrated assessment of the energy, environmental, vulnerability and health impact. Synergies with the global climate change. *Energy and Buildings*, 207, 109482.
- Walker, R. H. (2023). *Environmental Planning, Urban Development, and the Making of Environmental Injustice in Minneapolis* (Doctoral dissertation, University of Minnesota).

Capítulo XIV. Identificación del avance de la cobertura de suelo urbano utilizando supervisión clasificada en Google Earth Engine

Luz de Lourdes Cordero Gómez del Campo¹

Víctor Manuel Sánchez Vega²

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),
Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

Los procesos de financiarización han transformado a la inversión inmobiliaria convirtiendo activos fijos en circulantes, dotando al mercado de bienes raíces de grandes cantidades de capital y liquidez a través de diferentes instrumentos de inversión. Esto ha resultado en una comodificación de la vivienda, donde esta es considerada como un medio para la acumulación de capital y no como una necesidad primordial del ser humano. Entre las diversas consecuencias del impulso financiero sobre el mercado inmobiliario, tenemos el avance de la mancha urbana, con consecuencias socio-ambientales como pérdida de bosques, afectación de la calidad del aire y la recarga de acuíferos, así como la intensificación de la fragmentación del territorio y las desigualdades urbanas. En este capítulo explicamos cómo utilizamos percepción remota para identificar el avance de la cobertura urbana en la Alcaldía Cuajimalpa de la CDMX, donde aproximadamente el 80% de su superficie es considerada suelo de conservación (que incluye bosques y áreas naturales). Utilizamos clasificación supervisada en Google Earth Engine (GEE) con imágenes satelitales de USGS Landsat 7 y ESA Sentinel-2 MSI para identificar el avance de la cobertura urbana sobre otras coberturas, en un periodo comprendido entre 2009 y 2025. Este análisis forma parte de un proyecto de investigación más amplio que abarca otras Alcaldías de la Ciudad de México, pero para el caso de la Alcaldía Cuajimalpa encontramos que el avance del suelo urbano se ha dado principalmente sobre la cobertura de suelo desnudo, lo que sugiere una posible modificación en los usos de suelo, lo que favorece a la inversión inmobiliaria, premisa que analizaremos en futuras investigaciones.

Palabras clave: financiarización, inversión inmobiliaria, percepción remota, Google Earth Engine, clasificación supervisada.

Abstract

Financialization processes have transformed real estate investment by converting fixed assets into liquid ones, injecting the real estate market with

1 Doctora en Geografía por la Universidad Nacional Autónoma de México. Actualmente en Estancia Posdoctoral en la Sección de Estudios de Posgrado de la Escuela Superior de Ingeniería y Arquitectura, Unidad Tecamachalco, del Instituto Politécnico Nacional. Correo: lcorderog@ipn.mx, ORCID: <https://orcid.org/0000-0003-3045-7629>

2 Estudiante de Maestría en Ciencias en Arquitectura y Urbanismo en el Instituto Politécnico Nacional, ESIA, Unidad Tecamachalco, Correo: vsanchezv0901@alumno.ipn.mx, ORCID: <https://orcid.org/0009-0007-6830-0711>

large amounts of capital and liquidity through different investment instruments. This has resulted in the commodification of housing, where it is considered a means for capital accumulation and not a fundamental human need. Among the various consequences of the financial drive in the real estate market, we find the expansion of the urban footprint with social and environmental consequences such as the loss of forests, impact on air quality and aquifer recharge, as well as the intensification of territorial fragmentation and urban inequalities. In this chapter, we explain how we used remote sensing to identify the expansion of urban land cover in the Cuajimalpa borough of Mexico City, where approximately 80% of its surface is considered conservation land including forests and natural areas. Supervised classification in Google Earth Engine (gee) with satellite images from USGS Landsat 7 and ESA Sentinel-2 MSI was used to identify the expansion of urban land cover over other land covers in a period from 2009 to 2025. This analysis is part of a bigger research project that includes other boroughs in Mexico City, but in the case of Cuajimalpa, we found that the expansion of urban land has occurred mainly over bare soil cover, which suggests a possible change in land use that favors real estate investment, a premise that we will analyze in further research.

Palabras clave: financialization, real estate investment, remote sensing, Google Earth Engine, supervised classification.

Introducción

En 2011 se realizó la Oferta Pública Inicial (OPI) de la primera FIBRA mexicana: FibraUNO, que operando bajo el modelo de los REITs estadounidenses, convertiría un bien ilíquido (m^2 de construcción), en un bien líquido (certificados de inversión inmobiliaria). La aparición de las FIBRAS en el mercado de capitales mexicano duplicó y, en algunos casos, triplicó la cantidad de m^2 construidos por estas entidades financieras, por lo menos hasta 2018, lo que continúa en los siguientes años, aunque con menor energía. La construcción de oficinas, espacios comerciales y vivienda en México participa de los circuitos internacionales de financiarización a través de la intermediación de bancos, fondos de pensiones y fondos de inversión, entre otros, impulsando la construcción de más m^2 , con el objetivo de generar ganancias que se intercambian en los mercados financieros y se alejan de las necesidades reales de las comunidades donde se desempeñan.

Desde la década de los 2000, autores como Clark (2005), Leyshon, et al. (2007), y Aalbers (2009), destacan la importancia de estudiar este concepto dentro de las ciencias sociales, especialmente desde la geografía financiera, por la importancia que representa el componente espacial en los flujos globales financieros. Leyshon y Thrift (2007), en su trabajo *The Capitalization of Almost Everything*, explican cómo la financiarización transformó el papel del capital en la economía, cambiando la orientación de la lógica productiva hacia una lógica financiera en la que se prioriza la extracción de utilidades sobre la creación de

valor. Engelen, et al. (2014) y Halbert, et al. (2016) entre otros, abordan en este mismo sentido algunos temas de financiarización de la producción urbana y su impacto sobre el territorio.

En la introducción del reporte especial de las Naciones Unidas de enero de 2017, se define a la financiarización de la vivienda como el dominio que ejercen el sector financiero y las corporaciones sobre el mercado inmobiliario, explicando que los cambios estructurales, aunados a la participación de los mercados financieros y la inversión global, resultan en que la vivienda es tratada como un *commodity*, es decir, como medio para la acumulación de riqueza y como respaldo de instrumentos financieros que se venden e intercambian en mercados globales. Esto genera inversiones alejadas de la función social de proporcionar al individuo un lugar seguro y digno para vivir, y que son ajenas a las necesidades de las personas y las comunidades donde se insertan. Se enfatiza adicionalmente, en este reporte, el impacto de este mercado de vivienda financierizada sobre población vulnerable sobre prácticas predatorias de otorgamiento de créditos, y sobre la volatilidad del mercado, explicando que han tenido como resultado una precarización de la vivienda sin precedente (UNGA, 2017).

Una de las formas en las que se traducen estos procesos de financiarización de la vivienda en la CDMX, es la presión inmobiliaria que se ejerce sobre el suelo de conservación, sobre otros usos de suelo y en el desplazamiento de vivienda de interés medio y bajo, para dar cabida a desarrollos residenciales. Esto resulta en la pérdida de otras coberturas, al avanzar sobre predios con otros usos de suelo, fomentando, entre otros problemas, la ocupación de terrenos protegidos y con alto riesgo de desastres, como cañadas y barrancas, frecuentemente con vivienda irregular.

El objetivo de este capítulo es explicar cómo utilizamos la percepción remota para identificar el avance de la cobertura urbana en la Alcaldía Cuajimalpa de la CDMX, donde aproximadamente el 80% de la superficie es considerada suelo de conservación que incluye bosques y áreas naturales. Utilizamos clasificación supervisada en Google Earth Engine (GEE) con imágenes satelitales de USGS Landsat 7 y ESA Sentinel-2 MSI, para identificar el avance de la cobertura urbana sobre otras coberturas, en la Alcaldía Cuajimalpa de Morelos, en un periodo comprendido entre 2009 y 2025.

Percepción remota y Google Earth Engine

Maples (2021), en su video de YouTube: Google Earth Engine101: *An Introduction for Complete Beginners* para Stanford Geospatial Center, explica cómo la percepción remota nos permite obtener información sobre un objeto o un área a distancia, sin contacto físico, proporcionando herramientas de adquisición y análisis de información que pueden expresarse en imágenes formadas por píxeles, que son cuadrados de color que representan valores numéricos.

Estos valores indican la cantidad de energía electromagnética que refleja el área o el objeto que estemos analizando, y que se captura en forma de imágenes espectrales por cámaras digitales montadas en satélites o en vehículos aéreos. Maples (2021) también explica que cuando tomamos una fotografía con la cámara del celular, usamos un filtro para obtener una imagen RGB, compuesta de una muestra de cada uno de los tres colores de la parte visible del espectro: rojo, verde y azul. Sin embargo, las cámaras montadas en los satélites no tienen estos filtros, y pueden ver más allá de imágenes RGB, con bandas como infrarrojo cercano (NIR), infrarrojo de banda corta (SWIR), infrarrojo termal (TIR), o pancromático negro y blanco (Pan).

Estas diferentes bandas se pueden utilizar en diversas combinaciones para discriminar distintos tipos de cobertura terrestre como vegetación, suelo desnudo, suelo urbano o agua. Para realizar el análisis geoespacial de la Alcaldía Cuajimalpa, utilizamos imágenes satelitales obtenidas por LandSat y Sentinel y las capacidades de *Google earth engine (gee)*, que de acuerdo con su página web (GEE, 2025a), es una herramienta que combina un catálogo *multi-petabyte* de imágenes satelitales y bases de datos geoespaciales, con capacidad de análisis a escala planetaria.

A su vez, se posee un *Application Programming Interface* (API) para *Python* y *JavaScript*, que permite realizar análisis espaciales a través del editor de código, siendo *JavaScript* el lenguaje de programación que utilizamos. Con la ayuda de una clasificación supervisada de imágenes satelitales, es posible generar mapas temáticos de cobertura del suelo usando puntos de entrenamiento etiquetados.

Actualmente, disponemos de varias opciones de aprendizaje automático como *CART*, *RandomForest* y *SVM*; prefiriendo utilizar *CART*, cuyo flujo consiste en recolectar datos de entrenamiento (puntos con etiqueta conocida), para construir y entrenar a este clasificador.

El caso de estudio que toma este capítulo puntualmente corresponde a la alcaldía Cuajimalpa de Morelos de la CDMX, evaluada para los años 2009, 2013 y 2017, usando colección de imágenes de USGS Landsat 7, y para los años 2021 y 2025 usando colección de imágenes de ESA Sentinel-2 MSI, con el objetivo de obtener 5 mapas comparativos de cobertura del suelo (urbano, vegetación, agua, suelo desnudo) en dicha región.

Metodología

1. *Shapefiles. Marco Geoestadístico INEGI*

El primer paso para iniciar este análisis territorial de la Alcaldía Cuajimalpa de Morelos consiste en obtener el archivo *Shapefile*, correspondiente a su límite municipal. Este archivo se encuentra disponible dentro del Marco Geoestadístico, sistema desarrollado por el Instituto Nacional de Estadística y Geografía (INEGI).

Dicho sistema, de cobertura nacional, presenta la división geoestadística del territorio mexicano, tanto continental como insular, en distintos niveles de desagregación, y refiere geográficamente la información estadística generada a través de censos, encuestas e indicadores institucionales, integrados al Sistema Nacional de Información Estadística y Geográfica (SNIEG).

Para localizar el *Shapefile* adecuado, es necesario filtrar correctamente el área geográfica del caso de estudio. En este contexto se debe seleccionar la entidad correspondiente, Ciudad de México, y, dentro de ella, identificar a la Alcaldía Cuajimalpa de Morelos como unidad territorial específica. Posteriormente, se busca la versión más actualizada del Marco Geoestadístico que se va a utilizar, para garantizar la precisión en la delimitación espacial, puesto que INEGI actualiza periódicamente esta base de datos para mantener su vigencia y consistencia con los procesos censales más recientes.

Una vez definido el territorio y la versión del archivo, es fundamental aplicar el filtro por AGEM, es decir, el Área Geoestadística Municipal. Estas áreas constituyen las divisiones territoriales empleadas por el INEGI para organizar y referenciar la información estadística a nivel municipal o alcaldía. Cada AGEM cuenta con una clave única que permite identificar y extraer con exactitud el *Shapefile* correspondiente a la demarcación de interés.

2. Carga de Shapefile de zona de estudio y definición de puntos de entrenamiento

Antes de comenzar con el script para entrenar el clasificador, dentro del editor de código de GEE (GEE, 2025b) se debe cargar el *Shapefile* dentro de Assets, que se compone de archivos cuyas extensiones permitidas son: ***shp, zip, dbf, prj, shx, cpg, fix, qix, sbn*** o ***shp.xml***, importándolo al editor de código para renombrar la variable de este *Shapefile*.

Para tener los recursos que representen cada capa, se crean manualmente puntos, mostrados como marcadores, dentro del mapa, creando uno por clase: *urban* (suelo edificado), *vegetation* (vegetación), *water* (agua) y *soil* (suelo desnudo), lo cual añadirá 4 nuevas capas de geometrías (*Geometry Imports*) en el editor de código, una por clase, las mismas de las que deberemos declarar su variable de acuerdo con su representación. Al final debemos tener 5 entradas en el apartado de *Imports* del editor de código (Figura 1).




Figura 1. Panel de Imports en el editor de gee. Se muestran las cuatro colecciones de puntos de entrenamiento (urban, vegetation, water, soil) con su número de elementos, y el shapefile del área de estudio (Cuajimalpa). Fuente: elaboración propia.

Dentro del panel de *Imports* se configura cada capa como *FeatureCollection*, el color de identificador a utilizar, y se añade la propiedad *landcover* para definir un valor entero para cada capa. Por ejemplo, *landcover* = 0 para urbano, 1 para vegetación, etc. Con este esquema de etiquetado con enteros consecutivos desde 0, se mantiene la convención de gee para clasificación (Figura 2).

Teniendo la configuración e integración de estos 5 elementos en el *Import* del editor de código, será importante guardar 5 versiones de este para cada año (2009, 2013, 2017, 2021 y 2025) accediendo a *Save as...*, y escribiendo un nombre que identifique el archivo para cada año, tomando en cuenta no dejar espacios, y pudiendo delimitar cada palabra con los símbolos “-” o “_”, usando el símbolo “/” exclusivamente para denotar jerarquías o creación de subcarpetas (Figura 3).




Figura 2. Ejemplo de configuración de la capa urban en gee. Se definió como *FeatureCollection* con propiedad *landcover* = 0 (urbano). De forma similar se configuran las otras clases con valores de *landcover* 1, 2 y 3. Fuente: elaboración propia.




Figura 3. Ejemplo para guardar 5 versiones de script con los 5 elementos configurados e integrados. Fuente: elaboración propia.

3. Carga y procesamiento de colecciones

Para los años 2009, 2013 y 2017 se carga la colección LANDSAT/LE07/C02/T1, renombrando a la variable con un identificador para reconocer la colección y/o satélite que estamos empleando. Asimismo, se declara otra variable que contenga la variable de la colección, para aplicar filtros, nombrándola igualmente con un identificador para este caso. A continuación, se filtra temporalmente el año deseado con `.filterDate('Año-01-01','Año-12-31')`; y se restringe espacialmente al área de Cuajimalpa usando `filterBounds(Cuajimalpa)`; y el `Shapefile` importado. Por último, se aplica un filtro por nubosidad usando la propiedad `CLOUD_COVER` con un porcentaje de entre 20% y 30%. Como ejemplo, `filter(ee.Filter.lt('CLOUD_COVER', 20))`, que retiene escenas con menos del 20% y/o 30% de nubes.

La aplicación de estos filtros reduce la colección a imágenes relevantes por fecha, ubicación y calidad. Opcionalmente, puede aplicarse una máscara de nubes píxel_qa o el método `cloudScore`, pero para este caso solo se consideran los 3 filtros mencionados anteriormente. Optativamente, se puede hacer una impresión de los filtros en la consola para corroborar la cantidad de imágenes encontradas con las anteriores sentencias (Figura 4).




Figura 4. Ejemplo de integración de colección LANDSAT/LE07/C02/T1 para el año 2009.

Fuente: elaboración propia.

Para los años 2021 y 2025 el proceso es similar, salvo la carga de la colección corresponde a Sentinel-2, la cual es `COPERNICUS/S2_SR_HARMONIZED`.

Posteriormente, se renombra la variable con un identificador para reconocer la colección y/o satélite que estamos empleando. Asimismo, se declara otra variable que contenga la variable de la colección para aplicar filtros, nombrándola igualmente con un identificador para este caso. Se filtra temporalmente el año deseado con `.filterDate('Año-01-01','Año-12-31')`; además, se restringe espacialmente al área de Cuajimalpa usando `.filterBounds(Cuajimalpa)` y el

Shapefile importado; y por último se aplica un filtro por nubosidad, usando la propiedad `CLOUD_COVER` con un porcentaje de entre 20% y 30%. Como ejemplo, `filter(ee.Filter.lt('CLOUD_COVER', 30))` que retiene escenas con menos del 20% y/o 30% de nubes. Optativamente, se puede hacer una impresión de los filtros en la consola, para corroborar la cantidad de imágenes encontradas con las anteriores sentencias.

Para los años 2021 y 2025 el proceso es similar, salvo la carga de la colección que corresponde a Sentinel-2, la cual es `COPERNICUS/S2_SR_HARMONIZED`.

Posteriormente, se renombra la variable con un identificador para reconocer la colección y/o satélite que estamos empleando. Asimismo, se declara otra variable que contenga la variable de la colección para aplicar filtros, nombrándola igualmente con un identificador para este caso. Se filtra temporalmente al año deseado con `.filterDate('Año-01-01','Año-12-31')`; además, se restringe espacialmente al área de Cuajimalpa usando `.filterBounds(Cuajimalpa)`; y el *Shapefile* importado y, por último, se aplica un filtro por nubosidad usando la propiedad `CLOUD_COVER` con un porcentaje de entre 20% y 30%. Como ejemplo, `filter(ee.Filter.lt('CLOUD_COVER', 30))` que retiene escenas con menos del 20% y/o 30% de nubes. Optativamente, se puede hacer una impresión de los filtros en la consola para corroborar la cantidad de imágenes encontradas con las anteriores sentencias (Figura 5).




Figura 5. Ejemplo de integración de colección `COPERNICUS/S2_SR_HARMONIZED` para el año 2021. Fuente: elaboración propia.

4. Composición sin nubes

Para los scripts elaborados con Landsat 7, se genera una imagen compuesta libre de nubes con `ee.Algorithms.Landsat.simpleComposite`.

Este algoritmo calcula valores top-of-atmosphere y marca la nubosidad en cada píxel, luego selecciona para cada píxel los valores con menor nubosidad, y calcula el porcentaje deseado, por defecto el 50%, es decir, la media de cada banda, produciendo un mosaico que combina las mejores escenas disponibles. Además, se aplica un recorte espacial al área de estudio con `.clip(Cuajimalpa)`

para enfocar el mapa solo en la alcaldía y, opcionalmente, se puede hacer una impresión de la composición en la consola para corroborar la cantidad de imágenes encontradas con las sentencias aplicadas (Figura 6).




Figura 6. Ejemplo de script de composición sin nubes para Landsat 7 para el año 2009.

Fuente: elaboración propia.

Para los scripts elaborados con Sentinel-2, se genera una imagen compuesta libre de nubes mediante el método `.median()`, que calcula la mediana por píxel a partir de la colección de imágenes previamente filtradas. Este método selecciona, para cada píxel y banda espectral, el valor central dentro del conjunto ordenado de imágenes, lo que permite reducir la influencia de valores poco comunes, como nubes, sombras o errores radiométricos; esto ayuda a crear una representación más estable y representativa del comportamiento espectral del área del periodo analizado.

Finalmente, la imagen compuesta se recorta (`.clip`) al límite geográfico del municipio de Cuajimalpa, delimitando espacialmente el análisis al área de estudio (Figura 7).



Figura 7. Ejemplo de script de composición de nubes para Sentinel-2 para el año 2021.


Fuente: elaboración propia.

5. Composición RGB

Para los años 2009, 2013 y 2017 se crea un script para la visualización en color natural (RGB) de la imagen compuesta obtenida a partir de datos Landsat 7, usando el método `.visualize()` para aplicar un estilo visual a la imagen antes de mostrarla en el mapa. Se especifican las bandas que se usarán como componentes de color, para Landsat 7 B3 (Rojo), B2 (Verde) y B1 (Azul). Además, se establece el valor mínimo de reflectancia que se visualizará; todo valor menor será mapeado a negro, para este caso se considera `min: 0.05`.

Posteriormente, se establece el valor máximo de reflectancia, considerando `max: 0.3`. Todo valor mayor será mapeado a blanco. Se elige este valor porque los valores típicos de reflectancia para la vegetación, el suelo y cuerpos de agua suelen estar dentro de este rango.

Por último, se controla la curva de brillo con un valor `gamma: 1.2`; un valor mayor a 1 aumenta el brillo de las sombras, creando una imagen más clara sin saturar los colores brillantes, mejorando la visibilidad de detalles en áreas oscuras (Figura 8).



```
Clasificación_Cuajimalpa_2... Get Link Save Run Reset Apps
Imports (5 entries)
var urban: FeatureCollection (91 elements)
var vegetation: FeatureCollection (214 elements)
var water: FeatureCollection (10 elements)
var soil: FeatureCollection (221 elements)
var Cuajimalpa: Table projects/ee-my-victorshezy/assets/Cuajimalpa

1 // Cargar la colección de imágenes de radiancia a escala de Landsat 7.
2 var landsatCollection = ee.ImageCollection('LANDSAT/LE07/C02/T1')
3 var filter = landsatCollection
4   .filterDate('2009-01-01', '2009-12-31')
5   .filterBounds(Cuajimalpa)
6   .filter(ee.Filter.lt('CLOUD_COVER', 20));
7 print(filter)
8
9 // Crear una composición sin nubes.
10 var composite = ee.Algorithms.Landsat.simpleComposite({
11   collection: filter,
12   asFloat: true
13 }).clip(Cuajimalpa); // Recortar al área de Cuajimalpa
14 print(composite)
15
16 // Crear una versión visualizada de la composición en RGB.
17 var compositeRGB = composite.visualize({
18   bands: ['B3', 'B2', 'B1'],
19   min: 0.05,
20   max: 0.3,
21   gamma: 1.2
22 });
```

Inspector Console Tasks

Use print(...) to write to this console.

ImageCollection LANDSAT/LE07/C... 750N

Image (9 bands) 750N

Figura 8. Ejemplo de script para crear una versión visualizada de una composición en RGB de Landsat 7 para el año 2009. Fuente: elaboración propia.

Para la visualización en color natural de imágenes Sentinel-2, se crea un script, aplicando los parámetros adecuados para su escala de valores, que es diferente a Landsat.

Se especifican las bandas que se usarán como componentes de color, para Sentinel-2 B4 (Rojo), B3 (Verde) y B2 (Azul). Posteriormente, se establece el valor mínimo del rango de reflectancia visualizable en 0. En imágenes Sentinel-2, los valores no están normalizados entre 0 y 1 como en Landsat, sino que están escalados, típicamente entre 0 y 10,000. Además, se elige el valor máximo del rango de reflectancia en 3,000, que típicamente suele ser

el más adecuado para representar la mayoría de las superficies (vegetación, suelo, agua) sin saturar la imagen.

Por último, de igual manera se controla la curva de brillo con un valor gamma: 1.2; un valor mayor a 1 aumenta el brillo de las sombras, creando una imagen más clara sin saturar los colores brillantes, mejorando la visibilidad de detalles en áreas oscuras (Figura 9).




Figura 9. Ejemplo de script para crear una versión visualizada de una composición en RGB de Sentinel-2 para el año 2021. Fuente: elaboración propia.

Para mostrar las composiciones se crea un script que realiza la visualización de los resultados sobre el mapa en gee, específicamente mostrando el contorno geográfico de Cuajimalpa de Morelos, y la imagen compuesta en RGB generada previamente, ya sea con Landsat 7 o con Sentinel-2.

El primer comando `Map.addLayer(Cuajimalpa, {color: 'black'}, 'Cuajimalpa de Morelos', false)` añade al mapa el límite territorial del área de estudio. En este caso, la variable `Cuajimalpa` contiene el *Shapefile* de la alcaldía cargado al inicio, y se representa visualmente en negro con `{color: 'black'}`. La entrada de la función “Cuajimalpa de Morelos” es el nombre de la capa mostrada en el visor; por último, el valor `false` indica que la capa se agregará al visor, pero estará desactivada por defecto.

El segundo comando, `Map.addLayer(compositeRGB, {}, 'Cuajimalpa RGB', false)` incorpora al visor de mapa la imagen compuesta visualizada en formato RGB, generada anteriormente.

En este caso, no se usan nuevos parámetros de estilo, ya que la imagen en RGB ya tiene las propiedades de visualización (bandas, mínimos, máximos y gamma) que se definieron antes. Al igual que la capa anterior, esta también se agrega inactiva por defecto (Figuras 10 y 11).




Figura 10. Ejemplo de visualización de composición RGB para el año 2009. Fuente: elaboración propia.




Figura 11. Ejemplo de visualización de composición RGB para el año 2021. Fuente: elaboración propia.

6. Muestreo espectral y preparación del entrenamiento

Una vez que se ha generado y visualizado correctamente la composición RGB, se procede a identificar visualmente las distintas coberturas del suelo presentes en la zona de estudio. Es importante realizar el muestreo sobre la visualización de la composición RGB, ya que es posible ubicar con mayor precisión las zonas que representan claramente cada clase de interés: áreas urbanas, vegetación, cuerpos de agua y suelo desnudo.

A partir de esta identificación, se colocan manualmente puntos de entrenamiento en el mapa, basándose tanto en el reconocimiento visual como en el conocimiento previo que se tenga del caso de estudio. Entre mayor cantidad de marcadores se coloquen, mayor será el muestreo para que el entrenamiento sea más preciso (Figura 12).




Figura 12. Ejemplo de muestreo con marcadores para el año 2021. Fuente: elaboración propia.

Una vez muestreadas las cuatro categorías: urban, vegetation, water, soil, se pueden fusionar en una sola colección de entrenamiento usando `merge()`, que permite combinar múltiples `FeatureCollection` en una sola entidad. Tanto para imágenes Landsat 7 como Sentinel-2, se utiliza el mismo comando: `var newfc = urban.merge(vegetation).merge(water).merge(soil)`; creando un nuevo conjunto de datos llamado `newfc`, el cual servirá como base para entrenar el modelo de clasificación supervisada.

Posteriormente, es necesario especificar cuáles bandas espectrales de las imágenes se utilizarán como variables predictoras dentro del algoritmo de clasificación. En el caso de Landsat 7, se seleccionaron las bandas (B1, B2, B3, B4, B5 y B7), que corresponden a los canales espectrales más relevantes, para distinguir distintos tipos de cobertura terrestre, abarcando desde el azul hasta el infrarrojo de onda corta, excluyendo la banda térmica (B6), que comúnmente no se emplea para este tipo de clasificación (Figura 13).




Figura 13. Ejemplo de preparación del conjunto de entrenamiento para clasificación supervisada para el año 2009. Fuente: elaboración propia.

Por otro lado, para Sentinel-2 se utilizaron las bandas (B2, B3, B4 y B8), que representan el azul, verde, rojo e infrarrojo cercano (NIR), una combinación eficaz para distinguir vegetación, cuerpos de agua y estructuras construidas debido a sus contrastes espectrales marcados (Figura 14).




Figura 14. Preparación del conjunto de entrenamiento para clasificación supervisada para el año 2021. Fuente: elaboración propia.

Finalmente, se establece el nombre de la propiedad que contiene la etiqueta de clase dentro de cada punto. Esto se define mediante la variable `classProperty = 'landcover'`, lo cual indica que el algoritmo de clasificación debe utilizar el valor almacenado en la propiedad `landcover` de cada entidad para identificar a qué clase pertenece. Esta integración entre las bandas seleccionadas como entrada, y la propiedad de clase como salida, es esencial para que el algoritmo pueda aprender a discriminar entre las diferentes categorías de cobertura del suelo en función de sus firmas espectrales.

7. Entrenamiento del clasificador CART y aplicación

Con la colección de entrenamiento fusionada, el siguiente paso es generar los datos de entrenamiento propiamente dichos. Esto se logra mediante el método `sampleRegions()`, que extrae los valores espectrales de las bandas seleccionadas para cada punto de la colección `newfc`. En ambos scripts, la instrucción `composite.select(bands).sampleRegions(...)` indica que se tomarán en conjunto las bandas seleccionadas de la composición RGB, y se muestrearán en las ubicaciones definidas por los puntos etiquetados. Para el caso de Landsat 7, se especifica una resolución espacial de 30 metros (`scale: 30`). Mientras que para Sentinel-2 se emplea una escala de 10 metros (`scale: 10`), acorde a la resolución respectiva. Además, se indica que la propiedad `landcover` será la utilizada como etiqueta de clase, vinculando así los datos espectrales con su categoría correspondiente. Con los datos de entrenamiento ya generados, se procede a entrenar un clasificador supervisado, utilizando el algoritmo CART (Classification and Regression Trees). Este tipo de clasificador construye un árbol de decisión basado en los valores de las bandas espectrales, buscando separar de manera óptima las distintas clases definidas.

Para ambos casos (Landsat 7 y Sentinel-2), se emplea `ee.Classifier.smileCart().train(...)`, donde se indican como parámetros el conjunto de datos

de entrenamiento (features: training) y la propiedad que contiene la clase (classProperty: classProperty). Esto permite que el algoritmo aprenda los patrones espectrales asociados a cada tipo de cobertura del suelo a partir de los ejemplos proporcionados.

Una vez entrenado el modelo, se imprime un resumen del funcionamiento del clasificador utilizando `classifier.explain()`. Esta función proporciona detalles sobre la estructura interna del árbol de decisión, como el número de nodos, la profundidad del árbol y los criterios utilizados en cada división, lo cual es especialmente útil para evaluar la complejidad y comportamiento del modelo (Figura 15 y 16).

```

42 // El nombre de la propiedad en los puntos que almacena la etiqueta de clase
43 var classProperty = 'landcover';
44
45 // Muestrear el compuesto para generar datos de entrenamiento.
46 // Tener en cuenta que la etiqueta de clase se almacena en la propiedad 'lar
47 var training = composite.select(bands).sampleRegions({
48   collection: newfc,
49   properties: [classProperty],
50   scale: 30
51 });
52
53 // Entrenar el clasificador CART.
54 var classifier = ee.Classifier.smileCart().train({
55   features: training,
56   classProperty: classProperty,
57 });
58 // Imprime información sobre el clasificador (especifica de CART).
59 print('CART, explained', classifier.explain());
  
```

Inspector Console Tasks

Use print(...) to write to this console.

- ImageCollection LANDSAT/LE07/C... JSON
- Image (9 bands) JSON
- CART, explained JSON
- Object (5 properties) JSON

Figura 15. Ejemplo de muestreo, entrenamiento e interpretación del clasificador CART por cobertura del suelo para Landsat 7 para el año 2009. Fuente: elaboración propia.

```

40 // El nombre de la propiedad en los puntos que almacena la etiqueta de clase
41 var classProperty = 'landcover';
42
43 // Muestrear el compuesto para generar datos de entrenamiento.
44 // Tener en cuenta que la etiqueta de clase se almacena en la propiedad 'lar
45 var training = composite.select(bands).sampleRegions({
46   collection: newfc,
47   properties: [classProperty],
48   scale: 10
49 });
50
51 // Entrenar el clasificador CART.
52 var classifier = ee.Classifier.smileCart().train({
53   features: training,
54   classProperty: classProperty,
55 });
56 // Imprime información sobre el clasificador (especifica de CART).
57 print('CART, explained', classifier.explain());
  
```

Inspector Console Tasks

Use print(...) to write to this console.

- ImageCollection COPERNICUS/S2_... JSON
- Image (26 bands) JSON
- CART, explained JSON
- Object (5 properties) JSON

Figura 16. Ejemplo de muestreo, entrenamiento e interpretación del clasificador CART por cobertura del suelo para Sentinel-2 para el año 2021. Fuente: elaboración propia.

Por último, se aplica el clasificador sobre la imagen compuesta mediante la función `composite.classify(classifier)`, lo que genera una nueva imagen clasificada, donde cada píxel ha sido etiquetado con una de las capas aprendidas por el modelo. Esta imagen se visualiza en el mapa con `Map.addLayer(...)`, usando una paleta de colores específica que representa cada clase: negro para urbano, verde para vegetación, azul para cuerpos de agua, y marrón para suelo desnudo. La visualización se añade inicialmente desactivada (false) para no

saturar el visor, y se centra automáticamente la vista en la región de Cuajimalpa con `Map.centerObject(Cuajimalpa)`, permitiendo explorar visualmente los resultados del proceso de clasificación (Figura 17).




Figura 17. Visualización de la clasificación a partir de CART del año 2009. Fuente: elaboración propia.

Posterior a la visualización de la clasificación, se podrá realizar una inspección manual para corregir o agregar algún otro marcador que el clasificador haya comprendido mal o haya omitido, con la intención de tener un muestreo lo más amplio y completo posible.

8. Evaluación del modelo y matriz de confusión

Una vez entrenado el clasificador supervisado, es fundamental evaluar su precisión para entender qué tan bien ha aprendido a distinguir entre las diferentes clases de cobertura del suelo. Para ello, se utiliza una matriz de confusión, que es una herramienta estadística que compara las clases reales de los datos contra las clases simuladas por el modelo.

El proceso comienza con la creación de una columna de valores aleatorios al conjunto de entrenamiento, utilizando `training.randomColumn('random')`. Esta columna, llamada 'random', contiene valores distribuidos uniformemente entre 0 y 1, y sirve como criterio para dividir aleatoriamente los datos. Posteriormente, se define el criterio de separación con la variable `split = 0.7`, lo que significa que el 70% de los datos se usarán para entrenar el modelo (`trainingPartition`), mientras que el 30% restante se reservará para validación (`testingPartition`). Esta división permite que el modelo no se limite a aprender de memoria los ejemplos usados para entrenarlo, sino que sea capaz de reconocer correctamente nuevas situaciones que no ha visto antes.

Con la partición de entrenamiento, se entrena un nuevo clasificador utilizando el algoritmo Random Forest con 5 árboles de decisión, a través de `ee.Classifier.smileRandomForest(5).train(...)`. Este modelo se ajusta a los datos

contenidos en `trainingPartition`, usando como variables predictoras las bandas seleccionadas (`inputProperties: bands`), y como etiqueta de clase la propiedad 'landcover'. Una vez entrenado el modelo, se aplica al subconjunto de prueba (`testingPartition.classify(trainedClassifier)`) el 30% de datos restantes, generando predicciones que pueden compararse con las etiquetas reales.

Finalmente, se calcula la matriz de confusión mediante `test.errorMatrix(classProperty, 'classification')` (Figura 18), donde se contrastan las capas reales (`classProperty`, es decir, 'landcover') con las capas simuladas ('classification'). Esta matriz muestra, para cada clase, cuántos píxeles fueron correctamente clasificados y cuántos fueron confundidos con otras capas. A partir de esta matriz, es posible derivar métricas clave, como la precisión global (porcentaje de aciertos totales), la precisión por clase (porcentaje de aciertos por categoría), y otras medidas como el índice kappa, que ayudan a entender la robustez del modelo.

Este procedimiento ayuda a medir el rendimiento del clasificador de forma clara, y a encontrar errores específicos, como la confusión entre vegetación y suelo desnudo, que puede suceder en ciertos contextos espectrales.

```

Clasificación_Cuajimalpa_2009 *
69 // Realizar una evaluación de la precisión.
70 // Al agregar una columna de valores aleatorios uniformes al conjunto de datos de entren
71 var withRandom = training.randomColumn('random');
72
73 // Reservar parte de los datos para pruebas, para evitar el sobreajuste del modelo.
74 var split = 0.7; // Aproximadamente 70% para entrenamiento, 30% para pruebas.
75 var trainingPartition = withRandom.filter(ee.Filter.lt('random', split));
76 var testingPartition = withRandom.filter(ee.Filter.gte('random', split));
77
78 // Entrenar con el 70% de los datos.
79 var trainedClassifier = ee.Classifier.smileRandomForest(5).train({
80   features: trainingPartition,
81   classProperty: classProperty,
82   inputProperties: bands
83 });
84
85 // Clasificar el FeatureCollection de prueba.
86 var test = testingPartition.classify(trainedClassifier);
87
88 // Imprimir una matriz de confusión.
89 var confusionMatrix = test.errorMatrix(classProperty, 'classification');
90 print('Confusion Matrix', confusionMatrix);
  
```

Inspector Console Tasks

Use print(...) to write to this console.

- ImageCollection LANDSAT/LE07/C... JSON
- Image (9 bands) JSON
- CART, explained JSON
- Object (5 properties) JSON
- Confusion Matrix JSON
- [[25,2,1,0],[6,58,0,3],[3,2,2,...] JSON
- 0: [25,2,1,0]
- 1: [6,58,0,3]
- 2: [3,2,2,0]
- 3: [5,4,0,65]

Figura 18. Ejemplo de evaluación del clasificador mediante partición aleatoria y matriz de confusión para el año 2009. Fuente: elaboración propia.

9. Exportación de resultados

Una vez que se ha generado la imagen clasificada, esta puede ser exportada a Google Drive mediante la función `Export.image.toDrive()`. En este caso, se exporta la imagen `classified`, asignándole un nombre a la tarea ('Clasificación_Cuajimalpa'), un nombre al archivo de salida ('Clasificación_Cuajimalpa_2009'), y se indica que se guardará en la carpeta 'GEE_exports' dentro del Drive. La región que se exporta corresponde al polígono Cuajimalpa, y se establece una resolución de 30 metros por píxel, adecuada para imágenes Landsat 7 o una resolución de 10 metros por píxel, adecuada para imágenes Sentinel-2. Para evitar errores por tamaño, se fija un límite amplio de píxeles ($1e13$), y el sistema de coordenadas utilizado es 'EPSG:4326', compatible con la mayoría de los programas GIS.

Después de ejecutar el script, es importante ir al panel lateral llamado Tasks dentro del editor de gee. Ahí aparecerá una tarea con el estado *Unsubmitted tasks*, la cual debe activarse manualmente dando clic en *Run*. Al hacerlo, se iniciará la exportación, y el archivo generado se guardará automáticamente en la cuenta de Google Drive, en la ubicación especificada. La imagen generada será un archivo de extensión de archivo .tiff, que es una extensión del formato TIFF que permite la georreferenciación y geocodificación de imágenes ráster (Figura 19).

Además, se exporta también la composición RGB, que nos servirá como comparación y para un análisis mayor en un programa GIS. El script de exportación es similar, solo que se sustituyen los parámetros para la imagen RGB (Figura 20).




Figura 19. Ejemplo de exportación de imagen clasificada para el año 2009. Fuente: elaboración propia.



Figura 20. Ejemplo de exportación de imagen de composición RGB para el año 2009. Fuente: elaboración propia.

Resultados

A continuación, presentamos los mapas obtenidos para cada año, utilizando una clasificación supervisada.

A lo largo del periodo analizado, los mapas de clasificación supervisada revelan una transformación progresiva en la cobertura de suelo de la Alcaldía Cuajimalpa. En el año 2009, el paisaje estaba dominado por vegetación, con áreas urbanas apenas delineadas en el norte, y algunas zonas aisladas al centro. Sin embargo, a medida que avanzan los años, se evidencia un crecimiento constante del suelo urbano, sobre todo entre 2013 y 2021, con una notable consolidación hacia 2025.

Este crecimiento no se da de manera aleatoria. La expansión ocurre principalmente sobre áreas de suelo desnudo, lo que sugiere una planificación permisiva o incluso una posible modificación de usos de suelo. La vegetación permanece como la cobertura predominante, pero su superficie se ve reducida ante la presión inmobiliaria. La constancia del patrón urbano creciente, y el

desplazamiento hacia zonas de conservación, plantean interrogantes sobre la sostenibilidad territorial y el equilibrio ecológico de la zona.

Aunque el agua no sufre cambios drásticos, su estabilidad contrasta con el dinamismo de los otros usos. En conjunto, estos mapas configuran un escenario donde el capital inmobiliario ha encontrado espacio de expansión en uno de los territorios ecológicamente más valiosos de la CDMX. Este resultado confirma la hipótesis de una lógica de ocupación orientada más por criterios de rentabilidad que por un enfoque de preservación ambiental (Figuras 21, 22, 23, 24 y 25).




Figura 21. Mapa de clasificación supervisada, Alcaldía Cuajimalpa de Morelos, año 2009.
Fuente: elaboración propia.




Figura 22. Mapa de clasificación supervisada, Alcaldía Cuajimalpa de Morelos, año 2013.
Fuente: elaboración propia.




Figura 23. Mapa de clasificación supervisada, Alcaldía Cuajimalpa de Morelos, año 2017.
Fuente: elaboración propia.




Figura 24. Mapa de clasificación supervisada, Alcaldía Cuajimalpa de Morelos, año 2021.

Fuente: elaboración propia.




Figura 25. Mapa de clasificación supervisada, Alcaldía Cuajimalpa de Morelos, año 2025.

Fuente: elaboración propia.

Conclusiones

Para el caso de la Alcaldía Cuajimalpa, en el que analizamos el avance de la cobertura urbana de 2009 a 2025 utilizando clasificación supervisada en gee, esperábamos que este se presentara sobre suelo con cobertura vegetal, pero, en un primer análisis de los mapas generados, podemos identificar que el avance de suelo urbano ha ocurrido en su mayoría, sobre cobertura de suelo desnudo y muy poco sobre cobertura vegetal. Esto podría ser un indicador de cambios de uso de suelo por parte de las autoridades para favorecer la inversión inmobiliaria; pero, como comentamos en párrafos anteriores, esta es una premisa que requiere de un análisis más profundo, que realizaremos más adelante.

Este hallazgo es relevante, ya que nos confirma que los procesos de financiarización no se plasman homogéneamente sobre el territorio, y que su traducción espacial depende de diversos actores, como lo son los intermediarios financieros, las empresas inmobiliarias, las autoridades y los ciudadanos.

Como se planteó en la introducción de este capítulo, el objetivo central de este ejercicio es demostrar las capacidades de gee para identificar coberturas y usos de suelo en zonas determinadas de la superficie terrestre, utilizando clasificación supervisada de imágenes satelitales de colecciones de LandSat y Sentinel. La investigación aquí contenida forma parte de un proyecto que abarca otras Alcaldías de CDMX, y que considera factores adicionales como uso de suelo y clasificación entre diferentes tipos de suelo urbano. Para este ejercicio, presentamos una clasificación supervisada, de diferentes coberturas de la Alcaldía Cuajimalpa de Morelos, para identificar el avance de la cobertura de suelo urbano entre 2009 y 2025, utilizando imágenes satelitales. Para ello, generamos un código en JavaScript, que contiene un clasificador CART, identificando 602 puntos de las cuatro coberturas que se utilizaron para entrenar y evaluar al clasificador en una proporción 70/30, generando mapas clasificados, para finalmente exportarlos a un ambiente GIS, utilizando google drive. Incluimos el detalle del proceso utilizado, con el objetivo de que este ejercicio pudiera ser replicado para investigaciones futuras.

Referencias

- Aalbers, M. (2009). Geographies of the financial crisis [versión electrónica]. *Area*, 41(1), 34–42. Royal Geographical Society.
- Clark, G. (2005). Money flows like mercury [versión electrónica]. *Geografiska Annaler*, 87(2), 99–112. Swedish Society for Anthropology and Geography.
- Engelen, E., Fernández, R., y Hendrikse, R. (2014). How Finance Penetrates its Other: A Cautionary Tale on the Financialization of a Dutch University [versión electrónica]. *Antipode*, 46(4), 1072–1091.
- Google Earth Engine (gee). (2025a). <https://earthengine.google.com>
- Google Earth Engine (gee). (2025b). code.earthengine.google.com

- Halbert, L., y Attuyer, K. (2016). Introduction: The financialization of urban production: conditions, mediations and transformations. *Urban Studies*, 1–15.
- Instituto Nacional de Estadística y Geografía (INEGI). (2025). Marco Geoestadístico. <https://www.inegi.org.mx/temas/mg/>
- Leyshon, A., y Thrift, N. (2007). The Capitalization of Almost Everything. The Future of Finance and Capitalism. *Theory, Culture & Society*, 24(7–8), 97–115. <https://doi.org/10.1177/026327647084699>
- Maples, S. (2021). Google Earth Engine 101: An Introduction for Complete Beginners. Stanford Geospatial Center. www.youtube.com/@stanfordgeospatialcenter3079
- United Nations General Assembly (UNGA). (2017). Report on the Special Rapporteur on housing as a component to the right of an adequate standard of living, and the right to non discrimination in this context. Human Rights Council, A/HRC/34/51, agenda item 3. <https://docs.un.org/en/A/HRC/34/51>

Capítulo XV. Detección de fugas en la red primaria de la Ciudad de México a través de puntos de presión. Procesamiento de datos hidráulicos mediante análisis con Python

Ana Laura Castillo Hernández¹

Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura (ESIA),

Unidad Tecamachalco. Naucalpan, Estado de México.

Resumen

La Ciudad de México hoy en día presenta pérdidas significativas en la red hidráulica. Aproximadamente el 40% del agua se pierde a causa de fugas en la red, yéndose en su mayoría por el drenaje a consecuencia de una infraestructura deteriorada. Es por ello que el presente capítulo busca detectar fugas a través del histórico de presiones en el año 2022 mediante herramientas de programación como Python, empleando bibliotecas para manipulación de base de datos, organización, así como análisis estadístico en cada punto de presión (pandas) y para la visualización de resultados (matplotlib). Se estudió la evolución de la presión en 81 puntos para detectar patrones habituales y comportamientos anómalos que pudieran relacionarse con fugas, y así generar la clasificación de qué es fuga y qué no, arrojando gráficas únicas para cada punto de presión con escenarios de caídas constantes durante todo un año, o solo por periodos de un mes.

Palabras clave: infraestructura hidráulica, detección de fugas, programación.

Abstract

Mexico City currently experiences significant losses in its water network. Approximately 40% of water is lost due to leaks in the network, most of which is lost through drainage due to deteriorated infrastructure. Therefore, this chapter seeks to detect leaks through historical pressures in 2022 using programming tools such as Python, employing libraries for database manipulation, organization, and statistical analysis at each pressure point (Pandas) and for results visualization (Matplotlib). The evolution of pressure at 81 points was studied to detect common patterns and anomalous behaviors that could be related to leaks. This is a preliminary step that will allow the future implementation of more advanced hydraulic models for the detection and location of leaks in the primary network, useful for improving water management.

Palabras clave: hydraulic infrastructure, leak detection, programming.

Introducción

El agua ha sido un tema complejo, especialmente en el ámbito urbano, donde influyen múltiples factores dificultando su gestión. La sobreexplotación

¹ Candidata a Maestra en Ciencias en Arquitectura y Urbanismo, Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura, ESIA, Unidad Tecamachalco. Correo: acastillohernandez33@gmail.com, ORCID: <https://orcid.org/0000-0001-9366-1956>

de recursos hídricos se intensifica con el crecimiento acelerado de las ciudades, así como por el cambio climático. Bajo esta premisa se ha buscado garantizar el acceso equitativo; sin embargo, el agua requiere diferentes enfoques (no solo desde lo tradicional), como lo son las inspecciones físicas en la red, las lecturas manuales, los reportes ciudadanos y la gestión basada en experiencia técnica. Dichos enfoques, si bien han sido útiles pero suelen ser limitados, también pueden ir de la mano de herramientas tecnológicas que permitan comprender fenómenos complejos en menor tiempo, pero con una cantidad robusta de datos en la red hidráulica.




Figura 1. Acuíferos con disponibilidad, 2021 y 2022. Fuente: CONAGUA, 2023.

Una forma de expresar la problemática actual a nivel nacional es a través del estrés hídrico que vive el país, dada la sobreexplotación de acuíferos, donde hasta el año 2022 solo 378 acuíferos tenían disponibilidad de los 653. Las zonas más afectadas son hacia norte y centro del país (ver Figura 1). Por otra parte, aunque las cuencas hidrológicas son terrenos naturales en donde se acumula agua de lluvia (SEMARNAT, 2018), solo en 69 de 757 cuencas hidrológicas el caudal otorgado es mayor que del agua renovable (CONAGUA, 2023).

Esta situación no solo afecta el equilibrio ecológico, sino también a la infraestructura hidráulica, debido a que los aumentos de demandas y variación de presiones, aunados a la antigüedad de la red, generan deterioro físico, provocando fracturas y por ende fugas. Un ejemplo de ello, es que en zonas urbanas existen pérdidas de agua en las tuberías hasta del 40% (CONAGUA, 2020). Donde, comparando el porcentaje de agua no contabilizada del 2003

hasta el 2013, se puede observar un incremento de 10% aproximadamente (ver Tabla 1).

Tabla 1. Proporción de agua no contabilizada

País	Documentos
India	8
United Kingdom	8
Canada	7

Fuente: elaboración propia con base en CONAGUA, 2020.

La Ciudad de México (CDMX) ha enfrentado un deterioro considerable. Según el Sistema de Aguas de la Ciudad de México (SACMEX) las fugas han aumentado un 27.1% en el periodo 2020 al 2023; en otras palabras, de 8,878 reportes, la cantidad aumentó a 11,288, resultando un desafío para las autoridades (Grupo Incotex, 2024), a pesar de que se ha implementado una plataforma digital donde se pueden observar en tiempo real algunos datos de la red primaria como: producción total de agua potable, pozos, rebombeos, sectorización, entre otros (para lo que se utiliza información transmitida en tiempo real mediante macro medidores en la red). Al revisar cada parte que conforma esta plataforma, se pueden visualizar gráficas e históricos, así como infraestructura que se encuentra fuera de servicio, en mantenimiento o sin información. Esta última condición predomina en toda la red.


Se plantea como objetivo la implementación de detección de fugas en históricos de presión en la red primaria, mediante herramientas de programación, ya que el estudio de al menos un año contiene una base de datos robusta que por métodos convencionales no es posible analizar; y en la propia plataforma, por su parte, aún no se ha desarrollado un área donde se detecten en tiempo real posibles fugas, necesidad que se ha vuelto crítica e importante debido al contexto actual del agua en la CDMX. Bajo esta condición, un análisis automatizado mediante programación de las bases de datos no solo representa un avance, sino una necesidad de estrategia para una mejora en el mantenimiento preventivo de la red hidráulica.

La detección de fugas en una red hidráulica ha evolucionado con el uso de nuevas herramientas computacionales y modelos matemáticos. Actualmente, los métodos tradicionales han sido complementados o sustituidos por programación y análisis de datos, por ejemplo métodos de modelado numérico, los cuales identifican posibles áreas de fugas comparándolas con resultados de simulación y datos en campo; también modelos hidráulicos tradicionales utilizando datos en condiciones estables o ideales (Li, et al., 2015). Para poder llegar a esta parte, es importante recalcar que las bases de datos y simulaciones previamente deben ser depuradas y clasificadas para crear los escenarios; lo que a continuación se desarrollará.

Metodología

El presente estudio se desarrolló con un enfoque cuantitativo basado en tecnologías, de las cuales destacan sensores de presión en la red hidráulica urbana enviando información de la mano de sistemas SCADA (Supervisory Control and Data Acquisition), que observan y envían datos en tiempo real, para controlar procesos (Pérez, 2015) como el comportamiento del agua en las tuberías para detectar fugas en la red primaria con análisis computacional de datos hidráulicos, y los históricos de presión. Esta metodología combina análisis estadístico y programación para interpretar la base de datos en el año 2022, como lo hace Laucelli, et al. (2016) donde identifica, mediante gráficas, los comportamientos semanales basándose en datos históricos arrojados por sensores de presión.

Como primer paso, se obtuvo la base de datos del histórico de presión de la red primaria de la Ciudad de México del año 2022, a través del SACMEX, en un oficio dirigido a la Dirección Ejecutiva de Gestión Operativa y Eficiencia. La base de datos contiene fecha, hora y puntos de presión, los cuales fueron organizados y depurados mediante bibliotecas de Python: Pandas y Matplotlib. Pandas —esta es una biblioteca diseñada para la manipulación y análisis de datos— (DataScientest, 2024). Gracias a esta herramienta es que se puede cargar, manipular y depurar una base de datos, ya sea en formato .csv o .xlsx. Aunque, para este caso, se utilizó el primer formato por la cantidad de datos a manipular. En la Figura 2 se observa el paso que se refiere a importar pandas y carga del archivo. Para leer las primeras filas, se ocupa el comando `df.head()`.



```
[1]: import pandas as pd

[9]: #Cargar el archivo
ruta_archivo = "datos_presion.xlsx"
df = pd.read_excel("C:/Users/acast/Documents/MAESTRIA INSCRIPCION/CUARTO/BD_PPRESION/datos_presion.xlsx")
#Mostrar primeras filas
df.head()
```

	Fecha	Hora	PP01_ACANTILADO	PP02_VENUS	PP03_LAESCALERA	PP04_TICOMAN	PP05_CENTENARIO	PP06_CALLE325	PP07_EJE4NORTE	PP08_NORTE35
0	01/01/2022	00:00:00	0.3	0.39	0.3	0.315	NaN	0.4	0.648333	NaN
1	01/01/2022	00:15:00	0.3	0.39	0.3	0.315	NaN	0.4	0.655000	NaN
2	01/01/2022	00:30:00	0.3	0.39	0.3	0.315	NaN	0.4	0.665000	NaN
3	01/01/2022	00:45:00	0.3	0.39	0.3	0.315	NaN	0.4	0.675000	NaN
4	01/01/2022	01:00:00	0.3	0.39	0.3	0.315	NaN	0.4	0.685000	NaN

5 rows x 83 columns

Figura 2. Carga de documento Excel en Python mediante pandas. Fuente: elaboración propia con base en datos extraídos de histórico de presión SACMEX (2023).

Como se puede observar, las columnas fecha y hora están separadas. Estas se van a unir para poder trabajar en Python, con la finalidad de que el programa pueda ocupar la información; de lo contrario, arrojará error al querer generar gráficos y aplicar estadística. También, en los datos se aprecia que las unidades por cada punto de presión son en kg/cm²; sin embargo, estos deben convertirse a bares, como lo trabaja Lobos (2022), por ser la unidad estándar

para área industrial o en temas científicos. Por otra parte, si se quieren aplicar posteriormente a un modelo hidráulico en programas como EPANET, WaterGems, SCADA entre otros, los datos se trabajan con la unidad de bares (ba). En la Figura 3, con ayuda de pandas se unificaron las celdas fecha y hora, para crear una nueva columna *datetime* llamada 'Tiempo', que con *.astype* convierte datos de una o más columnas. Para unir las dos columnas se utiliza *pd.to_datetime()* y *errors='coerce'*. De este modo, se transforma el valor que sea inválido en nuestras celdas. En este caso se arrojaron 21,220 valores nulos, los cuales se verifican para saber si hay celdas vacías mediante *print(df[['Fecha', 'Hora']].isnull().sum())*. Sin embargo, no fue el caso; entonces el problema era que los formatos eran incorrectos. Por ello se revisan formatos únicos.

```
# Convertir 'Fecha' y 'Hora' en un solo campo de tipo datetime
df['Fecha'] = df['Fecha'].astype(str)
df['Hora'] = df['Hora'].astype(str)

df['Tiempo'] = pd.to_datetime(df['Fecha'] + ' ' + df['Hora'], errors='coerce')

print(df['Tiempo'].isnull().sum())

# Salida:
# 21220

print(df[['Fecha', 'Hora']].isnull().sum())

# Salida:
# Fecha    0
# Hora      0
# dtype: int64

# Revisar formatos únicos en 'Fecha' y 'Hora'
print("Formatos únicos en Fecha:")
print(df['Fecha'].unique()[:10]) # Mostrar solo los primeros 10 valores únicos

print("\nFormatos únicos en Hora:")
print(df['Hora'].unique()[:10]) # Mostrar solo los primeros 10 valores únicos

# Salida:
# Formatos únicos en Fecha:
# ['01/01/2022' '02/01/2022' '03/01/2022' '04/01/2022' '05/01/2022'
#  '06/01/2022' '07/01/2022' '08/01/2022' '09/01/2022' '10/01/2022']

# Formatos únicos en Hora:
# ['00:00:00' '00:30:00' '00:45:00' '01:00:00' '01:15:00'
#  '01:30:00' '01:45:00' '02:00:00' '02:15:00']
```

Figura 3. Creación de nueva columna. Fuente: elaboración propia.

Ahora se convierte el formato de la columna 'Fecha' "%d/%m/%Y" → Día/Mes/Año, como ocurre en el ejemplo 01/01/2020. Esto ocurre porque originalmente se trabaja en formato texto; entonces debe convertirse a fecha y hora, para que Python pueda reconocerlo y hacer análisis temporales con los datos de la fecha, ya sea por meses, semanas o por días. Todo esto es posible con `pd.to_datetime` y el código `format="%d/%m/%Y"`. Para comprobar esto, nuevamente se revisan los valores nulos, esta vez arrojando cero, lo que significa que el formato de la celda es correcto (Figura 4).

```
# Intentar convertir Fecha a datetime
df['Fecha'] = pd.to_datetime(df['Fecha'], format="%d/%m/%Y", errors="coerce")

# Revisar si hay valores nulos después de la conversión
print("Valores nulos en Fecha después de la conversión:", df['Fecha'].isnull().sum())

# Mostrar algunos valores de Fecha para verificar la conversión
print(df['Fecha'].head(10))

Valores nulos en Fecha después de la conversión: 0
0    2022-01-01
1    2022-01-01
2    2022-01-01
3    2022-01-01
4    2022-01-01
5    2022-01-01
6    2022-01-01
7    2022-01-01
8    2022-01-01
9    2022-01-01
Name: Fecha, dtype: datetime64[ns]
```

Figura 4. Conversión de columna 'Fecha'. Fuente: elaboración propia.

El proceso se repite para 'Hora' nuevamente con `.astype`, eliminando espacios, luego se concatena una nueva columna llamada 'Tiempo' integrando `errors='coerce'`, y revisando los valores nulos. En este caso arrojó cero después de la conversión. Posteriormente, se pide al programa muestre las primeras 10 filas de forma aleatoria de la nueva columna. Finalmente se eliminan las columnas 'Fecha' y 'Hora' (Figuras 5 y 6).

```
# Mostrar 10 filas aleatorias con la columna 'Tiempo'
print(df[['Tiempo']].sample(10))
Tiempo
6098 2022-03-05 12:30:00
28039 2022-09-02 02:45:00
21945 2022-08-17 11:55:00
8671 2022-04-01 07:45:00
34408 2022-11-25 20:30:00
28454 2022-10-24 10:30:00
215 2022-01-01 05:45:00
30977 2022-11-16 11:30:00
26246 2022-10-01 10:30:00
31493 2022-11-25 01:15:00
```

Figura 5. Conversión de columna 'Hora'. Fuente: elaboración propia.

```
# Convertir la columna 'Hora' a string y eliminar espacios en blanco ocultos
df['Hora'] = df['Hora'].astype(str).str.strip()

# Concatenar Fecha y Hora para formar la columna 'Tiempo'
df['Tiempo'] = pd.to_datetime(df['Fecha'].astype(str) + ' ' + df['Hora'], errors='coerce')

# Revisar cuántos valores nulos hay en 'Tiempo'
print("Valores nulos en Tiempo después de la conversión:", df['Tiempo'].isnull().sum())

# Mostrar algunas filas con error
errores = df[df['Tiempo'].isnull()]
print("Ejemplo de filas con error:")
print(errores[['Fecha', 'Hora']].head(20))

Valores nulos en Tiempo después de la conversión: 0
Ejemplo de filas con error:
Empty DataFrame
Columns: [Fecha, Hora]
Index: []
```

Figura 6. Conversión de columna 'Hora' (continuación). Fuente: elaboración propia.

Conversión de unidades en presión

Pandas seguirá siendo base para poder manipular y convertir datos en esta parte, pero antes se modificará la estructura de la tabla a formato largo (Kd Nuggets, 2023), como se había mencionado antes, con el cambio de unidades de presión, originalmente en kg/cm², que es una unidad correcta. Sin embargo, para la manipulación de información es necesario convertirla en bares mediante `df_largo=df.melt`, tomando el siguiente orden: 'Tiempo', 'Puntos de Presión' y 'Presión' (Figura 7). A continuación, se procede a convertir las unidades de esta última columna con base en la siguiente ecuación:

$$1 \frac{kg}{cm^2} = 0.980665 \text{ bar}$$

```
# Se procede a convertir el formato de la tabla
import pandas as pd

# Suponemos que la primera columna es "Tiempo" y las demás son puntos de
# presión
columnas_presion = df.columns[1:] # Excluye la columna "Tiempo"

# Convertir de formato ancho a largo
df_largo = df.melt(id_vars=["Tiempo"], var_name="Punto de Presión",
value_name="Presión (kg/cm²)")

# Convertir las presiones de kg/cm² a bar
df_largo["Presión (bar)"] = df_largo["Presión (kg/cm²)"] * 0.980665

# Verificar la conversión con algunas filas
print(df_largo.head(10))
```

	Tiempo	Punto de Presión	Presión (kg/cm²)	Presión (bar)
0	2022-01-01 00:00:00	PP01_ACANTILADO	0.3	0.2942
1	2022-01-01 00:15:00	PP01_ACANTILADO	0.3	0.2942
2	2022-01-01 00:30:00	PP01_ACANTILADO	0.3	0.2942
3	2022-01-01 00:45:00	PP01_ACANTILADO	0.3	0.2942
4	2022-01-01 01:00:00	PP01_ACANTILADO	0.3	0.2942
5	2022-01-01 01:15:00	PP01_ACANTILADO	0.3	0.2942
6	2022-01-01 01:30:00	PP01_ACANTILADO	0.3	0.2942
7	2022-01-01 01:45:00	PP01_ACANTILADO	0.3	0.2942
8	2022-01-01 02:00:00	PP01_ACANTILADO	0.3	0.2942
9	2022-01-01 02:15:00	PP01_ACANTILADO	0.3	0.2942

Figura 7. Conversión de formato de tabla. Fuente: elaboración propia.

Es importante destacar que, cuando se guarda la última modificación del archivo, esta arroja un error debido a que el archivo Excel sobrepasó el número de celdas a trabajar; por lo tanto, se convierte a formato .csv, y se repite el proceso para no marcar error en el documento (Figura 8).

```
File ~\anaconda3\Lib\site-packages\pandas\io\formats\excel.py:932, in
ExcelFormatter.write(self, writer, engine, storage_options, engine_kwargs)

    930 num_rows, num_cols = self.df.shape
    931 if num_rows > self.max_rows or num_cols > self.max_cols:
--> 932     raise ValueError(
    933         f"This sheet is too large! Your sheet size is: {num_rows},
{num_cols} "
    934         f"Max sheet size is: {self.max_rows}, {self.max_cols}"
    935     )
ValueError: This sheet is too large! Your sheet size is: 2838240, 4 Max sheet
size is: 1048576, 16384

df.to_csv("datos_presion_convertida.csv", index=False)
```

Figura 8. Conversión de formato a CSV. Fuente: elaboración propia.

Análisis estadístico

Al haber guardado el formato .csv, se repite el paso anterior de conversión y se guardan los cambios (Figura 9). Posteriormente, se procede a agrupar los datos por cada 'Punto de Presión' con estadísticas = `df_largo.groupby` (Pandas, 2024), como se puede ver en la Figura 10. Este código *group by* sirve para:

- Dividir datos en grupos, tomando uno o más nombres de columnas como argumento (Growup, 2023).

- Combinar resultados en una estructura de datos, con base a los datos originales. Después de dividir, se realiza una nueva combinación para dar nuevos resultados, como lo sería un análisis estadístico, desembocando en el cálculo de una o más estadísticas para cada grupo, necesarias para hacer series de tiempo para examinar el comportamiento de presiones.

```
# Convertir de formato ancho a formato largo
df_largo = df.melt(id_vars=["Tiempo"], var_name="Punto de Presión", value_name="Presión (kg/cm²)")

# Ver las primeras filas para comprobar la conversión
print(df_largo.head())

# Convertir kg/cm² a bar
df_largo["Presión (bar)"] = df_largo["Presión (kg/cm²)"] * 0.980665

# Verificar la conversión
print(df_largo.head())
```

	Tiempo	Punto de Presión (kg/cm²)	Presión (bar)	
0	2022-01-01 00:00:00	PP01_ACANTILADO	0.3	0.2942
1	2022-01-01 00:15:00	PP01_ACANTILADO	0.3	0.2942
2	2022-01-01 00:30:00	PP01_ACANTILADO	0.3	0.2942
3	2022-01-01 00:45:00	PP01_ACANTILADO	0.3	0.2942
4	2022-01-01 01:00:00	PP01_ACANTILADO	0.3	0.2942

```
# Rellenar valores nulos con 0 en la columna de presión en bar
df_largo["Presión (bar)"].fillna(0, inplace=True)

# Guardar como archivo CSV
df_largo.to_csv("datos_presion_convertidos.csv", index=False)
```

Figura 9. Conversión de unidades. Fuente: elaboración propia.

El proceso arrojó *count*, que hace referencia a la cantidad de datos que hay en promedio de presión, desviación estándar y porcentajes (Figura 8 y 9). Esto permite analizar de manera sistemática el comportamiento de la presión del agua.

```
[53]: # Analisis estadístico general
import pandas as pd
# Agrupar por punto de presión y calcular estadísticas
estadísticas = df_largo.groupby("Punto de Presión")["Presión (bar)"].describe()

# Mostrar en Jupyter Notebook
display(estadísticas) # Si usas Jupyter, esto mostrará una tabla
```

	count	mean	std	min	25%	50%	75%	max
Punto de Presión								
PP01_ACANTILADO	35040.0	0.702733	0.833959	0.0	0.294200	0.294200	0.487064	4.851023
PP02_VENUS	35040.0	0.692875	0.456155	0.0	0.402073	0.454375	0.882598	2.383016
PP03_LAESCALERA	35040.0	0.519867	0.449501	0.0	0.294200	0.294200	0.451106	1.980943
PP04_TICOMAN	35040.0	0.633059	0.597814	0.0	0.308909	0.308909	0.541000	2.476179
PP05_CENTENARIO	35040.0	0.162843	0.144703	0.0	0.000000	0.186326	0.274586	2.242454
...	...	...	...	...	...	...	...	...
PP77_AMORES	35040.0	0.798992	0.679655	0.0	0.294200	0.323619	1.425233	5.720546
PP78_MOLINOS	35040.0	2.076738	0.579854	0.0	1.725970	2.088816	2.461469	3.713452
PP79_UNIVERSIDAD	35040.0	0.496446	0.310036	0.0	0.279490	0.338329	0.720789	2.518675
PP80_DMADRIGAL	35040.0	0.844511	0.675201	0.0	0.215746	0.712617	1.356587	2.785089
PP81_PADIERNA	35040.0	1.746347	0.352367	0.0	1.735777	1.810961	1.886146	2.320907

Figura 10. Análisis estadístico. Fuente: elaboración propia.

```
[57]: #Detectar puntos con mayor variabilidad
# Ordenar puntos de presión por desviación estándar (mayor variabilidad primero)
variabilidad = estadísticas[['std']].sort_values(by="std", ascending=False)

# Mostrar tabla en Jupyter Notebook
display(variabilidad) # Si usas Jupyter Notebook
```

	std
Punto de Presión	
PP62_CÍAB	1.303204
PP61_OSENTIES	1.032571
PP51_DAVINCI	0.989887
PP52_AURRAZA	0.964804
PP66_NAUTLA	0.919269
...	...
PP05_CENTENARIO	0.144703
PP28_GCANAL	0.132747
PP46_SANTIAGO	0.104039
PP13_TALISMAN	0.097718
PP74_AJUAREZ	0.067899

81 rows x 1 columns

Figura 11. Análisis de mayor variabilidad. Fuente: elaboración propia.

Creación de gráficos

A partir de “matplotlib”, el cual es una biblioteca que se caracteriza por creación de gráficos desde histogramas, gráfica de barras, dispersión de puntos, etc. (Aprende con Alf, 2020), se facilita para este caso la creación de gráficas de series temporales de presión que involucran al factor tiempo —que abarca días y semanas—, fundamental para el análisis de comportamiento en la red primaria

de la CDMX. Como primer paso se extraen las variables a trabajar: 'Tiempo' > 'Horas del día', para calcular las presiones promedio por hora (Figura 13), dando como resultado, en la Figura 12, un aumento progresivo en las primeras horas del día, donde se alcanzó un punto máximo a las 9:00 am, seguido de una disminución constante durante el resto del día.

Para explicar el proceso de la Figura 13, el código `df_largo["Hora del día"]=df_largo["Tiempo"].dt.hour` se usa con el propósito de extraer cada registro para la columna 'Tiempo', guardando el resultado en una nueva columna llamada 'Horas del día'. El promedio se aplica con `promedio_por_hora=df_largo.groupby("Hora del día")["Presión (bar)"].mean()`. El resultado de esto es el valor de presión promedio para cada hora del día. Finalmente, para la creación del gráfico se utiliza `plt.figure(figsize=(10,5))` para crear la figura de un tamaño en específico, o sea 10 unidades de ancho por 5 de alto. Para darle estructura en el eje XY se le asignan valores de horas y presiones promedio.




Figura 12. Extracción de horas día. Fuente: elaboración propia.

```
import matplotlib.pyplot as plt

# Extraer la hora del día
df_largo["Hora del día"] = df_largo["Tiempo"].dt.hour

# Calcular la presión promedio por hora
promedio_por_hora = df_largo.groupby("Hora del día")["Presión (bar)"].mean()

# Graficar la presión promedio por hora
plt.figure(figsize=(10,5))
plt.plot(promedio_por_hora.index, promedio_por_hora.values, marker="o", linestyle="-")
plt.xlabel("Hora del día")
plt.ylabel("Presión promedio (bar)")
plt.title("Presión promedio a lo largo del día")
plt.grid()
plt.show()
```

Figura 13. Gráfica presión promedio a la largo del día. Fuente: elaboración propia.

Análisis promedio por día de la semana

Se hace en específico un análisis por día, donde se extrae cada día de la semana, dando el valor 0 al lunes, y el valor 6 al domingo (Figura 15). La presión fue calculada por agrupamiento, y los resultados se visualizaron en el gráfico de barras, donde se muestran ligeramente presiones más altas los viernes y domingos, mientras las más bajas aparecen los jueves (Figura 14).

Estos resultados preliminares en la gráfica arrojaron variaciones de demanda de agua, lo cual pueden ser indicativo de un comportamiento atípico o tendencias recurrentes en la red hidráulica. Se observan ligeras variaciones en diferentes días de la semana, donde el lunes tiene la presión más alta, mientras la más baja el jueves. Estas diferencias se pueden deber a diversos factores como lo son la demanda de agua normal por parte del usuario en días en específico, las intervenciones técnicas a la red, así como las fallas en la tubería por antigüedad. Llegar a esta conclusión no solo se efectúa por experiencia del técnico operador o un ingeniero, sino por el conocimiento de trabajos de intervención.

Detrás del gráfico, para su generación se extraen los datos de la semana y el cálculo de presiones por día de la semana, señalando las unidades en bares. Una vez descrita la indicación en el entorno de Python, se da la instrucción del tamaño que se quiere, `plt.figsize=(10,5)`, y los datos se muestran en los ejes XY, donde en X están los días de la semana, mientras en Y se presenta la presión promedio (Figura 15).




Figura 14. Extracción de información por días de la semana. Fuente: elaboración propia.

```
# Extraer el día de la semana (0 = Lunes, 6 = domingo)
df_largo["Día de la Semana"] = df_largo["Tiempo"].dt.dayofweek

# Calcular presión promedio por día de la semana
promedio_por_dia = df_largo.groupby("Día de la Semana")["Presión (bar)"].mean()

# Graficar
plt.figure(figsize=(10,5))
plt.bar(promedio_por_dia.index, promedio_por_dia.values)
plt.xticks(ticks=range(7), labels=["Lun", "Mar", "Mié", "Jue", "Vie", "Sáb", "Dom"])
plt.xlabel("Día de la Semana")
plt.ylabel("Presión Promedio (bar)")
plt.title("Presión promedio por día de la semana")
plt.grid()
plt.show()
```

Figura 15. Gráfica presión promedio por día de la semana. Fuente: elaboración propia.

Detección de fugas

Finalmente, se hizo una detección de fugas con los datos anteriores mediante *numpy*, que es una biblioteca fundamental en Python, utilizada para análisis de datos, machine learning y para realizar cálculos matemáticos (DataScientest, 2025), así como manejo de grandes volúmenes de datos (como es este el caso). Otra ventaja de Numpy son las amplias funciones de estadísticas; por esa razón no se usa de forma directa, sino que funciona de la mano con pandas, matplotlib y Tensor Flow.

En este apartado se comienza utilizando Numpy para la detección de fugas, dando la instrucción de una nueva columna para almacenar las sentencias de “Sí” o “No” es fuga, para aplicar la detección con *for punto in df_largo[“Punto de Presión”].unique()*. Esto se realiza para analizar individualmente cada punto, y la función *unique* es para obtener la lista de todos los puntos de presión en una columna con el mismo nombre. Al umbral de la fuga se le toma el 70% de la mediana de la presión, bajo la premisa de que si la presión cae por debajo de este valor podría considerarse como una fuga; dando como resultado 466,576 fugas en todos los puntos de presión que fueron graficados (Figura 16).

```

# Detectar fugas automáticamente en todos los puntos
import numpy as np

# Crear una nueva columna para almacenar si es fuga o no
df_largo["Fuga"] = "No"

# Aplicar detección de fugas a cada punto de presión
for punto in df_largo["Punto de Presión"].unique():
    df_punto = df_largo[df_largo["Punto de Presión"] == punto]

    # Definir umbral de fuga (ejemplo: presión menor al 30% del valor mediano de ese punto)
    umbral_fuga = df_punto["Presión (bar)"].median() * 0.7 # Puedes ajustar este porcentaje

    # Etiquetar como fuga si la presión está por debajo del umbral
    df_largo.loc[
        (df_largo["Punto de Presión"] == punto) &
        (df_largo["Presión (bar)"] < umbral_fuga),
        "Fuga"
    ] = "Sí"

# Verificar cuántas fugas se detectaron
print(df_largo["Fuga"].value_counts())
Fuga
No    2371664
Sí     466576
Name: count, dtype: int64

# Graficar fugas

# Elegir un punto específico
punto_especifico = "PP01_ACANTILADO"
df_filtrado = df_largo[df_largo["Punto de Presión"] == punto_especifico]

# Graficar la presión en el tiempo
plt.figure(figsize=(12,5))
plt.plot(df_filtrado["Tiempo"], df_filtrado["Presión (bar)"], label=punto_especifico, color='b')

# Marcar en rojo los puntos con fuga
plt.scatter(
    df_filtrado[df_filtrado["Fuga"] == "Sí"]["Tiempo"],
    df_filtrado[df_filtrado["Fuga"] == "Sí"]["Presión (bar)"],
    color='r', label="Posible Fuga", zorder=3
)

# Configurar etiquetas y título
plt.xlabel("Fecha/Hora")
plt.ylabel("Presión (bar)")
plt.title(f'Presión en el tiempo - {punto_especifico} (Con detección de fugas)')
plt.legend()
plt.grid()

# Mostrar la gráfica
plt.show()

```

Figura 16. Proceso detección de fugas. Fuente: elaboración propia.

Resultados

Como parte de los resultados de 81 puntos de presión, se muestran algunas gráficas, por ejemplo el punto Acantilado (Figura 17), ubicado al norte de la CDMX, donde se observa que este tuvo más comportamientos anómalos durante el mes de marzo de 2020, llegando a presión 0, y a su vez con subidas de presión, que puede ser el indicativo de un error en el sensor de presión. Por otra parte, Venus (Figura 18) muestra un comportamiento más irregular que Acantilado, con fluctuaciones más bruscas que se pueden deber a factores como fugas reales e inestabilidad en la operación de esa zona.




Figura 17. Gráfica Punto de Presión: Acantilado. Fuente: elaboración propia.




Figura 18. Gráfica Punto de Presión: Venus. Fuente: elaboración propia.

Finalmente, en el punto Eje 4 Norte (Figura 19) se ven alteraciones más severas, pues las fluctuaciones se ven marcadas durante todo el año con caídas de presión de 0 a 2.5 bares, donde a diferencia de los otros dos puntos se identifican aglomeraciones de fugas de manera periódica, lo que desemboca en escenarios de roturas en las tuberías o válvulas descompuestas que generan

la fuga. Sin embargo, esta información, así como la de los demás puntos de presión, debería ser comparada con información de mantenimientos a la red e intervenciones, para descartar anomalías por fuga.




Figura 19. Gráfica Punto de Presión: Eje 4 Norte. Fuente: elaboración propia.

Aplicación de una Red Neuronal Artificial con SIG

Con base en los patrones obtenidos en el análisis estadístico, se aplicó una red neuronal artificial, y al haber etiquetado los datos que son propensos a una fuga de agua se construyeron escenarios con y sin fuga mediante algoritmos como ReLu y Sigmoid, para detectar problemas de clasificación binaria y posteriormente aplicar métricas de accuracy para evaluar el desempeño del modelo, utilizando una matriz de confusión, la cual reflejó verdaderos positivos y fugas reales no detectadas (Figura 20).




Figura 20. Elaboración matriz de confusión. Fuente: elaboración propia.

Esta información fue llevada a un sistema de información geográfica, donde de los 80 puntos posibles de fuga encontrados en la CDMX, predominaron el nororiente y centro de la ciudad en las alcaldías Azcapotzalco, Gustavo A. Madero, Cuauhtémoc, Benito Juárez y Tláhuac (Figura 21). Los causales de estos patrones pueden deberse a la antigüedad de la infraestructura, las altas presiones que obligan a implementar bombeos en puntos críticos, y los asentamientos irregulares que predominan en la zona oriente.

Este análisis no solo permitió visualizar zonas vulnerables, sino la falta de mantenimiento en una red tan grande que abastece una ciudad de más de 9 millones de personas. Por ello es importante la aplicación de inteligencia artificial en este contexto, lo que puede servir como una herramienta de gestión sostenible del agua urbana.




Figura 21. Mapa puntos probables de fuga por red neuronal artificial Fuente: elaboración propia.

Discusión y conclusiones

El presente estudio demostró la viabilidad de aplicar herramientas de programación, específicamente Python, para la detección de posibles fugas en redes de distribución de agua a partir del análisis de datos históricos de presión. La metodología implementada estableció umbrales para la medición de cada punto, permitiendo etiquetar alrededor de 466,000 registros como posibles fugas.

La visualización desempeñó un papel clave al evidenciar la recurrencia y distribución de estos eventos, lo que sugiere áreas de oportunidad para una gestión más eficiente del recurso hídrico; por otra parte, aunque esta aproximación no constituye una técnica de inteligencia artificial, sí representa una fase previa para dar estructura al análisis y validar la hipótesis inicial. Ello, para que en futuras etapas se implementen modelos de aprendizaje automático, como redes neuronales artificiales que optimicen la detección mediante múltiples variables.

En términos generales, en este capítulo se evidencia el potencial del análisis mediante programación en la gestión de una red urbana, ofreciendo una herramienta flexible que puede adaptarse a diversos contextos con solo ajustar los criterios de clasificación, dando apertura a la integración de Geo Inteligencia Artificial. Gracias a la combinación de datos geospaciales se puede hacer un modelado hidráulico de toda la red urbana, donde estos puntos de presión analizados pueden visualizarse en programas como EPANET, que es un software para modelar redes hidráulicas y generar escenarios de un estado estable en las tuberías contra uno de fugas, y hacer predicción de lugares más susceptibles a falla.

Aunque este tipo de programas no cuenta con una cartografía tan avanzada como lo sería ArcGis, su utilidad radica en la información y precisión del comportamiento hidráulico. Por lo tanto, no se reemplaza el análisis espacial, sino que se complementa con otras herramientas para simulaciones que no es posible aplicar en softwares comunes, fortaleciendo el criterio para la toma de decisiones, no solo desde el área urbana sino desde la ingeniería, como se ve en trabajos de investigación de Lobos (2022), donde mediante redes neuronales artificiales y el modelado de la red en EPANET se detectan y localizan fugas en una red urbana.

Referencias

- Aprende con Alf. (04 de octubre de 2020). La librería Matplotlib. <https://aprende-conalf.es/docencia/python/manual/matplotlib/>
- Conagua. (2020). Programa Nacional Hídrico 2020-2024 [Resumen]. https://www.gob.mx/cms/uploads/attachment/file/553479/PNH_Resumen_Im-prenta_v200311.pdf
- Conagua. (2023). Estadísticas del Agua en México 2023. https://sinav30.conagua.gob.mx:8080/Descargas/pdf/EAM2023_f.pdf
- DataScientest. (19 de enero de 2025). Numpy: La biblioteca de Python más utilizada en Data Science. <https://datascientest.com/es/numpy-la-biblioteca-python#:~:text=%C2%BFQu%C3%A9%20es%20NumPy?,y%20For-tran%20es%20muy%20sencilla>.
- DataScientest. (19 de diciembre de 2022). Pandas: La librería de Python dedicada a la Data Science. <https://datascientest.com/es/pandas-python>

- Growup. (16 de enero de 2023). Agrupo datos con GroupBy en Python. <https://www.growupcr.com/post/groupby-python#:~:text=groupby%20es%20una%20herramienta%20poderosa.otra%20manera%20podr%C3%A1-Dan%20pasar%20desapercibidos>.
- Grupo incotex. (24 de mayo de 2024). SACMEX: Incrementan Fugas de Agua en la Ciudad de México. <https://grupoincotex.com/noticias/sacmex-incrementan-fugas-de-agua-en-la-ciudad-de-mexico/>
- KDnuggets. (2023). *Pandas melt: Convert wide data to long format*. <https://www.kdnuggets.com>
- Laucelli, D., Romano, M., Savic, D., y Giustolisi, O. (2016). Detecting anomalies in water distribution network using EPR modelling paradigm. *Journal of Hydroinformatics*, Vol. 18, No. 3, 409-427. <https://doi.org/10.2166/hydro.2015.113>
- Li, R., Huang, H., Xin, K., y Tao, T. (2015). A review of methods for burst/leakage detection and location in water distribution systems. *Water Supply*, Vol. 15, No. 3, 429-411. <https://doi.org/10.2166/ws.2014.131>
- Lobos, J. (2022). Detección y localización de fugas en redes de distribución de agua potable en una gran ciudad de Chile mediante un algoritmo de clasificación de redes neuronales. [Tesis de licenciatura, Universidad de Chile]. <https://repositorio.uchile.cl/handle/2250/185782>
- Pandas. (2024). Group by: split-apply-combine. https://pandas.pydata.org/docs/user_guide/groupby.html
- Pérez, E. (2015). Los Sistemas SCADA en la automatización industrial. *Tecnología en Marcha*, Vol. 28. No. 4, 3-14.
- SACMEX (2023). Base de datos histórico de presiones en la red primaria de la Ciudad de México año 2022. (Datos proporcionados mediante solicitud institucional).
- Semarnat. (27 de junio de 2018). ¿Qué son las cuencas hidrológicas y las reservas de agua? <https://www.gob.mx/semarnat/articulos/que-son-las-cuencas-hidrologicas-y-las-reservas-de-agua>

Conclusiones generales

Los resultados encontrados a partir de todos los capítulos muestran, de manera clara, la incorporación de herramientas de la geomática, la inteligencia artificial (IA) y el análisis espacial, lo que permite avanzar en la comprensión de las dinámicas urbanas latinoamericanas. Los estudios realizados identifican patrones claros de monocentrismo incipiente, gentrificación climática, expansión urbana desordenada, desigualdad en la movilidad y fragmentación territorial. Asimismo, se lograron localizar nodos funcionales emergentes, zonas críticas de vulnerabilidad ambiental, así como puntos de presión hídrica y riesgo vial, todos ellos detectados mediante metodologías automatizadas, supervisadas o algorítmicas.

Así mismo, se validó que el uso de algoritmos de clasificación supervisada, Python, Google Earth Engine, teledetección multispectral y modelos de regresión geoespacial no solo son útiles para la visualización de datos, sino que permiten identificar patrones estructurales y predecir comportamientos futuros del territorio. Esto se traduce en una capacidad mejorada para anticipar riesgos, evaluar políticas públicas y formular estrategias urbanas más precisas y sostenibles. El libro demuestra cómo las tecnologías pueden modelar fenómenos complejos como la densificación vertical (caso Polanco), la gentrificación climática (Bogotá y Barranquilla), o la micro-segregación residencial (Managua), sin sacrificar rigor teórico ni profundidad contextual.

La hipótesis transversal donde se entiende que la geomática, junto con la IA, puede potenciar la planificación urbana crítica, fue comprobada empíricamente en distintos escenarios territoriales. Se verifica que la CDMX avanza hacia una configuración policéntrica; que la vulnerabilidad ambiental en zonas como el Bosque de Agua puede diagnosticarse de manera efectiva con SIG y teledetección; y que es posible identificar correlaciones entre cobertura vegetal, temperatura superficial y desigualdad socioeconómica, con datos satelitales. Los hallazgos validan también que, en territorios altamente desiguales, la integración de tecnología no sustituye el juicio crítico, sino que lo amplifica cuando se combina con una lectura multiescalar e interdisciplinaria.

El libro concluye que la geomática y la inteligencia artificial no deben entenderse como recursos técnicos aislados, sino como pilares de una nueva epistemología urbana. Cada capítulo aporta una lectura situada y contextualizada de los procesos urbanos, evitando generalizaciones simplistas. En conjunto, las investigaciones revelan que fenómenos como la centralidad, la inseguridad vial, la segregación espacial y los impactos ambientales, requieren metodologías híbridas que articulen teoría, datos y código. Las conclusiones parciales de cada línea temática refuerzan esta visión: para la Planeación urbana y geomática se requiere repensar los modelos espaciales tradicionales bajo esquemas de simulación y predicción adaptativa. En el caso de los Procesos urbanos y habitabilidad, la justicia territorial debe abordarse con evidencia

georreferenciada, identificando desigualdades invisibles. En lo que corresponde a las Transformaciones ambientales, la geomática permite medir impactos en tiempo real, pero también exige responsabilidad ética en la interpretación y el uso de los datos.

El libro también se posiciona como una continuación avanzada del volumen anterior (2023), proponiendo una maduración conceptual al pasar de la pregunta “¿cómo se hace geomática urbana?”, hasta cuestionar “¿para qué sirve en los contextos reales?”. Con ello, la obra se convierte en un puente entre la academia, la técnica y la praxis territorial.

Agradecimientos

Se brinda un agradecimiento especial al apoyo del IPN a través del proyecto 20240362 “Infraestructura y servicios, elementos importantes en la Planeación Urbana”, por el cual se pudo realizar y publicar el libro.

Asimismo, este trabajo contó con el respaldo de los proyectos de investigación PRORED “Sistema Autónomo de Monitoreo del Tránsito Urbano para la Investigación Aplicada en Movilidad de Ciudades Intermedias” (Proyecto No. 20254782) y SIP “Monocentrismo o policentrismo en la Zona Metropolitana del Valle de México” (SIP 20250563), ambos del Instituto Politécnico Nacional.

Semblanza de los autores

Ricardo Gómez Maturano

(Distrito Federal, 1978). Es Doctor en Urbanismo por la Universidad Nacional Autónoma de México, Maestro en Ciencias en la Especialidad de Arquitectura e Ingeniero Arquitecto por el Instituto Politécnico Nacional. Realizó estancias en el Centro de Desarrollo Urbano Sustentable (CEDEUS) (Chile), en el Instituto de Geografía de la Universidad Católica de Chile y en la Facultad de Arquitectura de la Universidad Autónoma del Estado de Morelos. Las líneas de investigación desarrolladas en sus estudios son la geomática, la fragmentación urbana, la segregación residencial y los procesos de gentrificación. Es miembro del Sistema Nacional de Investigadores y profesor investigador de la Sección de Estudios de Posgrado e Investigación de la Escuela Superior de Ingeniería y Arquitectura, Unidad Tecamachalco del IPN, donde imparte cátedra en la Maestría y Doctorado, en Ciencias en Arquitectura y Urbanismo.

María Fernanda Islas Monroy

Maestrante en Ciencias en Arquitectura y Urbanismo en el Taller de Geomática y Procesos Urbanos. Cuenta con una maestría en Building Information Modeling y estudios en arquitectura. Su línea de investigación se centra en el análisis urbano mediante herramientas digitales, el crecimiento vertical de las ciudades y la relación entre BIM y GIS. Sus estudios abordan la planeación territorial, la modelación de datos espaciales y el impacto de la tecnología en la arquitectura y el urbanismo.

Rogelio Contreras González

Ingeniero Arquitecto por el IPN y estudiante de la Maestría en Ciencias en Arquitectura y Urbanismo, con más de 10 años de experiencia en diseño arquitectónico, planeación urbana y planes maestros. Ha participado en la coordinación de proyectos habitacionales, urbanos y de movilidad para clientes como SEDATU, BID e institutos de planeación. Su trayectoria incluye la elaboración de instrumentos de planeación territorial, supervisión de obra y análisis normativo. Además, ha desarrollado proyectos con enfoque en sostenibilidad, movilidad y gestión urbana, combinando experiencia técnica con un alto interés en la investigación y aplicación de nuevas metodologías en el desarrollo urbano.

Álvaro Flores Miranda

Candidato a Doctor en Ciencias en arquitectura y urbanismo por la Escuela Superior de Ingeniería y Arquitectura Unidad Tecamachalco (ESIA) del Instituto Politécnico Nacional (IPN); maestro en Ciencias en Arquitectura y Urbanismo por ESIA-IPN; y, licenciado en Arquitectura por la Universidad Autónoma del

Estado de Hidalgo, (UAEH). Temas de especialidad: políticas públicas urbanas, evaluación de políticas públicas y gobernanza, planificación urbana y desarrollo urbano. Ha escrito artículos especializados diversos sobre la importancia de la evaluación y el seguimiento de políticas públicas urbanas y la vinculación directa al aprovechamiento de bases de datos a través de la estadística espacial y el uso de los sistemas de información geográfica.

Perla María Sánchez Uriarte

Doctora y Maestra en Ciencias en Arquitectura y Urbanismo por el Instituto Politécnico Nacional (IPN) y Arquitecta por la Facultad de Arquitectura de la Universidad Nacional de Ingeniería (UNI). Posdoctorante en el Instituto de Geografía de la Universidad Nacional Autónoma de México (UNAM). Se ha especializado en política habitacional; procesos urbanos como segregación residencial y fragmentación espacial, financiarización de la vivienda, y deuda y vida cotidiana, sobre los cuales ha escrito y publicado diversos trabajos. Ha trabajado como consultora para la Agencia Suiza para el Desarrollo y la Cooperación (COSUDE), el Banco Interamericano de Desarrollo (BID) y la Corporación Financiera Internacional (IFC).

Margarita Ruiz Camacho

Ingeniero Arquitecto por la Escuela Superior de Ingeniería y Arquitectura, Unidad Tecamachalco, IPN. Maestría en Ciencias en Arquitectura y Urbanismo por el IPN. Actualmente es estudiante del Doctorado en Ciencias en Arquitectura y Urbanismo. Auxiliar de investigación en el proyecto de investigación “Monocentrismo o Policentrismo en la ZMVM”. Sus líneas de investigación desarrolladas se han enfocado en la habitabilidad en áreas periurbanas, y actualmente el tema de investigación que desarrolla se relaciona con la movilidad cotidiana y la justicia espacial en la ZMVM. Ha trabajado en la construcción de vivienda masiva de interés social en la periferia del Estado de México, así como en la construcción del Hospital de Oncología en el Edo. de México, el Edificio Aleph San Ángel y el Trolebús en Av. Ermita-Iztapalapa.

Raquel Andrea Delgadillo Díaz

Maestra en Ciencias en Arquitectura y Urbanismo e Ingeniera Arquitecta egresada de la Escuela Superior de Ingeniería y Arquitectura (ESIA) Unidad Tecamachalco. Su profundo interés en la arquitectura y el urbanismo la llevó a continuar su formación académica, emprendiendo estudios de posgrado en la Maestría en Ciencias en Arquitectura y Urbanismo. Actualmente, su investigación está centrada en la accidentabilidad de los motociclistas en la Ciudad de México, reflejando su preocupación por los problemas sociales y su deseo de contribuir a soluciones sostenibles y efectivas. Es una profesional comprometida con la mejora de la calidad de vida urbana y la seguridad vial.

Víctor Raúl Quintero Barba

Maestrante en Ciencias en Arquitectura y Urbanismo en el Instituto Politécnico Nacional (IPN); Arquitecto por la Universidad de Panamá; Perito Forense en el Instituto de Medicina Legal y Ciencias Forenses; y Artista Plástico formado en el Instituto Nacional de Cultura Centro Superior Bellas Artes de Chitré. Ha trabajado en el diseño y desarrollo de residencias unifamiliares y comercios desde 2021, participando además en exposiciones pictóricas a nivel nacional. Como perito forense, ha realizado inspecciones oculares y estudios técnicos en el ámbito judicial desde 2016. Su investigación académica se centra en la violencia urbana en Panamá.

Ma. de los Ángeles Martínez Ortega

Doctora en Educación, Universidad CUGS- 2024, Maestra en Administración y Desarrollo de la Educación, IPN. Actualmente trabaja en el Instituto Politécnico Nacional, ESIA-TECAMACHALCO, como Docente-Investigadora. Ha escrito algunos documentos tales como libros, artículos científicos, y participado directamente en congresos de proyección educativa y formación de recursos humanos. Su línea de investigación incluye gestión educativa, y su vinculación con el cuidado del medio ambiente a través de la educación sostenible, Planeación Estratégica, cuestiones de Urbanismo, Movilidad Urbana, Tecnologías de Información y Comunicación, Medio Ambiente, Administración de Recursos Materiales y Naturales en comunidades en estado de pobreza y estudios de Género, papel o rol de la Mujer en diferentes actividades: desde el hogar, la familia, la economía e impacto social, entre otros.

Luis Armando Soto Martínez

Candidato a Maestro en Urbanismo, Área Urbano-Regional, UNAM. Arquitecto por la Universidad La Salle. Laboró 19 años en el Programa Universitario de Estudios sobre la Ciudad (PUEC-UNAM), desarrollando metodologías, investigaciones, estudios, proyectos, planes y programas de desarrollo urbano. Profesor de la Licenciatura en Urbanismo de la Facultad de Arquitectura, UNAM. Sus áreas de especialidad incluyen el desarrollo de planes y programas de Ordenamiento Territorial y Desarrollo Urbano, así como la Resiliencia y la Planeación Participativa. Ha publicado sobre temas urbanos, metodologías de planeación participativa, recorridos de campos y levantamiento de usos de suelo y centros históricos (análisis y planeación urbana).

Cristy Monserratt Sánchez Ramos

Maestra y Doctorante en Ciencias en Arquitectura y Urbanismo por el Instituto Politécnico Nacional (IPN), en la Escuela Superior de Ingeniería y Arquitectura (ESIA), Unidad Tecamachalco. Ingeniera Arquitecta por el IPN. Estancia de investigación en la facultad de Geografía e Historia de la Universidad

de Barcelona (UB). Sus líneas de investigación se centran en temas relacionados con urbanización, coberturas y usos de suelos, crisis medioambiental, desigualdad socioambiental y sistemas de información geográfica (SIG).

Marielena Medina Ruiz

Maestra y Doctorante en ciencias en Arquitectura y urbanismo en el Instituto Politécnico Nacional, en la Escuela Superior de Ingeniería y Arquitectura ESIA Tecamachalco. Sus líneas de investigación desarrolladas se enfocan en temas tales como climas urbanos, gentrificación climática, sistemas de información geográfica, urbanismo social y diseño participativo. Arquitecta en la Universidad Católica de Colombia. Realizó una estancia de investigación en el departamento de geografía en la Facultad de Arquitectura y Urbanismo de la Universidad de Chile, y participó en el XXI ENANPUR, Curitiba, Brasil.

J. Guadalupe Martínez Granados

Coordinador de la Maestría en Ciencias en Arquitectura y Urbanismo del Instituto Politécnico Nacional, ESIA Tecamachalco. Sociólogo egresado de la Universidad Nacional Autónoma de México (UNAM), cuenta con estudios de Maestría y Doctorado en Urbanismo por la Facultad de Arquitectura de la misma institución. Ha realizado una estancia posdoctoral en la Escuela Superior de Ingeniería y Arquitectura (ESIA), Unidad Tecamachalco, del Instituto Politécnico Nacional (IPN). Actualmente, es miembro del Sistema Nacional de Investigadores (SNI), Nivel I, y se desempeña como profesor-investigador en la Sección de Estudios de Posgrado e Investigación de la ESIA Tecamachalco, donde participa como docente en los programas de Maestría y Doctorado en Ciencias en Arquitectura y Urbanismo.

Luz de Lourdes Cordero Gómez del Campo

Licenciada en Administración de Empresas por la Universidad Iberoamericana. Licenciada, Maestra y Doctora en Geografía por la Universidad Nacional Autónoma de México. Principales áreas de Investigación: Gentrificación, Financiarización, Ciudades digitales. Actualmente en Estancia Posdoctoral en el área de Posgrado en el Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura, Unidad Tecamachalco.

Víctor Manuel Sánchez Vega

Maestrante en Ciencias en Arquitectura y Urbanismo por el IPN y egresado de la carrera de Ingeniero Arquitecto, ha desarrollado su trayectoria profesional en el ámbito de la infraestructura y el urbanismo, con enfoque en proyectos aeroportuarios y de obra pública. Ha dirigido ingenierías M.E.P. en obras como el Aeropuerto de Tulum y la ampliación del aeropuerto de Tepic, y ha participado en el diseño de la red “El Cuchillo 2” en Nuevo León. Asimismo, ha contribuido

en el PMDU de Atenco, Estado de México, y colaborado en la Alcaldía Gustavo A. Madero y el Municipio de la Paz, Estado de México, en el área de Desarrollo Urbano y Ordenamiento Territorial.

Ana Laura Castillo Hernández

Maestrante en Ciencias en Arquitectura y Urbanismo del IPN, y egresada de la carrera de Ingeniero Arquitecto. Ha ejercido en el área gubernamental en SACMEX, en el área de Proyectos de Agua Potable, supervisando la ejecución de proyectos en plantas potabilizadoras, así como la licitación de las mismas. En el inter de su estancia en dicha institución se crearon presentaciones de planes de acción en caso de sismo en todas las áreas operativas para presentar en Japón para la institución JICA, la cual tiene convenio con México, y es encargada de realizar investigaciones para solucionar asuntos de desarrollo en países en vías de desarrollo.

6 3 3 6 7 5 1 1 6 5 4 9 6 8 8 4 4 1 4
5 7 8 9 6 9 2 1 5 5 9 5 9 1 7 7 6 2 6 5 3 5 5 5
4 6 3 9 7 2 6 9 2 2 9 3 7 9 3 8 5 5 3 6 7 7
2 4 1 7 6 2 8 4 9 3 6 7 9 6 4 9 8 6 8 8
1 2 1 1 1 2 4 2 5 7 5 9 4 8 2 5 6 6 9 1 4 6 8 8 5 4 4
2 1 5 8 7 9 7 3 3 1 2 3 9 4 4 4 4
7 1 1 7 3 3 7 5 6 1 6 1 4 4 8 7
2 4 7 2 8 4 2 9 1 5 1 1 3 2 1 7 6 4 5 1 1 3 8 5 4 4
2 1 8 9 7 5 9 9 4 5 4 8 5 7 5 3 4 4 4
5 3 7 6 9 6 8 9 5 6 4 6 7 6 3 6 9 4 3 8 3 3 4 4
7 6 7 4 1 4 3 3 9 4 4 8 7 4 6 4 1 5 7 5 5 4 4
8 4 6 2 7 5 1 8 8 6 1 4 3 7
5 7 8 1 2 7 6 9 9 5 9 7
5 6 5 6 6 9 9 7 2 3 1
6 7 4 6 6 4 2 1 3 1 5
6 1 4 7 4 2 7 6 9 8
1 5 6 6 7 5 4 3 9 9 1 7 4 8
7 4 8 8 3 4 7 9 4 5 5 1
2 8 3 7 8 4 8 8 8 9 2 4 6 8 6 6
2 5 4 2 7 7 1 5 2 7 8
2 7 3 6 3 3 2 4 7 4 4
6 2 8 6 9 3 8 4 1
4 7 3 1 4 7 4 1
6 6 5 9 6 5 2 2 4 5 8 1 9
8 4 3 6 2 3 8 1 1 1 1
6 8 6 3 2 1 4 4 9 5 4 5 4 4
9 6 8 6 8 3 4 7 4 8 1 3 8
1 4 1 6 5 6 3 8 3 4 3 1 3 1 4 4
3 8 8 7 5 2 4 4 4 4 4 4 4 4
2 5 9 6 4 4 9 1 4 1 4 4
5 4 9 5 5 4 4 5 1 4 1 4 4
3 3 9 8 9 7 8 4 4 4 4 4 4
1 4 4 4 4 5 8 4 4 4 4 4 4 4
2 3 1 5 1 9 6 8 9 4 4 4 4 4
3 6 5 8 8 8 4 4 4 4 4 4 4
3 6 6 9 7 8 5 3 1 1 4 4 4 4
2 7 1 5 6 4 4 4 4 4 4 4
1 1 1 8 4 1 3 1 4 4 4 4 4
2 3 9 1 2 2 4 4 4 4 4 4 4
8 4 4 4 3 2 2 4 4 4 4 4 4
9 4 7 4 1 4 9 1 2 2 4 4 4 4
9 4 1 4 4 4 4 4 4 4 4 4
3 4 9 2 4 4 4 4 4 4 4 4
4 1 8 4 1 4 4 4 4 4 4 4 4
2 4 4 4 4 4 4 4 4 4 4 4
1 9 7 2 4 4 4 4 4 4 4 4 4
1 4 4 4 4 4 4 4 4 4 4 4 4
1 3 4 4 4 4 4 4 4 4 4 4 4
1 7 4 4 4 4 4 4 4 4 4 4 4
4 4 4 4 4 4 4 4 4 4 4 4 4
4 1 8 4 1 4 4 4 4 4 4 4 4
2 4 4 4 4 4 4 4 4 4 4 4 4

Este libro reúne una serie de investigaciones académicas orientadas al análisis y comprensión de los procesos urbanos contemporáneos mediante el uso de herramientas geomáticas, inteligencia artificial y análisis espacial. Está dirigido a estudiantes de posgrado, investigadores, urbanistas, ingenieros territoriales y tomadores de decisiones que busquen enfoques metodológicos basados en datos para enfrentar los desafíos urbanos actuales. Su propuesta integra conocimientos técnicos, científicos y teórico-conceptuales que permiten modelar, interpretar y transformar el territorio desde una perspectiva crítica y propositiva.

Se estructura en tres líneas temáticas. La primera, "Planeación urbana, geomática e IA aplicada a los análisis urbanos", con estudios sobre monocentrismo, dispersión, densificación, regeneración urbana y análisis funcional de ciudades mediante modelos geoespaciales e inteligencia artificial. La segunda línea, "Procesos urbanos, habitabilidad y transformación socioespacial", se enfoca en la movilidad cotidiana, la seguridad vial, la accesibilidad a servicios urbanos, la vivienda saludable y el análisis de criminalidad, con un enfoque en la justicia espacial. La tercera línea, "Transformaciones ambientales urbanas y tecnologías geoespaciales para el análisis territorial", aborda la gentrificación climática, el impacto urbano sobre el ambiente, el monitoreo de islas de calor y el uso de SIG para el análisis de fugas hidráulicas y estrés hídrico. Como trabajo colectivo ofrece herramientas conceptuales y operativas para la planificación urbana sostenible, promoviendo una toma de decisiones informada, sustentada en evidencia empírica y nuevas tecnologías.

Se agradece el apoyo del Instituto Politécnico Nacional (IPN), a través del Proyecto 20240362 "Infraestructura y servicios, elementos importantes en la Planeación Urbana", que hizo posible el desarrollo de esta edición del libro.

