



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO

FACULTAD DE INGENIERÍA  
MAESTRÍA EN CIENCIAS DE LA INGENIERÍA

UN MODELO DE CRECIMIENTO URBANO  
VERTICAL CON FACTORES  
CARACTERÍSTICOS BASADO EN  
INTELIGENCIA ARTIFICIAL

T E S I S

QUE PARA OBTENER EL GRADO DE:  
**Maestro en Ciencias de la Ingeniería**

PRESENTA:

**Ing. Luis Antonio López Rivera**



DIRECTOR DE TESIS:  
**Dr. Marcelo Romero Huertas**

Toluca, Estado de México, 2021

# Resumen

El crecimiento urbano vertical se define como un fenómeno espacio-temporal que surge como consecuencia de factores sociales, económicos o geográficos produciéndose tanto en forma horizontal como vertical. La acción del crecimiento horizontal genera consecuencias geográficas como destrucción de bosques, áreas agrícolas y espacios de agua. Por otro lado, el tiempo de traslado en actividades cotidianas aumenta, impactando en el tiempo requerido para el acceso a servicios.

Tras el ataque del World Trade Center el 11 de septiembre de 2001, se pronosticaba que el crecimiento vertical se detendría; sin embargo, las ciudades han seguido creciendo verticalmente. Al optar por un crecimiento vertical los planeadores urbanos han adaptado los edificios como herramientas para buscar la integración de servicios y minimizar el daño a zonas naturales.

Recientemente, con la evolución tecnológica, la geografía ha comenzado a integrar técnicas de inteligencia artificial en modelos de crecimiento urbano, con el fin de simular el comportamiento de las ciudades o regiones, tomando en cuenta los factores humanos que dirigen el crecimiento. Este tipo de modelos presentan un área de oportunidad que se encuentra en aumento debido a que son técnicas matemáticas que simulan el comportamiento del cerebro humano.

En esta tesis se presenta un modelo con redes neuronales y autómatas celulares integrado al SIG libre QGIS mediante el lenguaje de programación Python para proyectar el crecimiento vertical, a través de imágenes raster y mapas vectoriales.

El modelo propuesto se conforma de cuatro etapas:

- Procesamiento de datos
- Diseño de arquitectura de red neuronal
- Proyección mediante autómatas celulares
- Validación del modelo

Durante el procesamiento de datos ráster se realizan correcciones (radiométricas, geométricas y atmosféricas) a las imágenes satelitales para reducir errores producidos al tiempo de su captura. Posteriormente, mediante combinación de bandas satelitales y aplicación de índices espectrales se resalta la zona urbana objetivo.

---

Los datos vectoriales se procesan a través del sistema de información geográfica QGIS para georreferenciar la información y rasterizar los datos. Finalmente, los datos se normalizan en valores entre 0 y 1 para hacerlos compatibles con las funciones de activación de la red neuronal.

Para el diseño de red neuronal se desarrolla un script en Python que busque la arquitectura óptima para los datos de estudio, una vez terminado el proceso de búsqueda se proyecta un mapa de probabilidad que combina imágenes satelitales y factores de crecimiento. A partir de este mapa se realiza la proyección del crecimiento vertical, para ello se diseña un autómata celular con un conjunto de reglas que permiten evaluar los valores de la vecindad de un edificio y determinar si puede o no darse un crecimiento vertical.

El modelo se prueba en cuatro zonas metropolitanas de México (Valle de México, Guadalajara, Monterrey y Puebla-Tlaxcala) y el caso de estudio internacional de la metrópolis de Tokio (Japón). Se generan resultados con una exactitud del 73% los cuales se validan mediante: i) Promedio de cantidad de edificios proyectados, ii) Posición utilizando el índice Kappa y, iii) Valor en la imagen satelital mediante el índice Jaccard.

Se observa que el crecimiento vertical se concentra alrededor de las ciudades principales de México; sin embargo, con el paso de los años comienza a expandirse hacia los municipios cercanos debido a la relación entre los factores de crecimiento vertical.

# Publicaciones

Parte de la presente tesis ha sido publicada previamente en:

1. Luis Antonio López-Rivera and Marcelo Romero-Huertas. (2021). An artificial neural network & cellular automata vertical urban growth model using major socioeconomic and geographical factors. *Springer Nature - Book Series: Transactions on Computational Science & Computational Intelligence*, ISSN: 2569-7072.
2. López Rivera, L. (2021). Una oportunidad para las ciudades inteligentes. *UNIVERSITARIA*, 4(30), 34-35. Consultado de <https://revistauniversitaria.uaemex.mx/article/view/16171>.
3. Luis Antonio López-Rivera, Marcelo Romero-Huertas, and David Valle-Cruz. (2021). A neural network-cellular automata based model for predicting vertical urban growth. In *DG.O2021: The 22nd Annual International Conference on Digital Government Research (DG.O'21)*, June 9–11, 2021, Omaha, NE, USA. ACM, New York, NY, USA, <https://dl.acm.org/doi/10.1145/3463677.3463751>.

# Tabla de contenido

Capítulos	Página
Índice de figuras	VIII
Índice de tablas	XI
<b>1. Introducción</b>	<b>1</b>
1.1. Problemática . . . . .	2
1.2. Justificación . . . . .	3
1.3. Hipótesis . . . . .	4
1.4. Objetivos . . . . .	4
1.5. Estructura de la tesis . . . . .	5
<b>2. Marco teórico</b>	<b>6</b>
2.1. Planeación urbana . . . . .	6
2.1.1. Sistemas de información geográfica . . . . .	7
2.2. Tipos de crecimiento urbano . . . . .	9
2.3. Redes neuronales artificiales . . . . .	11
2.3.1. Tipos de funciones de activación . . . . .	13
2.3.2. Perceptrón multicapa . . . . .	14
2.3.3. Algoritmo de retropropagación . . . . .	15
2.4. Autómatas celulares . . . . .	19
2.4.1. Estructura de un autómata celular . . . . .	19
<b>3. Estado del arte</b>	<b>21</b>
3.1. Factores de crecimiento . . . . .	21
3.2. Crecimiento urbano aplicando técnicas de inteligencia artificial . . . . .	22
3.3. Crecimiento vertical . . . . .	24
<b>4. Marco metodológico</b>	<b>28</b>
4.1. Generalidades . . . . .	28
4.2. Selección de factores de crecimiento . . . . .	29
4.3. Tratamiento de imágenes . . . . .	31

4.3.1.	Imágenes satelitales . . . . .	31
4.3.1.1.	Ubicación y descarga de zona de estudio . . . . .	32
4.3.1.2.	Preprocesamiento de imágenes . . . . .	32
4.3.1.3.	Combinación de bandas satelitales . . . . .	34
4.3.1.4.	Extracción de zona urbana . . . . .	34
4.3.2.	Rasterización de datos vectoriales . . . . .	36
4.3.2.1.	Descarga de datos de estudio . . . . .	37
4.3.2.2.	Creación de shapefiles . . . . .	37
4.3.2.3.	Rasterización . . . . .	38
4.3.2.4.	Normalización . . . . .	39
4.4.	Modelado . . . . .	40
4.5.	Simulación y análisis de resultados . . . . .	40
<b>5.</b>	<b>Modelo de crecimiento vertical</b>	<b>42</b>
5.1.	Diseño del modelo . . . . .	42
5.2.	Diseño de red neuronal . . . . .	44
5.2.1.	Arquitectura de red neuronal . . . . .	45
5.2.2.	Selección de red neuronal . . . . .	46
5.3.	Diseño de autómata celular . . . . .	47
5.3.1.	Espacio n-dimensional . . . . .	47
5.3.2.	Condición inicial del espacio n-dimensional . . . . .	49
5.3.3.	Conjunto de estados . . . . .	49
5.3.4.	Espacio de vecindad . . . . .	52
5.3.5.	Reglas de transición . . . . .	54
5.3.5.1.	Diseño de estadísticos no espaciales . . . . .	56
5.3.5.2.	Diseño de estadísticos espaciales . . . . .	58
5.3.6.	Autómata Celular propuesto . . . . .	61
<b>6.</b>	<b>Experimentación y análisis de resultados</b>	<b>64</b>
6.1.	Zona metropolitana del Valle de México (México) . . . . .	64
6.1.1.	Datos de trabajo . . . . .	64
6.1.2.	Resultados . . . . .	67
6.2.	Zona metropolitana de Guadalajara (México) . . . . .	69
6.2.1.	Datos de trabajo . . . . .	70
6.2.2.	Resultados . . . . .	71
6.3.	Zona metropolitana de Monterrey (México) . . . . .	73
6.3.1.	Datos de trabajo . . . . .	74
6.3.2.	Resultados . . . . .	74
6.4.	Zona metropolitana de Puebla-Tlaxcala (México) . . . . .	77

6.4.1. Datos de trabajo . . . . .	77
6.4.2. Resultados . . . . .	78
6.5. Metrópolis de Tokio (Japón) . . . . .	81
6.5.1. Datos de trabajo . . . . .	81
6.5.2. Resultados . . . . .	82
6.6. Resumen de resultados . . . . .	85
<b>7. Conclusiones y trabajo futuro</b>	<b>88</b>
7.1. Conclusiones . . . . .	88
7.2. Trabajo futuro . . . . .	89
<b>Referencias</b>	<b>91</b>

# Índice de figuras

Figura	Página
2.1. Representación del modelo Ráster. Obtenido de <a href="#">ESRI (2016b)</a> . . . . .	8
2.2. Representación del modelo Vectorial. Obtenido de <a href="#">(Campbell et al., 2018)</a> . . . . .	8
2.3. Tipos de crecimiento urbano. Obtenido de <a href="#">Wilson et al. (2003)</a> . . . . .	10
2.4. Funcionamiento de una red neuronal. . . . .	12
2.5. Modelo de neurona propuesto por McCulloch-Pitts, el cual consta de $D$ entradas y pesos, una salida $y$ y la función de activación $g$ . Obtenido de <a href="#">(Palma Méndez and Morales, 2008)</a> . . . . .	12
2.6. Arquitectura Perceptron Multicapa. Obtenido de <a href="#">(Palma Méndez and Morales, 2008)</a> . . . . .	14
2.7. Organigrama de empresa. . . . .	16
2.8. Componentes autómata celular: (a) Espacio unidimensional binario, (b) Espacio bidimensional binario, (c) Vecindad de Von Neuman, (d) Vecindad de Moore y (e) Vecindad hexagonal. . . . .	20
4.1. Metodología propuesta. . . . .	29
4.2. Etapas realizadas en el tratamiento de imágenes satelitales. . . . .	31
4.3. Seleccionando como zona de estudio a la Ciudad de México del repositorio del satélite Landsat 8. . . . .	32
4.4. Ejemplo de corrección atmosférica en imagen ráster, mediante el proceso de corrección se reduce el ruido ocasionado por la nube. . . . .	33
4.5. Ejemplo de corrección radiométrica en imagen satelital, a través del ajuste lineal en función de la media de niveles vecinos. . . . .	33
4.6. Ejemplo de corrección geométrica en imagen ráster. . . . .	34
4.7. Combinación de bandas satelitales de la Ciudad de México. (a) PCA de la combinación de bandas 6-7, (b) PCA de la combinación de bandas 10-11. . . . .	35
4.8. Índices para la Ciudad de México. (a) NDVI, (b) MNDWI, (c) NDBI y (d) BAEM. . . . .	37
4.9. Pasos realizados para la rasterización de mapas vectoriales. . . . .	37
4.10. Georreferenciación de datos tabulares. . . . .	38
4.11. Ejemplo rasterización. . . . .	38
4.12. Factores rasterizados de la zona urbana de la Ciudad de México. (a) representa el factor de población, (b) observa el factor de vivienda, (c) corresponde al factor de población económicamente activa y (d) representa la infraestructura de servicios municipales. . . . .	39



5.1. Procesamiento de datos para su entrada a la red neuronal. . . . .	43
5.2. Modelo de crecimiento urbano vertical. . . . .	44
5.3. Evolución de aprendizaje en las redes neuronales. . . . .	47
5.4. Mapas de probabilidad de crecimiento vertical del año 2015: (a) Zona Metropolitana del Valle de México, (b) Zona Metropolitana de Guadalajara, (c) Zona Metropolitana de Monterrey. . . . .	48
5.5. Tipos de condiciones iniciales en autómatas celulares: (a) Condición inicial propuesta por Wolfram (1983), (b) Condición inicial propuesta por Margenstern (2007), (c) Ejemplo de condición inicial en la investigación. . . . .	49
5.6. Gráficas de comparativas entre error producido por truncamiento y redondeo: (a) Zona Metropolitana del Valle de México, Norte, (b) Zona Metropolitana del Valle de México, Sur, (c) Zona Metropolitana de Guadalajara, (d) Zona Metropolitana de Monterrey. . . . .	50
5.7. Histogramas de las Zonas Metropolitanas antes y después del redondeo. . . . .	51
5.8. Ejemplos de niveles para criterios de vecindad en espacios bidimensionales. . . . .	52
5.9. Ejemplos de edificios en las Zonas Metropolitanas. . . . .	53
5.10. Espacio de vecindad para la Zona Metropolitana de Monterrey. . . . .	54
5.11. Problema del tablero de ajedrez y la unidad espacial modificable. . . . .	55
5.12. Intervalos de confianza para las Zonas Metropolitanas. . . . .	58
5.13. Vecindad del edificio Torre Lux, como ejemplo para calcular el nivel de riesgo propuesto. . . . .	59
5.14. Mapas de calor para las Zonas Metropolitanas de estudio, cuyos valores rojos representan una mayor cantidad de edificios. . . . .	61
6.1. Zona metropolitana del Valle de México, delimitación 2015. . . . .	65
6.2. Limitante de la zona metropolitana del Valle de México. . . . .	65
6.3. Imágenes ráster de la zona metropolitana del Valle de México. . . . .	66
6.4. Imágenes ráster de factores para la zona metropolitana del Valle de México. . . . .	66
6.5. Edificios en la zona metropolitana del Valle de México. . . . .	67
6.6. Resultados de proyección para la zona metropolitana del Valle de México. . . . .	68
6.7. Edificios en la zona metropolitana del Valle de México. . . . .	69
6.8. Zona metropolitana de Guadalajara, delimitación 2015. . . . .	70
6.9. Imágenes ráster de factores para la zona metropolitana de Guadalajara. . . . .	70
6.10. Edificios en la zona metropolitana de Guadalajara. . . . .	71
6.11. Resultados de proyección para la zona metropolitana de Guadalajara. . . . .	72
6.12. Edificios en la zona metropolitana de Guadalajara. . . . .	73
6.13. Zona metropolitana de Monterrey, delimitación 2015. . . . .	73
6.14. Imágenes ráster de factores para la zona metropolitana de Monterrey. . . . .	74
6.15. Edificios en la zona metropolitana de Monterrey. . . . .	75
6.16. Resultados de proyección para la zona metropolitana de Monterrey. . . . .	75
6.17. Edificios en la zona metropolitana de Monterrey. . . . .	76

6.18. Zona metropolitana de Puebla-Tlaxcala, delimitación 2015. . . . .	77
6.19. Imágenes ráster de factores para la zona metropolitana de Puebla-Tlaxcala. . . . .	78
6.20. Edificios en la zona metropolitana de Puebla-Tlaxcala. . . . .	79
6.21. Resultados de proyección para la zona metropolitana de Puebla-Tlaxcala. . . . .	79
6.22. Edificios en la zona metropolitana de Puebla-Tlaxcala. . . . .	80
6.23. Metrópolis de Tokyo. . . . .	81
6.24. Imágenes ráster de factores para la metrópolis de Tokio. . . . .	82
6.25. Edificios en la metrópolis de Tokio. . . . .	83
6.26. Resultados de proyección para la metrópolis de Tokio. . . . .	83
6.27. Crecimiento vertical en Tokio por año. Imagen obtenida de ( <a href="#">Metropolitan Government, 2019</a> ). . . . .	84
6.28. Edificios en Tokio. . . . .	85
6.29. Crecimiento vertical en zonas metropolitanas de México. . . . .	86

# Índice de tablas

Tabla	Página
2.1. Tipos de crecimiento urbano. . . . .	10
2.2. Definiciones de crecimiento vertical en la literatura. . . . .	11
2.3. Componentes de un autómata celular propuestos por <a href="#">Wolfram (2018)</a> . . . . .	20
2.4. Categorías del comportamiento de un autómata celular. . . . .	20
3.1. Factores que propician el crecimiento urbano vertical reportados en la literatura . . . . .	23
3.2. Estado del arte en crecimiento vertical. . . . .	27
4.1. Factores investigados en trabajos relacionados. . . . .	30
4.2. Factores seleccionados para el diseño del modelo crecimiento vertical. . . . .	31
4.3. Tipos de errores en una imagen satelital y sus tipos de correcciones asociadas. . . . .	32
4.4. Interpretación de resultados basada en la propuesta de <a href="#">Jiménez (2019)</a> . . . . .	41
5.1. Búsqueda de arquitectura óptima en la literatura. . . . .	45
5.2. Resultados de arquitectura de red seleccionada. . . . .	46
5.3. Dimensión en pixeles de las zonas de estudio. . . . .	48
5.4. Clasificación de niveles de intensidad para las imágenes satelitales de las Zonas Metropolitanas. . . . .	56
5.5. Comparación de estadísticos de bondad de ajuste. . . . .	57
5.6. Niveles de confianza para las Zonas Metropolitanas. . . . .	58
5.7. Niveles de riesgo asociados a la clasificación de suelo. . . . .	59
5.8. Nivel de riesgo permitido en vecindad para las Zonas Metropolitanas de estudio. . . . .	60
5.9. Categorías propuestas para la clasificación de niveles de influencia en los mapas de calor de las zonas de estudio. . . . .	61
5.10. Estructura del autómata celular propuesto. . . . .	62
6.1. Resultados de crecimiento vertical para el Valle de México. . . . .	68
6.2. Resultados de crecimiento vertical para la zona metropolitana de Guadalajara. . . . .	72
6.3. Resultados de crecimiento vertical para la zona metropolitana de Monterrey. . . . .	76
6.4. Resultados de crecimiento vertical para la zona metropolitana de Puebla-Tlaxcala. . . . .	80

6.5. Resultados de crecimiento vertical para la metrópolis de Tokio. . . . .	84
6.6. Resumen de resultados de crecimiento vertical proyectado. . . . .	86
6.7. Comparación entre investigaciones de la literatura con el trabajo propuesto. . . . .	87

# Capítulo 1

## Introducción

Uno de los problemas a los que se enfrentan los investigadores y científicos, es el de encontrar modelos o funciones que expliquen cómo se comportan los sistemas que se observan en el entorno. El contar con tales modelos, otorga la posibilidad de predecir el comportamiento de dichos sistemas en el futuro mediante datos de entrada controlados.

En algunas ocasiones es posible encontrar el modelo matemático que explica el proceso mediante el cual se producen los datos que se observan, sin embargo, en ocasiones no es posible encontrarlo, por lo que se debe estimar un modelo que se aproxime lo mayor posible.

Como ejemplo de un fenómeno del cual no es posible explicar a detalle su funcionamiento, se encuentra el crecimiento urbano. La literatura sobre este fenómeno es consistente, entre las técnicas utilizadas con mayor frecuencia para su estudio se encuentran autómatas celulares, regresiones lineales y cadenas de Markov (Jiménez, 2019; Mustafa et al., 2017; Torres et al., 2019). Recientemente, con la evolución tecnológica, la geografía ha comenzado a integrar técnicas de inteligencia artificial en modelos de crecimiento urbano, con el fin de simular el comportamiento de las ciudades o regiones (Silva, 2004), tomando en cuenta los factores humanos que dirigen el crecimiento urbano.

En este sentido destacan modelos basados en agentes (Kaviari et al., 2019), redes neuronales (Chakraborti et al., 2018) y algoritmos genéticos (Pazos Perez et al., 2017) debido a que son técnicas matemáticas que simulan el comportamiento del cerebro humano.

Esto permite construir modelos que se aproximan al fenómeno observado, es así que los modelos de crecimiento urbano con técnicas de inteligencia artificial presentan un área de oportunidad que se encuentra en aumento (Wu and Silva, 2010). Cabe destacar que, la mayoría de estos estudios analizan el crecimiento urbano en su enfoque horizontal, mientras que las investigaciones que analizan el crecimiento urbano vertical son menos numerosas (He et al., 2017; Koziatek and Dragičević, 2017; Lin et al., 2014).

Por lo antes expuesto, en esta tesis se propone el desarrollo y evaluación de un modelo de crecimiento urbano vertical a través de factores característicos utilizando técnicas de inteligencia artificial, adicionalmente, para facilitar el uso del modelo de crecimiento por los planeadores urbanos se busca su integración a Sistemas de Información Geográfico (SIG), los cuales son una herramienta fundamental para el trabajo de especialistas en la planeación urbana (Garrocho, 2016).

### 1.1. Problemática

La expansión urbana o crecimiento urbano es actualmente uno de los temas centrales en la planeación urbana, ya que en este proceso se generan problemas sociales y ambientales. La Organización de las Naciones Unidas (ONU) estima que para el 2030 un 60 % de la población mundial vivirá en ciudades y el 95 % de la expansión urbana se producirá en los países en desarrollo. Por lo que, el desarrollo sostenible dependerá cada vez más de que se planifique el crecimiento urbano (ONU, 2018).

Como consecuencia de la expansión urbana se produce un mayor tiempo de traslado para obtener acceso a servicios y actividades cotidianas y se disminuye la comunicación entre los habitantes. Por otro lado, la creación de nuevos asentamientos en las periferias genera altos costos del gasto público afectando así a la economía (Buzai, 2018) y se destruyen superficies de terreno como bosques, áreas agrícolas y espacios de agua (Koziatek and Dragičević, 2017).

Necesariamente, la expansión urbana es un fenómeno espacio-temporal que incluye crecimiento, tanto horizontal como vertical (Zhang et al., 2017). Sin embargo, la mayoría de las investigaciones que se encuentran en la literatura están enfocadas en el estudio del crecimiento horizontal (Lin et al., 2014; Zhang et al., 2017). Actualmente, en una ciudad con múltiples edificios, si se deja de lado el crecimiento vertical no es posible analizar correctamente la expansión urbana (He et al., 2017).

El ignorar el crecimiento urbano vertical aumenta la probabilidad de sufrir problemas de tráfico, produce ineficiencia en la distribución de edificios comerciales y residenciales (Lin et al., 2014), genera islas de calor (Li and Gong, 2016), mayor consumo eléctrico e incremento de la densidad de población en una superficie de terreno menor (Koziatek and Dragičević, 2017). Por tales motivos, es necesario generar modelos que permitan simular este tipo de crecimiento con el fin de anticiparse a los problemas previamente mencionados.

El crecimiento urbano no se produce de manera aleatoria, sino que resulta de factores generales que permiten formular modelos que lo expliquen (Buzai, 2018). El identificar aquellos factores que influyen en el crecimiento urbano presenta una complejidad que no puede ser resuelta mediante la implementación de técnicas tradicionales como encuestas o discusiones. Como es el caso de la ciudad de Xiamen (China), donde se

utilizan los resultados de una encuesta para apoyar a los tomadores de decisiones a encontrar estrategias de planeación urbana que promuevan la participación pública y gestión de residuos, con resultados poco favorables (Xiao et al., 2017).

De igual manera la planeación del crecimiento urbano no puede ser resuelta utilizando sistemas de información tradicionales, por ejemplo Sistemas de Planificación de Recursos Empresariales, puesto que su enfoque está orientado al procesamiento de datos bajo formatos tabulares. Impidiendo así el análisis de las relaciones entre datos desde una perspectiva espacial (Orellana et al., 2006), a fin de entender, analizar, y visualizar fenómenos del mundo real de acuerdo a sus ubicaciones (Boulos et al., 2019).

La tecnología que participa directamente en el análisis espacial son los Sistemas de Información Geográfica (SIG), los cuales están orientados al estudio de las estructuras y procesos espaciales por lo útil para relacionar lo social y lo espacial (Burrough, 1998). En este contexto, un modelo de crecimiento urbano vertical integrado a un SIG permite una exploración oportuna de escenarios de planificación; contribuyendo también, a la solución de los pocos casos en los que se desarrollan herramientas de software para el análisis espacial (Chávez and Garrocho, 2018), sobre todo para algoritmos generados en investigaciones de planeación urbana.

En el estado del arte se reportan diversas técnicas para detectar el crecimiento urbano vertical, las cuales tienen un rendimiento inferior al 70%. Esto se debe a que no se considera el dinamismo de los factores que propician el crecimiento urbano ya que su naturaleza depende del comportamiento humano (Abdalla and Email, 2019). Por otro lado, investigaciones como VoPham et al. (2018) y Li et al. (2016) sugieren que el 80% de los datos almacenados en las bases de datos actuales son de naturaleza geográfica. Por lo que, se requieren técnicas especializadas que sean capaces de: i) Manipular grandes volúmenes de datos y ii) Simular el comportamiento humano. La inteligencia artificial surge como respuesta al deseo de aproximar el comportamiento y el pensamiento humano para la solución de determinadas problemáticas (Cruz, 2011), además, se ha mostrado capaz de manipular grandes volúmenes de datos (VoPham et al., 2018).

Para contrarrestar los problemas mencionados en los párrafos anteriores es necesario optar por un modelo de crecimiento alternativo que considere los factores de crecimiento de las ciudades y que integre algoritmos basados en inteligencia artificial a fin de resolver problemas no sólo de una manera novedosa, sino sobre todo que permitan tener soluciones eficientes.

## 1.2. Justificación

Estadísticas de la Organización de las Naciones Unidas (ONU) muestran que mientras la tasa de crecimiento anual de la población urbana en México en los últimos 30 años es de 2.7%, la tasa de expansión territorial de las ciudades en el mismo periodo es de 7.4% (ONU, 2011). De acuerdo con el Departamento de

Desarrollo Urbano del Banco Mundial, en las ciudades de países en desarrollo, como México, el área urbana se incrementará de 200,000 a 600,000  $Km^2$  entre los años 2000 al 2030 (Angel et al., 2008).

Las cifras previamente mostradas, muestran la necesidad de una adecuada planeación urbana. Necesariamente, el crecimiento urbano es un fenómeno espacio-temporal que consiste tanto de expansión horizontal como vertical (Zhang et al., 2017). Distinguir dónde se producen estos crecimientos es crucial para tomar decisiones en beneficio de la sociedad, para ello, planeadores urbanos e investigadores han enfocado sus estudios en la generación de modelos urbanos que permitan predecir tales crecimientos.

Sin embargo, como se muestra en el estado del arte, es necesario generar modelos que incluyan tanto crecimiento horizontal como vertical, para tomar decisiones certeras sobre planeación urbana. Así mismo, se muestra que trabajos como (Duque et al., 2019; Torres et al., 2019), consideran el crecimiento urbano como una cuestión de probabilidades en la que no toman en cuenta aquellos factores sociales, económicos o geográficos que producen el crecimiento urbano, lo cual no es la solución óptima, pues un modelo eficiente para proyectar el crecimiento urbano es aquel que entiende al espacio como un efecto de diversos factores (De la Luz Hernández et al., 2017).

Por otro lado, es cada vez mayor el interés en utilizar técnicas de inteligencia artificial combinadas con procesos de análisis espacial (Abdalla and Esmail, 2019; Batty, 2018; Rook and Monk, 2018), como una alternativa novedosa que permita estudiar el complejo y dinámico proceso del crecimiento urbano.

Es así, que es necesario el desarrollo de un modelo que incluya los factores que propician el crecimiento urbano en ambos sentidos (vertical y horizontal). Así mismo, se observa un área de oportunidad para modelar el crecimiento urbano utilizando técnicas de inteligencia artificial, en beneficio de la planeación urbana. Por tales motivos, el interés y motivación de la presente tesis consiste en desarrollar un modelo de crecimiento urbano novedoso que apoye la toma de decisiones en la planeación urbana.

### 1.3. Hipótesis

Un modelo basado en factores de crecimiento y técnicas de inteligencia artificial mejora en al menos 2% la exactitud en la proyección del crecimiento urbano vertical respecto a los modelos propuestos en el estado del arte.

### 1.4. Objetivos

El objetivo general y los objetivos específicos que se pretenden lograr en esta tesis son los siguientes.



## Objetivo general

Diseñar y evaluar un modelo de crecimiento urbano vertical a través de factores de crecimiento característicos utilizando técnicas de inteligencia artificial.

## Objetivos específicos

- Analizar los factores que propician el crecimiento urbano tanto horizontal como vertical, con base en el estado del arte, para su integración a un modelo.
- Evaluar la exactitud de las redes neuronales y autómatas celulares para proyectar el crecimiento de una zona urbana, con base en las implementaciones del estado del arte y bases de datos estándar e imágenes satelitales en formato ráster.
- Codificar el modelo de crecimiento urbano en un lenguaje de programación libre a fin que sea posible su integración a SIG.

## 1.5. Estructura de la tesis

La presente tesis está integrada por los siguientes capítulos:

**Capítulo I Introducción.** Conceptualiza el problema de investigación, el objetivo y la estructura del documento.

**Capítulo II Marco teórico.** Describe los conceptos principales que forman parte de las técnicas utilizadas en la presente tesis. Destacando los temas de factores de crecimiento y técnicas de Inteligencia Artificial.

**Capítulo III Estado del Arte.** Documenta los trabajos relevantes en relación al crecimiento urbano vertical, además se presnetan algunos trabajos sobre crecimiento urbano horizontal.

**Capítulo IV Marco metodológico.** Se describe la metodología propuesta para el diseño del modelo de crecimiento vertical. Se estructura teniendo en cuenta, qué se requiere, cómo hacerlo y qué se espera.

**Capítulo V Modelo de crecimiento vertical** Se detalla el proceso de diseño del modelo de crecimiento vertical y se pone a prueba en la zona de estudio.

**Capítulo VI Experimentación y resultados.** Pone a prueba el modelo propuesto en diferentes zonas de estudio y periodos de tiempo, además se explican los resultados obtenidos.

**Capítulo VII Conclusiones y trabajo futuro.** Se presenta una serie de conclusiones respecto a los temas y resultados de la investigación.

# Capítulo 2

## Marco teórico

En este capítulo se describe la teoría que fundamenta el trabajo de tesis destacando temas como planeación y crecimiento urbano. Se detallan los temas de factores de crecimiento vertical e inteligencia artificial con el objetivo de ganar en claridad sobre la teoría que forma la base para el modelo de crecimiento propuesto.

### 2.1. Planeación urbana

La planeación urbana tiene por objeto apoyar el proceso de toma de decisiones, desarrollando escenarios futuros que permitan evaluar opciones y alternativas para ese futuro deseado (Chaparro, 2014).

Una planeación urbana requiere una serie de procesos orientados al orden y control del crecimiento de las ciudades. Sandercock and Lyssiotis (2003) propone que la planeación urbana debe llevarse a cabo teniendo en cuenta actividades humanas como: habitación, esparcimiento, trabajo y circulación; de esta forma, los planeadores urbanos pueden diseñar la ciudad bajo una visión funcional.

Catanese and Steiss (1968) propone una de las primeras metodologías para la planeación urbana, la cual consta de siete fases:

1. Definición de problemas actuales-futuros, y sus interrelaciones.
2. Predicción de condiciones futuras derivadas de problemas identificables.
3. Identificación de parámetros o restricciones que determinan las posibles soluciones de los problemas.
4. Determinación de metas y objetivos a varios niveles.
5. Formulación de políticas alternativas.
6. Evaluación de costos y simulación de alternativas en el sistema urbano, para comprender el desempeño de la solución propuesta.
7. Recomendación e implementación de las políticas seleccionadas.

El análisis regional y urbano involucra el entendimiento de diversos enfoques como transporte, medio am-

biente, salud, vivienda, construcción y economía (Thakuriah et al., 2017), sin embargo, desde la década de los 60, especialistas urbanos desarrollan modelos de planeación urbana generales que tengan en cuenta la mayoría de los factores de las ciudades (Catanese and Steiss, 1968).

La tecnología actual, permite explorar y entender el sistema urbano a través de los datos que se generan mediante dispositivos con conexión a internet (Rathore et al., 2016), lo que permite generar modelos urbanos con técnicas de Internet de las Cosas, Big Data o Inteligencia Artificial.

A partir de lo anterior puede definirse a la planeación urbana como una disciplina que busca mejorar el bienestar de las personas y sus comunidades mediante el desarrollo de ciudades equitativas, saludables, eficientes y atractivas para las generaciones presentes y futuras (Lee, 2016).

### 2.1.1. Sistemas de información geográfica

Como herramienta de apoyo a la planeación urbana se encuentran los Sistemas de Información Geográfica (SIG), los cuales se definen como un sistema administrador de base de datos capaz de capturar, almacenar, recuperar, analizar y desplegar datos espacialmente definidos (NCGIA, 2018).

La tecnología SIG se ha popularizado debido a que permite al usuario mostrar datos sobre ubicaciones a través de mapas digitales. Los sistemas de gestión de bases de datos tradicionales no permiten el análisis que los SIG realizan. Por ejemplo: Encontrar propiedades a la venta dentro de un radio determinado, con una tasa de crecimiento poblacional del 1% anual y fuera de la zona de terremotos (Ron et al., 2001).

Actualmente los SIG como ArcGIS (ESRI, 2019) o QGIS (QGIS, 2018) se utilizan como sistemas de apoyo para la toma de decisiones, cuya diferencia principal con otros sistemas de información es que trabajan con datos referenciados espacialmente, que pueden ser analizados y convertidos a información para un propósito o aplicación específica (Stanton-Chapman and Chapman, 2006).


## Modelos de representación geográfica

Con el propósito de representar la naturaleza o alguna parte de ella de manera digital se utilizan modelos de representación que permiten almacenar y visualizar datos (Longley et al., 2005). En un SIG los formatos digitales que se utilizan para representar zonas geográficas y sus características son el formato ráster y vectorial (Buzai, 2015).

### a) Formato Ráster

El modelo ráster fue la primera forma de representar la información geográfica en un SIG, según la ESRI (2016b) este modelo consta de una matriz de celdas (o píxeles) organizadas en filas y columnas

(ver Figura 2.1) en la que cada celda contiene un valor que representa información, como la temperatura o el tipo de terreno. El origen de los datos ráster son las fotografías aéreas digitales, imágenes de satélite, imágenes digitales o incluso mapas escaneados.



**Figura 2.1:** Representación del modelo Ráster.  
Obtenido de [ESRI \(2016b\)](#).

La [ESRI \(2016b\)](#) establece que existen dos tipos de datos almacenados en formato ráster para representar fenómenos del mundo real:

- **Datos temáticos:** También conocidos como discretos, los cuales representan entidades como datos de la tierra y su uso.
- **Datos continuos:** Representan fenómenos como la temperatura, la elevación o datos espectrales, entre ellos imágenes satelitales y fotografías aéreas.

### b) Formato Vectorial

Este modelo representa el espacio geográfico mediante figuras de la geometría convencional ([Jones, 2014](#)). La información espacial y la información de los atributos del modelo se vinculan mediante un número de identificación que se proporciona a cada entidad en un mapa ([Campbell et al., 2018](#)).

Se distinguen tres tipos de estructuras de representación en el modelo vectorial (ver Figura 2.2): punto, línea y polígono ([Campbell et al., 2018](#)).



**Figura 2.2:** Representación del modelo Vectorial.  
Obtenido de ([Campbell et al., 2018](#)).

Punto, es un objeto adimensional que contiene un par de coordenadas, esta estructura se utiliza para representar ubicaciones específicas en el espacio. Línea o arco, son objetos unidimensionales formados por una sucesión de puntos, se usan para representar elementos como caminos, ríos, fallas, etc. Un polígono es un objeto bidimensional formado por varias líneas que se repiten para crear un objeto cerrado con

propiedades de área y perímetro.

Existen diferentes formatos de archivo que guardan información vectorial, sin embargo, el formato más aceptado es el *shapefile*, desarrollado por la compañía ESRI. Tal y como se expresa en el *Shapefile Technical Description* (ESRI, 1998) un *shapefile* básico de ESRI se conforma de tres archivos principales:

- **Main file (.shp)**: Archivo en el que cada registro describe una figura con una lista de sus vértices, es decir contiene las características geométricas de los objetos.
- **Index file (.shx)**: Archivo que almacena los índices de las entidades geométricas con el propósito de acelerar su búsqueda.
- **dBASE table (.dbf)**: Base de datos que almacena información de los atributos de cada objeto.

## 2.2. Tipos de crecimiento urbano

El crecimiento urbano, según el Instituto Nacional de Ecología (INEC) es una expansión geográfica-espacial y/o demográfica de un asentamiento humano, ya sea por extensión territorial, por incremento en las densidades de construcción y población, o como generalmente sucede, por ambos aspectos, en forma espontánea o en forma planificada (INEC, 1978).

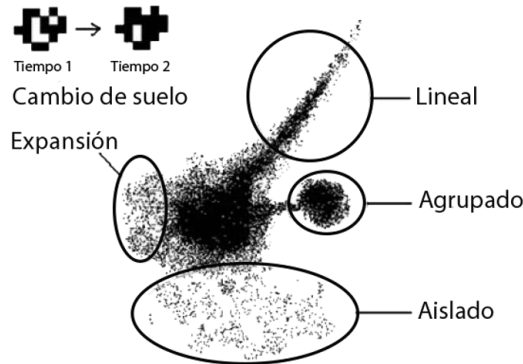
El estudio del crecimiento urbano se concentra en las ciudades y pueblos en términos de su expansión física y demográfica, no en vano es uno de los principales temas de estudio en el campo de la planeación urbana (Hester, 1971), para analizarlo, la geografía se apoya de modelos que permitan realizar proyecciones orientadas a la toma de decisiones de los planeadores urbanos.

El crecimiento urbano puede definirse en relación con los procesos de transformación del paisaje de Forman (2014), los cuales se definen desde la perspectiva de un cambio de uso de suelo (Xu et al., 2007).

Autores como Camagni et al. (2002) distinguen cuatro tipos de crecimiento urbano: cambio de uso, expansión, desarrollo lineal y crecimiento a larga escala. Por otro lado, Wilson et al. (2003) identifica cinco tipos de crecimiento urbano: i) cambio de uso, ii) expansión, iii) aislado, iv) lineal y v) agrupado. La distancia con las áreas urbanas existentes es importante para determinar qué tipo de crecimiento urbano ha ocurrido. La Figura 2.3 muestra estos tipos de crecimiento y la Tabla 2.1 presenta sus definiciones.

**Tabla 2.1:** Tipos de crecimiento urbano.

Tipo de crecimiento	Descripción
Cambio de suelo	Consiste en intercambiar el uso del terreno entre urbano y no urbano (Xu et al., 2007), el cual generalmente ocurre en áreas con servicios públicos (Wilson et al., 2003).
Expansión	También referido como crecimiento urbano marginal (Wilson et al., 2003), se refiere al crecimiento que se extiende a partir de la periferia del área urbana existente (Hao et al., 2012).
Lineal	Define al crecimiento urbano como un nuevo camino, corredor o desarrollo lineal que generalmente está rodeado de suelo no urbano y es continuación del espacio urbano existente (Wilson et al., 2003).
Agrupado	Define un crecimiento urbano típico de un desarrollo compacto y denso (Wilson et al., 2003), el cual ha sido analizado a través de modelos basados en teoría de fractales, siendo Makse et al. (1998) un estudio pionero.
Aislado	Se caracteriza por la existencia de uno o varios asentamientos humanos en terreno no desarrollado (Wilson et al., 2003).



**Figura 2.3:** Tipos de crecimiento urbano. Obtenido de Wilson et al. (2003).

Por otro lado autores como Zhang et al. (2018), He et al. (2017) y Koziatek and Dragičević (2017) definen el crecimiento urbano en tendencia horizontal y vertical.

**a) Crecimiento urbano horizontal**

Se expande sobre la superficie terrestre hacia la periferia del área urbana, caracterizándose por el grado de dispersión que presenta. Algunos autores lo denominan crecimiento urbano 2D (He et al., 2017), pues se expande en terminos de latitud y longitud.

**b) Crecimiento urbano vertical**

El crecimiento urbano vertical o compacto consiste en el incremento de la altura de los asentamientos (Koziatek and Dragičević, 2019). Este crecimiento se denomina tridimensional (3D) (He et al., 2017; Zhang et al., 2017), puesto que las construcciones sobre la superficie terrestre aumentan en altitud.

Pudiera inferirse que para medir el crecimiento vertical de un asentamiento humano se deben obtener datos sobre la altura de las construcciones a través del tiempo (Salvati et al., 2013). Sin embargo, como se muestra

en la Tabla 2.2 en la literatura están documentadas formas alternas para medirlo.

**Tabla 2.2:** Definiciones de crecimiento vertical en la literatura.

Referencia	Definición	Explicación
(Salvati et al., 2013; Zambon et al., 2019)	Altura	Cambio en la altura de las construcciones.
(Lin et al., 2014)	Función de la construcción	La existencia de múltiples funciones o giros que pueden tener las construcciones, por ejemplo, comerciales, habitacionales e industriales.
(Koziatek and Dragičević, 2019)	Densidad de bloque	Incremento en la densidad de construcciones dentro de un bloque.
(Zambon et al., 2019)	Relación piso-área	Establece que la densidad poblacional y actividades económicas conducen al aumento de la relación piso-área.
(Zhang et al., 2017)	Volumen de construcción	El aumento en los volúmenes de construcción refleja el crecimiento tanto vertical como horizontal.

## 2.3. Redes neuronales artificiales

Las técnicas de inteligencia artificial surgen como una respuesta al deseo de aproximar el comportamiento y el pensamiento humano a diversos sistemas para la solución de determinadas problemáticas (Cruz, 2011).

La literatura reporta múltiples definiciones sobre el concepto inteligencia artificial, Romero et al. (2007) la definen como una rama de la ciencia que propone la creación de técnicas que posean un comportamiento inteligente. Schalkoff (1990) la define como un campo de estudio que se enfoca al análisis y simulación de la conducta humana utilizando técnicas computacionales. Para propósitos de esta investigación se adopta la definición propuesta por Cowardin et al. (1988) quienes la definen como una ciencia de la computación cuyo objetivo es simular al proceso del pensamiento humano, a través del uso del software.

La inteligencia artificial ha progresado independientemente de la Geografía (Voženílek, 2009) sin embargo, en la última década del siglo XX la inteligencia artificial se ha utilizado en trabajos de extracción de características geográficas Kaviari et al. (2019), clustering de zonas urbanas (Zhang et al., 2017), modelos de interacción espacial (Wahyudi and Liu, 2016) y proyección de la mancha urbana (Hu et al., 2019).


Las redes neuronales artificiales (RNA) son una técnica de inteligencia artificial cuyo fin es modelar la forma en que el cerebro realiza una tarea, usualmente se implementan en componentes electrónicos o en programas de software (Haykin, 1994). Consisten en un número de neuronas que intercambian información de forma similar a como lo hacen las células biológicas en la sinapsis del cerebro humano (Kristollari and Karathanassi, 2020).

Meade et al. (1995) definen a la red neuronal como una técnica de procesamiento de datos que relaciona conjuntos de información de entrada y salida. Las redes neuronales se entrenan de modo que una entrada determinada conduce a un objetivo de salida específico. Como se muestra en la Figura 2.4 la red se ajusta comparando la salida con el objetivo, el proceso continúa hasta que ambos elementos coincidan (Hajian and Styles, 2018).



**Figura 2.4:** Funcionamiento de una red neuronal.

McCulloch and Pitts (1943) forman el modelo matemático de neurona que sirve como base para los modelos de redes neuronales actuales (Ver Figura 2.5). En dicho modelo cada neurona recibe un conjunto de  $d$  entradas  $x_1, x_2, \dots, x_D$  y genera una única salida  $y$ . En la neurona existen múltiples conexiones con diversos niveles de intensidad entre las distintas entradas que la forman, la intensidad de conexión se determina mediante los  $d$  pesos sinápticos (pesos)  $w_1, w_2, \dots, w_D$ . De manera que cada entrada  $x_i$  de una neurona se encuentra relacionada con un nivel de intensidad determinado por el peso  $w_i$ .



**Figura 2.5:** Modelo de neurona propuesto por McCulloch-Pitts, el cual consta de  $D$  entradas y pesos, una salida  $y$  y la función de activación  $g$ .  
Obtenido de (Palma Méndez and Morales, 2008).

Para obtener la salida  $y$  de la neurona se requieren dos pasos (Palma Méndez and Morales, 2008). En el primero se calcula la suma ponderada  $a$  de las entradas, llamada activación de la neurona.

$$a = \sum_{i=1}^D w_i x_i + w_0 \quad (2.1)$$

Donde  $w_0$  es un *umbral* o *sesgo* que se utiliza para compensar la diferencia entre el valor medio de las entradas y el correspondiente valor medio de las salidas. Posteriormente, a partir de la suma ponderada  $a$ , se obtiene el valor de la salida  $y$  mediante la aplicación de la *función de activación*  $g(a)$ , es decir:



$$y = g(a) = g\left(\sum_{i=1}^D w_i x_i + w_0\right) = g\left(\sum_{i=0}^n w_i x_i\right) \quad (2.2)$$

Donde se observa que es posible tratar el umbral  $w_0$  como un peso más con un valor fijo de 1.

### 2.3.1. Tipos de funciones de activación

Las funciones de activación permiten limitar la amplitud de la salida de una neurona, limita el rango de amplitud permisible de la señal de salida a algún valor finito. La función de activación define la salida de una neurona en términos de la suma ponderada  $a$  (Haykin, 1994). Así, el objetivo principal de una función de activación es el de decidir si una neurona debe ser activada o no.

La función escalón utilizada en el modelo de McCulloch-Pitts se define por la ecuación:

$$y = g(a) = \begin{cases} 0 & \text{cuando } a < 0 \\ 1 & \text{cuando } a > 0 \end{cases} \quad (2.3)$$

Al diseñar una red neuronal generalmente no se tiene conocimiento previo de qué tipo de función de activación es la más adecuada para los datos. Sin embargo, existen cuatro funciones de activación que se encuentran con frecuencia en la literatura (Hajian and Styles, 2018):

1. Función lineal

$$y = g(a) = a \quad (2.4)$$

2. Función sigmoide

$$y = g(a) = \frac{1}{1 + e^{-a}} \quad (2.5)$$

3. Función tangente hiperbólica

$$y = g(a) = \frac{e^a - e^{-a}}{e^a + e^{-a}} \quad (2.6)$$

4. Función Gaussiana

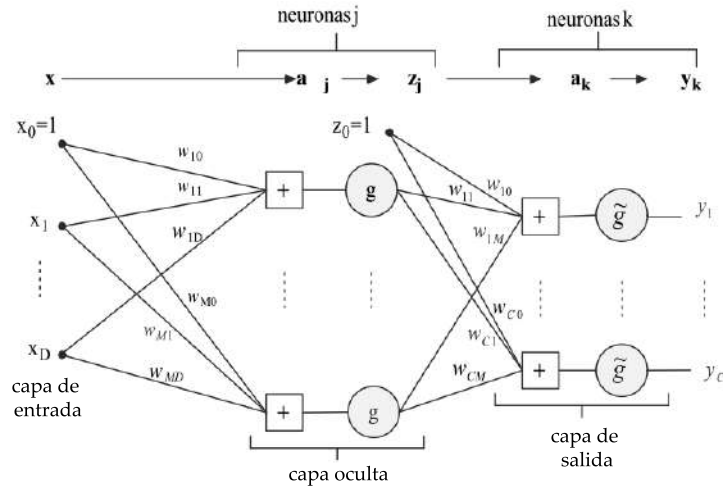
$$y = g(a) = -\exp\left(-\frac{(a - \mu)^2}{2\sigma^2}\right) \quad (2.7)$$

La elección adecuada de las funciones de activación en la red neuronal tiene un efecto significativo en la dinámica de entrenamiento, el desempeño y los resultados de la tarea que se esté realizando (Haykin, 2010). Por tal motivo, autores como (Karlik and Olgac, 2011; Ramachandran et al., 2017) enfocan sus estudios en encontrar la función de activación con mejor aproximación durante la investigación.

### 2.3.2. Perceptrón multicapa

A pesar de que una sola neurona es capaz de realizar numerosas tareas, (Minsky and Papert, 2017) demuestran que existen limitaciones entre la que resalta el hecho de solo poder resolver problemas lineales. Ante esas limitantes se busca el implementar una arquitectura que permita resolver funciones no lineales con el grado de precisión deseado, es así como surge el preceptron multicapa MLP (por sus siglas en inglés, *MultiLayer Perceptron*).

El término multicapa se refiere a la existencia de varios niveles o capas de neuronas, es así que la arquitectura del MLP (ver Figura 2.6) permite aproximar cualquier función continua con cierto nivel de precisión (De Sa, 2012).



**Figura 2.6:** Arquitectura Perceptron Multicapa. Obtenido de (Palma Méndez and Morales, 2008).

La arquitectura mostrada en la Figura 2.6 consiste de una capa con  $D$  entradas,  $M$  neuronas en la capa oculta y  $C$  unidades de salida. El nivel de activación  $a_j$  de la neurona  $j$  de la capa oculta se calcula como una combinación lineal de las  $D$  entradas  $x_i$  que recibe sobre la que, tras aplicar una función de transferencia  $g$  se obtiene la salida  $z_j$  de dicha neurona (Palma Méndez and Morales, 2008):

$$z_j = g(a_j) = g \left( \sum_{i=0}^D w_{ji} x_i \right) \quad (2.8)$$

Donde  $w_{ij}$  es el peso asociado a la neurona  $j$  y la entrada  $x_i$ . Cada salida de la red se obtiene como una suma ponderada de las salidas de las neuronas de la capa oculta, sobre la que se aplica una función de transferencia, así, la salida de la neurona  $k$  está dada por (Palma Méndez and Morales, 2008):

$$y_k = \tilde{g}(a_k) = \tilde{g}\left(\sum_{j=0}^M w_{kj}z_j\right) = \tilde{g}\left(\sum_{j=0}^M w_{kj}g\left(\sum_{i=0}^D w_{ij}x_i\right)\right); k = 1, 2, \dots, C. \quad (2.9)$$

Aunque en la Figura 2.6 se considera únicamente un MLP con una capa oculta, el hecho de añadir capas extra sólo supone repetir las operaciones de las ecuaciones 2.8 y 2.9. Las neuronas de la capa de entrada de la red suministran los elementos del patrón de activación, que constituyen las señales de entrada aplicadas a las neuronas de la segunda capa. Las señales de salida de la segunda capa se utilizan como entradas de la tercera capa, y así sucesivamente para el resto de la red (Haykin, 2010).

El aprendizaje en el perceptrón multicapa se genera en sus pesos mediante una regla de ajuste del error, es decir, se trata de determinar los pesos de las conexiones entre las neuronas de manera que las salidas de la red coincidan con las salidas deseadas, o por lo menos, se aproximen a los resultados buscados (Kristollari and Karathanassi, 2020).

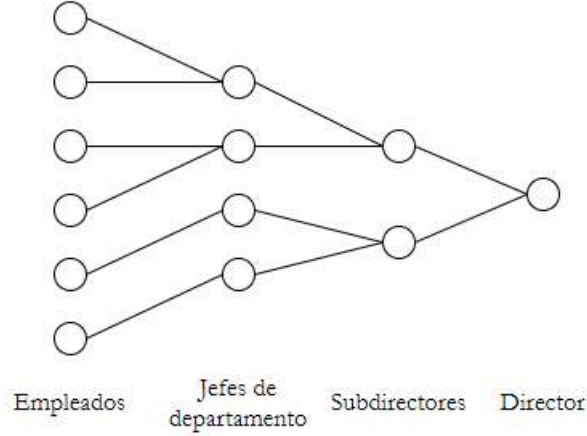
Diferentes arquitecturas de redes neuronales se han generado a partir del perceptrón multicapa sin embargo, esas propuestas están fuera del alcance de esta tesis, para mayor información se recomienda consultar De Sa (2012); Haykin (2010); Kristollari and Karathanassi (2020); Meade et al. (1995).

### 2.3.3. Algoritmo de retropropagación

Es uno de los principales algoritmos para aprendizaje en redes neuronales, y en estudios de crecimiento urbano las redes neuronales de retropropagación prueban ser efectivas (Chakraborti et al., 2018; Hoang and Bui, 2017) por lo que se implementa este tipo de red en el modelo de crecimiento urbano vertical.

El algoritmo de retropropagación minimiza iterativamente una función de error en los resultados de la red, los cuales se validan y si cumplen con el porcentaje esperado termina el proceso de simulación (Rumelhart et al., 1986). Una analogía para entender el algoritmo consiste en analizar el organigrama de una empresa cuyos resultados financieros nos son los esperados, y el director decide tomar acción al percatarse del error que existe en sus finanzas.

Al existir una dependencia de responsabilidad como la que se observa en la Figura 2.7. El director consultara a los subdirectores, estos a los jefes de departamento y estos últimos a los empleados, es decir, el error producido en la empresa se retropropaga a lo largo de la cadena de mando. Posteriormente, cada empleado ajusta su trabajo para reducir el error de la empresa hasta que nuevamente llegan los resultados al director, si estos son correctos la cadena de mando habrá aprendido a ejecutar el trabajo, de lo contrario seguirá continuando el proceso hasta obtener los resultados esperados.



**Figura 2.7:** Organigrama de empresa.

Al resumir los trabajos de [Li et al. \(2018c\)](#), [Haykin and Network \(2004\)](#) y [Rumelhart et al. \(1986\)](#) se identifica que el proceso de aprendizaje mediante el algoritmo de retropropagación consiste en:

1. Inicializar los pesos ( $w$ ) de la red en forma aleatoria.
2. Realizar el entrenamiento de la red con los datos de entrada y los pesos aleatorios.
3. Calcular el error producido por los parámetros de pesos ( $w$ ) y niveles de ajuste ( $b$ ) en la última capa de la red. Donde  $n$  representa el número de capas de la red y  $j$  el número de neurona en la capa  $n$ .

Puesto que los parámetros  $w$  y  $b$  se incluyen en la suma ponderada  $z$  de las neuronas, es decir:

$$z_j^n = \sum_{n=1}^D w_n^j x_n + b_j^n \quad (2.10)$$

Y esta suma ponderada se evalúa por la función de activación ( $a$ )

$$a(z_j^n) \quad (2.11)$$

La cual se evalúa por la función de error  $e$ .

$$e(a(z_j^n)) \quad (2.12)$$

Se requiere del uso del cálculo de las derivadas parciales tanto de los pesos  $w$  como de los niveles de ajuste  $b$ , esto es:

$$\begin{aligned} \frac{\partial e}{\partial w_j^n} &: \text{Derivada parcial del error respecto a los pesos.} \\ \frac{\partial e}{\partial b_j^n} &: \text{Derivada parcial del error respecto a niveles de ajuste.} \end{aligned} \quad (2.13)$$

Dado que estas derivadas se encuentran en una función de funciones que se muestra en 2.12 se hace uso de la regla de la cadena, la cual indica que para calcular la derivada de una función de funciones de deben calcular sus derivadas intermedias, esto es:

$$\frac{\partial e}{\partial w_j^n} = \frac{\partial e}{\partial a^n} * \frac{\partial a^n}{\partial z^n} * \frac{\partial z^n}{\partial w_j^n} \quad (2.14)$$

$$\frac{\partial e}{\partial b_j^n} = \frac{\partial e}{\partial a^n} * \frac{\partial a^n}{\partial z^n} * \frac{\partial z^n}{\partial b_j^n} \quad (2.15)$$

El primer término  $\frac{\partial e}{\partial a^n}$  de las ecuaciones 2.14 y 2.15 representa cómo cambia el error respecto a la activación de las neuronas (Haykin and Network, 2004). Por ejemplo, si se utiliza el error cuadrático medio para evaluar las activaciones:

$$e(a^n) = \frac{1}{2} \sum_{j=1} (y_j - a_j^n)^2 \quad (2.16)$$

Se calcula su derivada:

$$\frac{\partial e}{\partial a^n} = a_j^n - y_j \quad (2.17)$$

El segundo término  $\frac{\partial a_j^n}{\partial z_j^n}$  de las ecuaciones 2.14 y 2.15 representa cómo cambia la salida de una neurona, respecto a la suma ponderada de las salidas de las neuronas (Li et al., 2018c). Por ejemplo, si la activación de las neuronas está dada por una función sigmoideal:

$$a^n(z^n) = \frac{1}{1 + e^{-z^n}} \quad (2.18)$$

Se calcula su derivada:

$$\frac{\partial a^n}{\partial z^n} = a^n(z^n) * (1 - a^n(z^n)) \quad (2.19)$$

Los primeros dos términos de las ecuaciones 2.14 y 2.15 representan la variación del error en función de la suma ponderada, esto indica en que grado se modifica el error cuando hay un cambio en la suma de la neurona (Haykin and Network, 2004; Li et al., 2018c), también se le conoce como error de la neurona y se representa con la letra delta  $\delta$ .

$$\delta^n = \frac{\partial e^n}{\partial z^n} = \frac{\partial e}{\partial a^n} * \frac{\partial a^n}{\partial z^n} \quad (2.20)$$

Por lo que las ecuaciones 2.14 y 2.15 pueden reescribirse de la siguiente forma:

$$\frac{\partial e}{\partial w_j^n} = \delta * \frac{\partial z^n}{\partial w_j^n} \quad (2.21)$$

$$\frac{\partial e}{\partial b_j^n} = \delta * \frac{\partial z^n}{\partial b^n} \quad (2.22)$$

Por último, los términos  $\frac{\partial z^n}{\partial w^n}$  y  $\frac{\partial z^n}{\partial b^n}$  de las ecuaciones 2.14 y 2.15 representan como varia la suma ponderada respecto a una variación de los parámetros de los pesos y niveles de ajuste respectivamente (Haykin and Network, 2004; Li et al., 2018c), al calcular la derivada estos elementos se obtiene:

$$\frac{\partial z^n}{\partial w^n} = a_j^{n-1} \quad (2.23)$$

$$\frac{\partial z^n}{\partial b^n} = 1 \quad (2.24)$$

Al resolver las ecuaciones 2.21 y 2.22 con las ecuaciones 2.23 y 2.24 respectivamente, se obtiene la derivada parcial del error respecto a los pesos:

$$\frac{\partial e}{\partial w^n} = \delta^n * a_j^{n-1} \quad (2.25)$$

Y la derivada parcial del error respecto a los niveles de ajuste:

$$\frac{\partial e}{\partial b^n} = \delta^n \quad (2.26)$$

Con lo que se concluye la etapa del cálculo de errores en la red.

#### 4. Retropropagar el error.

Finalmente, se calculan los errores de la capa  $n-1$  a fin de propagar el error a lo largo de la red. Lo que permite saber cómo cambia la suma ponderada cuando se varia la activación de una neurona en la capa previa (Rumelhart et al., 1986), lo cual está dado por:

$$\frac{\partial z^n}{\partial a^{n-1}} = W^n \quad (2.27)$$

Donde  $W^n$  representa la matriz de pesos que conecta a una capa  $n$  con su anterior capa  $n - 1$ . Por lo que la retropropagación consiste en:

$$\delta^{n-1} = W^n * \delta^n * \frac{\partial a^{n-1}}{\partial z^{n-1}} \quad (2.28)$$

#### 5. Repetir los pasos 1-4 hasta ajustar los pesos de forma que el error sea mínimo o se encuentre un nivel aceptable.

En resumen, el algoritmo de retropropagación consiste en establecer los pesos aleatoriamente, calcular los errores en la capa de salida y propagar el error a través de la red para ajustar los pesos. El proceso se repite durante  $x$  iteraciones hasta que la tasa de error se reduce al mínimo o alcanza un nivel aceptable (Haykin and Network, 2004; Li et al., 2018c; Rumelhart et al., 1986).

## 2.4. Autómatas celulares

El desarrollo de los autómatas celulares (AC) se atribuye al trabajo de Stanislaw Ulam y John Von Neumann durante sus investigaciones en el laboratorio de Los Álamos en Nuevo México. Mientras Ulam estudiaba el crecimiento de los cristales, Von Neumann trabajaba con estructuras o patrones que pueden construir copias de ellos mismos a través del tiempo. Esta es la filosofía central de los autómatas celulares, similar al proceso de evolución biológica, donde las células se replican a sí mismas siguiendo ciertas reglas (Ghosh et al., 2017), es debido a esta similitud con el crecimiento de las células que se les debe su nombre.

Wolfram (2018) expone que los autómatas celulares consisten en una red uniforme y regular (o matriz), con una variable discreta en cada sitio (célula). Cada célula tiene un estado, especificado por el valor de la variable que contiene. Un AC evoluciona en pasos de tiempo discretos, y el valor de la variable en un sitio se ve afectado por los valores de las variables en los sitios de su vecindario en el paso de tiempo anterior. La vecindad de un sitio se considera típicamente como el sitio mismo y todos los sitios inmediatamente adyacentes. Así, las variables de cada sitio se actualizan simultáneamente basándose en los valores de las variables de su vecindario en el paso de tiempo anterior y de acuerdo con un conjunto definido de reglas.

Comúnmente, un conjunto de AC es una matriz rectangular de células de una o dos dimensiones. Sin embargo, también se utilizan otras topologías, por ejemplo, teselaciones pentagonales (Carter and Meyers, 2009) o espacios hiperbólicos (Margenstern, 2007). La estructura de la vecindad, las conexiones entre las células, también pueden cambiar dinámicamente durante la evolución del autómata. Las células de un AC actualizan sus estados simultáneamente, sin embargo, hay una familia de autómatas asíncronos donde las células pueden no tener una regla global (Fatès, 2018).

Los autómatas celulares pueden utilizarse como modelos para una amplia variedad de sistemas físicos, biológicos, geográficos y computacionales. En Wolfram (1983) se examinan varios aspectos y aplicaciones de esta técnica.

### 2.4.1. Estructura de un autómata celular

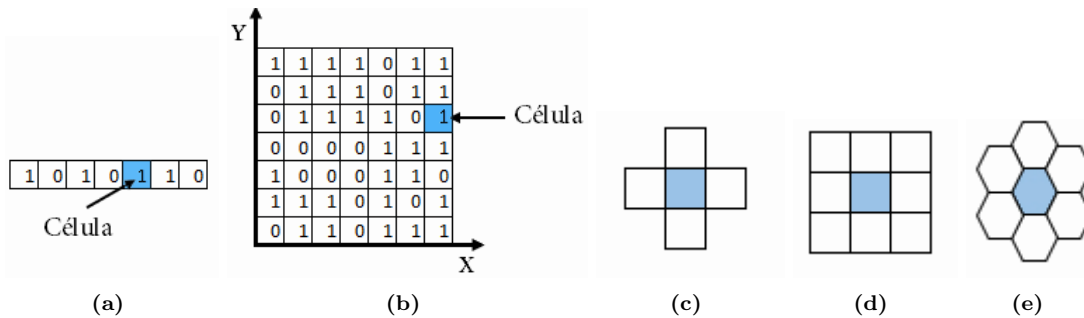
Autores como (Ghosh et al., 2017) y (Kari, 2005) definen matemáticamente a un autómata celular como una estructura de cuatro elementos  $(d, S, H, \delta)$ , donde:

- $d$ : Corresponde a la dimensión del autómata celular.
- $S$ : Conjunto finito de valores o estados que puede tener una célula.
- $H$ : Conjunto de celdas vecinas.
- $\delta$ : Función o regla de transición.

Wolfram (2018) describe la estructura de un autómata celular mediante cinco componentes básicos, espacio n-dimensional, variables o estados, condición inicial, vecindad, función de transferencia; los cuales se describen en la Tabla 2.3.

**Tabla 2.3:** Componentes de un autómata celular propuestos por Wolfram (2018).

Componente	Descripción
Espacio n-dimensional	Lugar donde se ejecuta el autómata celular, puede ser uni o multidimensional donde cada división se llama célula (Ver Figura 2.8).
Variables o estados	Conjunto finito de valores o estados que puede tener una célula (Figura 2.8), también se le denomina alfabeto.
Condición inicial	Consiste en asignar una variable o estado del alfabeto a cada una de las células en el espacio n-dimensional
Espacio de vecindad	Distribución espacial de las células que se considerarán al aplicar las reglas de transición (Figura 2.8).
Función de transferencia	Regla que determina el comportamiento del AC, define como debe cambiar el estado de cada célula, dependiendo de los estados anteriores de sus vecindades. Puede representarse mediante una expresión algebraica.



**Figura 2.8:** Componentes autómata celular: (a) Espacio unidimensional binario, (b) Espacio bidimensional binario, (c) Vecindad de Von Neuman, (d) Vecindad de Moore y (e) Vecindad hexagonal.

La flexibilidad en el comportamiento de los autómatas celulares permite varios niveles de predicción a partir de determinados estados iniciales, tal comportamiento puede estar en alguna de las categorías propuestas por Wolfram (2018) y formalizadas por Culik II and Yu (1988), donde adicionalmente se muestra que no existe algún algoritmo que permita determinar a qué clase pertenece un AC., las cuales se muestran en la Tabla 2.4.

**Tabla 2.4:** Categorías del comportamiento de un autómata celular.

Clase	Comportamiento	Definición
1	Fijo	Las condiciones iniciales convergen a un mismo valor eliminando la aleatoriedad en el patrón inicial.
2	Periódico	Las condiciones iniciales forman estructuras que se repiten continuamente sin aleatoriedad.
3	Caótico	Algunas configuraciones iniciales cambian continuamente de forma no predecible en el espacio.
4	Complejo	Ciertas configuraciones iniciales convergen en patrones inestables o complejos.



## Capítulo 3

# Estado del arte

En este capítulo se documentan trabajos relevantes sobre el crecimiento urbano y los factores que lo propician, se destaca la evolución de los modelos de crecimiento urbano, el trabajo relacionado y los niveles de aceptabilidad que tendrían los ciudadanos en caso de habitar en ciudades verticales.

### 3.1. Factores de crecimiento

El crecimiento urbano no se produce de manera aleatoria, sino que resulta de acciones generales que permiten formular modelos que explican su comportamiento (Buzai, 2018). Aquellas acciones que impulsan el crecimiento urbano, ya sean geográficas, sociales o económicas, se definen en la literatura como *fuerzas impulsoras* o *factores* los cuales son considerados en estudios de planeación urbana y forman parte de los modelos de crecimiento urbano (De la Luz Hernández et al., 2017).

Los factores que producen el crecimiento urbano generan un sistema de dependencias e interacciones que cambian de forma espacio-temporal, lo que dificulta el analizarlos y representarlos adecuadamente (Bürgi et al., 2005). Ciertamente, un modelo de crecimiento urbano no puede considerar todos los factores que producen tal fenómeno, sin embargo, pueden ser separados con el fin de analizar su comportamiento, es así, que para entender el crecimiento urbano se han realizado investigaciones teniendo en cuenta una serie de diversos factores.

Li et al. (2018a) clasifican los factores de crecimiento en tres grupos: geográficos, como distancia a servicios públicos; socioeconómicos, como producto interno bruto; y políticos, como dependencia económica local contra regional. La investigación realizada por Zhao et al. (2017) en México, atribuye el crecimiento urbano a factores como: proximidad a servicios públicos, accesibilidad a recursos, densidad de población, número de zonas industriales, entre otros.

En América Latina el trabajo de Duque et al. (2019) destaca por analizar el crecimiento urbano a partir

de su relación con factores correlacionados como rendimiento económico y las barreras naturales que limitan el desarrollo (topografía). Esta investigación es relevante porque refiere que el crecimiento urbano en países latinoamericanos como México, Brasil y Colombia, no respeta la biodiversidad. Generando así un impacto negativo en el medio ambiente debido a la falta de planeación urbana y modelos de crecimiento.

La investigación hace referencia a que el crecimiento urbano en países latinoamericanos como México, Brasil y Colombia, no respeta áreas protegidas, lo cual pone en peligro la biodiversidad y el medio ambiente, debido a la falta de planeación urbana y modelos de crecimiento que apoyen a los gobiernos locales a diseñar estrategias de urbanización.

Como se puede observar en la Tabla 3.1 existe una variedad de factores que contribuyen al crecimiento vertical, de los cuales, los más frecuentes son: densidad de población, acceso a servicios y tipo de suelo. Debe resaltarse que las investigaciones reportadas en la Tabla 3.1 pertenecen a diversos países, teniendo así un panorama global sobre los factores utilizados para el diseño de modelos de crecimiento vertical.

## 3.2. Crecimiento urbano aplicando técnicas de inteligencia artificial

Para estudiar el fenómeno de crecimiento urbano se proponen modelos que lo analizan desde un enfoque tanto horizontal como vertical (Zhang et al., 2017), de los cuales se describen a continuación algunos trabajos.

La literatura sobre el crecimiento urbano horizontal es extensa dentro de la cual destaca (Kaviari et al., 2019), la cual propone un modelo basado en agentes y teoría de juegos que permite simular la expansión de la mancha urbana en la ciudad de Zanzan (Irán) entre los años 2011 y 2016, debido a que utiliza una técnica de inteligencia artificial el trabajo permite obtener una guía sobre como vincular modelos de crecimiento urbano e inteligencia artificial.

La investigación utiliza imágenes satelitales y datos del censo de población realizado por el Centro Estadístico de Irán. El proceso experimental consiste en identificar los factores de crecimiento de la zona de estudio: accesibilidad, pendiente y precio del suelo para posteriormente proyectar el crecimiento mediante la competencia de los agentes utilizando teoría de juegos. La principal ventaja del modelo basado en agentes y la teoría de juegos, para un problema de modelado urbano, es que juntos pueden representar interacciones y comportamientos sociales, es así que el nivel de exactitud del modelo se encuentra en un rango del 94 % al 97 %.

Investigaciones actuales como Abdalla and Esmail (2019); Boulos et al. (2019); Chow (2018); VoPham et al. (2018), muestran que el utilizar técnicas de inteligencia artificial con técnicas de análisis espacial permite incrementar el nivel de exactitud de las proyecciones. De igual forma, se considera importante tomar en cuenta los factores que propician el crecimiento urbano para tener proyecciones exactas al crecimiento real en los estudios de planeación urbana (Abhishek et al., 2017; Bürgi et al., 2005; De la Luz Hernández et al., 2017; Li

**Tabla 3.1:** Factores que propician el crecimiento urbano vertical reportados en la literatura

Referencia	País	Factores
Duque et al. (2019)	México, Brasil y Colombia	- Densidad de población - Forma de la mancha urbana - Tipo de suelo - Fuerza económica
Chakraborti et al. (2018)	India	- Distancia a servicios - Densidad de población - Concentración de edificios - Zonas restringidas
Gounaridis et al. (2018)	Grecia	- Tipo de suelo - Tasa de empleo - Densidad de población - Tasa de actividad emprendedora
Li et al. (2018a)	China	- Producto interno bruto - Tipo de suelo - Distancia a servicios
Abhishek et al. (2017)	India	- Economía local - Desarrollo tecnológico - Nivel de educación
De la Luz Hernández et al. (2017)	México	- Precio de suelo - Densidad de población - Potencial de mercado - Política interna
Mustafa et al. (2017)	Bélgica	- Distancia a servicios - Tipo de suelo - Acceso a empleos
Zhao et al. (2017)	México	- Densidad de población - Acceso a redes de transporte - Zonas industriales
Wahyudi and Liu (2016)	Estados Unidos, Japón, Corea, Malasia y Nepal	- Acceso a escuelas - Aeropuertos - Economía local - Servicios de salud - Zonas restringidas - Densidad de población
Bičik et al. (2001)	República Checa	- Acceso a recursos - Densidad de población - Desarrollo económico
Rashed et al. (2005)	Israel	- Uso de suelo - Densidad de edificios - Zonas restringidas
Bürgi et al. (2005)	Suiza	- Tipo de suelo - Desarrollo tecnológico - Herencia cultural
Rashed et al. (2005)	Egipto	- Densidad de edificios - Zonas sísmicas

et al., 2018a).

Al respecto, He et al. (2017), proponen un modelo que permite simular de forma simultánea el crecimiento horizontal y vertical de la ciudad de Wuhan (China), utilizando una red neuronal de retro propagación (BPANN), en combinación con la técnica de autómatas celulares. El autómata celular se diseña utilizando factores geográficos y sociales tales como: topografía del terreno, producto interno bruto y densidad de la población; para calcular la probabilidad de crecimiento, teniendo como regla de transición un modelo de regresión lineal, el modelo tiene una precisión del 69.2%, para predecir el crecimiento vertical.

Mediante algoritmos genéticos (AG) Pazos Perez et al. (2017), desarrollan un modelo que permite simular escenarios de crecimiento vertical a través de patrones previos de crecimiento y factores económicos en la ciudad de Tokyo (Japón), utilizando imágenes fotogramétricas 3D, durante el periodo de 1991 a 2015. El primer paso del proceso experimental de la herramienta es el cálculo de índices de accesibilidad a servicios tales como: transporte, salud y escuelas. Para que a partir de ello, se genere un mapa de probabilidad que sirva como entrada del algoritmo genético para calcular el crecimiento vertical de los edificios. La investigación destaca los hallazgos siguientes:

- Precisión del 19.5 % al proyectar la altura de los edificios.
- Precisión del 66.67 % al comparar edificios simulados contra edificios del año 2015.
- Utilizar una herramienta que permita simular escenarios de crecimiento urbano facilita la toma de decisiones a planeadores urbanos y gobiernos locales.

### 3.3. Crecimiento vertical

Respecto al estudio del crecimiento vertical, a través de autómatas celulares, Lin et al. (2014) desarrollan un modelo para calcular la probabilidad de crecimiento vertical en la ciudad de Guangzhou (China), utilizando imágenes raster con datos demográficos, de transporte y de nuevas construcciones durante los años 2000 y 2010. El proceso experimental consta de tres etapas: i) Identificar celdas libres de urbanización, donde para cada una de estas celdas se calcula su probabilidad de cambio de area no urbana a urbana; ii) Identificar celdas ocupadas por edificios, para cada celda identificar sus atributos de construcción y calcular el nuevo crecimiento de la celda; y iii) Generar el mapa de crecimiento urbano. La exactitud media conseguida a través del proceso experimental es de 81.2%.

Desde otro enfoque, Koziatek and Dragičević (2017) generan escenarios de crecimiento vertical a través del software ESRI *CityEngine*, una herramienta perteneciente a ArcGIS, la cual trabaja con métodos tridimensionales que permiten generar edificios en 3D utilizando reglas programáticas basadas en la geometría vectorial existente.

La herramienta funciona con las técnicas de evaluación multicriterio y proceso jerárquico analítico, para la investigación se utilizan datos pertenecientes al censo de Canadá e imágenes satelitales ráster, una vez recopilados los datos, se ingresan a la herramienta, se ejecuta y se analizan los resultados producidos. Para esta investigación, los resultados muestran que el crecimiento vertical tiende a producirse en lugares cercanos a las redes de transporte.

Desde otra perspectiva, [Zhang et al. \(2017\)](#), presentan un modelo para estimar el crecimiento urbano vertical y horizontal, a través de similitud espectral de imágenes obtenidas del satélite Landsat 8. El modelo se divide en tres etapas: clasificación de imágenes, similitud espectral y operaciones morfológicas.

La etapa de clasificación de imágenes consiste en utilizar máquinas de vector soporte (MVS) para clasificar las imágenes en función de su espectro de luz, esto con el fin de separar sombras proyectadas de los edificios, de vegetación, cuerpos de agua, y zona urbana. Una vez clasificados los espectros de luz se utiliza la similitud espectral y cadenas de Markov (CM) para proyectar el crecimiento de la mancha urbana.

Posteriormente mediante operaciones morfológicas enfocadas en detectar las sombras con base en el ángulo del sol, se localizan los pixeles vecinos y se etiquetan como edificios los cuales representan el área potencial de crecimiento vertical. Finalmente, analizando cada celda de la imagen satelital se proyecta dicho crecimiento, lo que genera los siguientes resultados:

- Exactitud que varía en el rango 91.7%-94.3 % durante la etapa de preclasificación.
- Exactitud media del 65.2 % para el crecimiento vertical, considerando altura.
- El obtener imágenes satelitales, libres de ruido mejora la exactitud durante la preclasificación.
- La exactitud del modelo se reduce en zonas con múltiples edificios, debido al fenómeno de oclusión, en este caso, la sombra proyectada por el edificio más alto oculta la de los edificios cercanos.
- Los edificios que proyectan sombras con poca distancia no son detectados.

La escasez de tierras disponibles en las ciudades con alta densidad de hogares y edificios exige maximizar su utilidad, motivo por el que se desarrollan modelos de crecimiento urbano vertical, sin embargo, autores como [Mualam et al. \(2019\)](#); [Wong \(2004\)](#) realizan investigaciones sobre la percepción, actitudes, preocupaciones y aceptación por parte de los posibles residentes de una ciudad vertical.

El trabajo de [Mualam et al. \(2019\)](#) destaca el concepto de mezclar la propiedad pública y privada con los servicios públicos dentro de una sola estructura. La mezcla de servicios públicos y privados se considera producto de una ideología ambiental que promueve la sustentabilidad y la idea de crear una ciudad compacta, caracterizada por una densidad relativamente alta que permita una movilidad eficiente en el espacio.

Sin embargo, existen algunas barreras para la mezcla de los servicios públicos y privados dentro de un mismo edificio. Al analizar 58 planes de crecimiento vertical de empresas constructoras en la ciudad de Tel

Aviv (Israel) se destacan las siguientes limitantes:

- Negociaciones de acuerdos entre accionistas a fin de evitar conflictos por espacios de los edificios.
- El proceso de diseño suele ser costoso y tardado debido a la necesidad de abordar las preocupaciones sobre ruido, tráfico, estacionamiento, seguridad y protección de cada accionista.
- Tanto promotores como inversionistas corren el riesgo de que cualquiera de los socios sea incapaz de cumplir sus obligaciones financieras con el proyecto cuando se produzcan sobrecostos o gastos operativos imprevistos.

La literatura reporta diversos beneficios como parte del crecimiento urbano vertical. Por ejemplo, genera un tipo de planificación sostenible, ya que tiende a generar ahorros en la construcción de infraestructura pública por ejemplo la construcción de carreteras y en instalaciones de transporte. Las ciudades verticales garantizan distancias de viaje cortas entre residencias y lugares de trabajo, reduciendo la carga de tráfico causada por la dependencia de desplazamientos diarios (Mualam et al., 2019).

La planificación del uso mixto en edificios, como parte del crecimiento urbano vertical, también tiene sentido desde el punto de vista funcional, ya que la combinación del espacio residencial con oficinas e instalaciones comerciales produce un uso eficiente del terreno disponible al utilizar el espacio las 24 horas del día, con diferentes funciones (Shim et al., 2004). La percepción ante estas ventajas teóricas debe ser estudiada por Wong (2004), el cual realiza investigación cuyo objetivo es conocer el nivel de aceptabilidad que tienen las personas que podrían habitar en una ciudad vertical.

Para lograr el objetivo propuesto se realiza un conjunto de encuestas, cuyas respuestas se evalúan mediante los valores 0 (No) y 1 (Si), a los habitantes de la ciudad de Singapur. En la encuesta se exponen las características positivas y negativas de vivir en una ciudad vertical.

Los resultados revelan que menos de la mitad de la población de Singapur (48.2%) elegiría vivir en ciudades verticales. Se observa que las parejas jóvenes, particularmente los hombres, tienden a ser más receptivos a esta forma de vivienda. Los principales atractivos de las ciudades verticales son las vistas panorámicas y el entorno ventoso. Por otro lado, las principales preocupaciones, son los precios de la vivienda, la seguridad de la estructura de los edificios, la insuficiencia de instalaciones y la búsqueda de estacionamiento.

En términos de preferencia del nivel de piso la mayoría de los encuestados (51.9%) prefieren vivir en los primeros 20 pisos del edificio, mientras que solo el 10% prefiere hacerlo en el piso 40 o superiores. Estos resultados tienen importantes repercusiones para los encargados de diseños de edificios, especialmente en las ciudades donde el espacio de terreno es una limitación importante, y la única forma de crecimiento es vertical.

Finalmente, en la Tabla 3.2, donde se comparan las diferentes investigaciones en crecimiento vertical, se observa que la mayoría de los estudios utilizan modelos de análisis espacial, como autómatas celulares o cadenas

de Markov para proyectar el crecimiento urbano. Se destacan (en color rojo) los trabajos que utilizan técnicas de inteligencia artificial. Aunque predominan las investigaciones con imágenes ráster, el nivel de exactitud en las investigaciones es similar a la lograda respecto a los estudios de imágenes LiDAR o fotogramétricas. Los estudios que consideran factores en sus investigaciones, hacen uso de técnicas estadísticas como: análisis principal de componentes (PCA), evaluación multicriterio (MCE) o estadística descriptiva, para identificar aquellos factores que influyen en el crecimiento urbano. Trabajos como el de [Zhang et al. \(2017\)](#) no considera los factores como parte del modelo de crecimiento urbano. Cabe destacar también que la mayoría de las investigaciones no alcanzan el 70% de efectividad, siendo el trabajo de ([Zhang et al., 2018](#)) el que obtuvo la mejor exactitud con un 72.0%.

**Tabla 3.2:** Estado del arte en crecimiento vertical.

Referencia	Técnica	Base de datos	Tipo imagen	Exactitud
<a href="#">Koziatek and Dragičević (2019)</a>	MCE	LiDAR	Fotogramétricos	No disponible
<a href="#">Handayani et al. (2018)</a>	MCE	LiDAR	Fotogramétricos	65.3 %
<a href="#">Zhang et al. (2018)</a>	MC <sup>1</sup>	LandSat	Ráster	72.0 %
<a href="#">Pazos Perez et al. (2017)</a>	GA <sup>2</sup>	Google 3D	Fotogramétricos	66.7 %
<a href="#">Zambon et al. (2019)</a>	PCA	LandSat	Ráster	60.0 %
<a href="#">Zhang et al. (2017)</a>	SVM+MC+MO <sup>3</sup>	LandSat	Ráster	66.0 %
<a href="#">He et al. (2017)</a>	BPNN+CA <sup>4</sup>	LandSat	Ráster	65.2 %
<a href="#">Koziatek and Dragičević (2017)</a>	CityEngine	LandSat	Ráster	63.1 %
<a href="#">Agyemang et al. (2018)</a>	Estadística Descriptiva	Instituciones públicas	Vector	No disponible
<a href="#">Félix (2015)</a>	Estadística Descriptiva	INEGI	Vector	No disponible
<a href="#">Lin et al. (2014)</a>	CA	LandSat	Ráster	68.8 %
<a href="#">Benguigui et al. (2008)</a>	CA	Datos socioeconómicos	Ráster	No disponible

<sup>1</sup> : Cadenas de Markov <sup>2</sup> : Algoritmos genéticos <sup>3</sup> : SVM: Support Vector Machines; MO: Operaciones morfológicas <sup>4</sup> : BPNN: Red neuronal de retropropagación; CA: Autómatas celulares

Como se observa en la Tabla 3.2 las técnicas para estudiar el crecimiento urbano vertical son variadas y difieren tanto en los datos de trabajo como en el nivel de complejidad, sin embargo, el promedio de exactitud de los modelos presentados es apenas superior al 66%, por lo que esta línea de investigación representa un área de oportunidad importante.

Desde la perspectiva de los posibles residentes de una ciudad vertical, los tomadores de decisiones deben lograr un equilibrio para garantizar la seguridad en los edificios y que sea apropiada para los ciudadanos. Mediante la simulación de escenarios de crecimiento vertical, con los modelos presentados anteriormente, los planificadores urbanos podrán tener decisiones sólidas con mejores fundamentos para los futuros cambios en las ciudades y anticipar nuevas necesidades de infraestructuras o reglamentos.

# Capítulo 4

## Marco metodológico

En este capítulo se describe el marco metodológico para el desarrollo de la presente investigación, el cual está formado por cuatro etapas.

### 4.1. Generalidades

Para diversas ciudades del mundo como México, China o Nueva York, el crecimiento vertical se ha convertido en una alternativa contra la expansión urbana, de igual forma se muestra como una expresión de su cultura, que representa tanto la modernidad como la gestión territorial por parte de sus líderes políticos y planeadores urbanos, así mismo refleja el poder económico alcanzado por la ciudad (Bharne, 2012).

Una buena gestión territorial es producto de investigación científica aplicada a estudios de crecimiento urbano, pues esta puede influir en los planeadores urbanos y líderes políticos a tomar mejores decisiones con fundamentos sólidos al momento de diseñar una ciudad (van Oort, 2017).

En esta investigación, la metodología de investigación para el diseño del modelo de crecimiento vertical tiene como base el método científico, pues permite ordenar el proceso de investigación y con ello detallar lo que se pretende lograr (Bunge, 2016). Esta estrategia de investigación científica se complementa con revisión de la literatura existente (Ver Sección 3.3: Trabajo relacionado).

Dicha metodología se conforma por cuatro etapas mostradas en la Figura 4.1, cuya orientación es el diseño y evaluación de un modelo de crecimiento urbano vertical a través de factores de crecimiento característicos utilizando técnicas de inteligencia artificial.



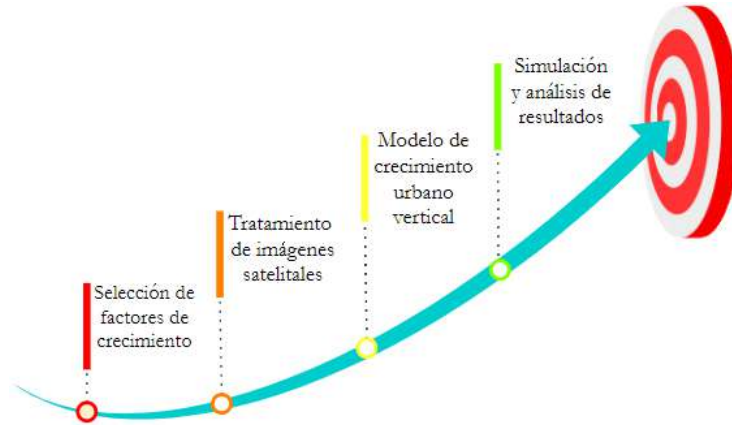


Figura 4.1: Metodología propuesta.

Las siguientes secciones detallan cada una de las etapas mostradas en la Figura 4.1.

## 4.2. Selección de factores de crecimiento

El crecimiento urbano no se produce de manera aleatoria, sino que resulta de acciones generales que permiten formular modelos que explican su comportamiento (Buzai, 2018). Aquellas acciones que impulsan el crecimiento urbano, ya sean geográficas, sociales o económicas, se definen en la literatura como *fuerzas impulsoras* o *factores*, los cuales son considerados en estudios de planeación urbana y forman parte de modelos de crecimiento urbano (De la Luz Hernández et al., 2017).

Ciertamente, un modelo de crecimiento urbano no puede considerar la totalidad de factores que producen tal fenómeno por lo que pueden ser separados con el fin de analizar su comportamiento (Bürigi et al., 2005), por lo que las investigaciones toman en cuenta un conjunto específico de factores como los referidos en la sección 3.1 del estado del arte.

Para determinar qué factores se han utilizado en la literatura y cuáles considerar en el diseño del modelo de crecimiento vertical propuesto se utiliza el proceso de revisión literaria propuesto por Tranfield et al. (2003).

El proceso de identificación y selección genera un total de 43 artículos con factores pertenecientes a los países de: Bélgica, Brasil, China, Colombia, Corea, Egipto, Estados Unidos, Grecia, India, Israel, Malasia, México, Nepal, Republica Checa y Suiza.

Clasificados en cinco categorías: i) De proximidad, ii) Sociales, iii) Económicos, iv) Geográficos y v) De vecindad, conforme a las propuestas de De la Luz Hernández et al. (2017), Chakraborti et al. (2018) y Mustafa et al. (2017).

Al resumir y descartar factores de cada uno de los artículos seleccionados, se identifica un total de 104 factores, 26 clasificados como sociales, 14 como factores de proximidad, 32 como económicos, 24 geográficos y 8 como factores de tipo vecindad. La lista de los factores identificados se presenta en la Tabla 4.1.

**Tabla 4.1:** Factores investigados en trabajos relacionados.

<b>Sociales</b>		
- Capital humano	- Centros de compras	- Centros de negocios
- Densidad de población	- Desarrollo planeado	- Escuelas
- Estructura urbana externa	- Población no agrícola	- Política de suelo
- Servicios de salud	- Sitios industriales	- Terrenos del gobierno
- Educación inicial	- Población total	- Población agrícola
- Gobernanza	- Herencia colonial	- Infraestructura pública
- Jardines	- Lugares de recreación	- Lugares temáticos
- Migración	- Módulos de policía	- Políticas territoriales
- Regulación de zonas	- Total de viviendas	
<b>De proximidad</b>		
- Distancia a áreas verdes	- Distancia a formaciones geológicas	- Distancia a la naturaleza
- Distancia a autopistas	- Distancia a los centros de la ciudad	- Distancia al río más cercano
- Distancia a caminos	- Distancia a redes de transporte	- Distancia a servicios
- Distancia a canales	- Distancia al océano	- Distancia a casetas
- Distancia a ciudad central	- Distancia a pueblos principales	
<b>Económicos</b>		
- Aeropuertos	- Ingresos	- Inversión inmobiliaria
- Capital de estado ficticio	- Land value (Precio de terreno)	- Medidas económicas
- Capital externo	- Ciudad portuaria	- Mercado
- Clima financiero	- Empleos	- Costos de transporte
- Mezcla industrial	- Economía local vs regional	- Producto Interno Bruto
- Desarrollo económico	- Producción industrial	- Fuerza económica
- Renta de terrenos	- Potencial de mercado	- Salarios urbanos
- Precio de suelo	- Tasa anual de crecimiento	- Tasa de empleo
- Población económicamente activa	- Tasa de edificios	- Tasa de emprendimiento
- Tendencias económicas	- Tecnología	- Tasa de ganadería
- Tasa de agricultura	- Tasa de desempleo	
<b>Geográficos</b>		
- Calidad del suelo	- Genética del suelo	- Orientación del suelo
- Campos de cultivo	- Otros tipos de medio ambiente	- Topología
- Áreas protegidas	- Topografía	- Patrones de uso de suelo
- Áreas verdes	- Elevación	- Restricción de bosques
- Cuerpos de agua	- Forma de la mancha urbana	- Restricción de cuerpos de agua
- Densidad de suelo urbano original	- Fragmentación del paisaje	- Restricción de pantanos
- Disponibilidad del suelo	- Tipos de suelo	- Restricción de parques nacionales
- Áreas protegidas	- Reservas de bosques	- Pendiente
<b>De vecindad</b>		
- Bloques de edificios	- Efecto de vecindad	- Área industrial
- Concentración de edificios	- Densidad de ciudades industriales	- Áreas de desarrollo urbano
- Áreas desarrolladas existentes	- Densidad de redes de transporte	

Debido a la disponibilidad georreferenciada en archivos vectoriales y la compatibilidad de datos durante el periodo 2015 en bases de datos oficiales mexicanas como el Instituto Nacional de Estadística y Geografía (INEGI), Instituto Nacional para el Federalismo y el Desarrollo Municipal (INAFED), Consejo Nacional de Población (CONAPO), Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT) y el Sistema de Información Empresarial Mexicano (SIEM), los factores de la investigación se presentan en la Tabla 4.2:

**Tabla 4.2:** Factores seleccionados para el diseño del modelo crecimiento vertical.

Categoría	Factor	Fuente	Tipo de dato
Social	Población total	Encuesta Intercensal 2015 (INEGI)	Vectorial (.shp)
Social	Total de viviendas	Encuesta Intercensal 2015 (INEGI)	Vectorial (.shp)
Económico	Infraestructura de servicios	Principales datos socioeconómicos por municipio del 2015 (INAFED)	Vectorial (.shp)
Económico	Población económicamente activa	Principales datos socioeconómicos por municipio del 2015 (INAFED)	Vectorial (.shp)
Geográfico	Tipo de suelo	Satélite Landsat 8 Imágenes satelitales 2015 y 2020	Ráster (.tif)
De vecindad	Efecto de vecindad	Imágenes satelitales 2015	Ráster (.tif)

En la sección 4.3 se muestra cómo tratar estos factores de forma espacial utilizando mapas vectoriales (.shp) e imágenes satelitales (.tif).

### 4.3. Tratamiento de imágenes

La etapa de tratamiento de imágenes se divide en dos procesos principales, el primero corresponde al procesamiento de la imagen satelital lo que permite resaltar la zona urbana de interés. La segunda etapa consiste en rásterizar mapas vectoriales, esto permite representar espacialmente los datos conforme a la zona de estudio definida en la primera etapa.

#### 4.3.1. Imágenes satelitales

Para procesar imágenes satelitales autores como [Burton-Johnson et al. \(2016\)](#); [de Graaf et al. \(1992\)](#); [Gómez Vargas et al. \(2013\)](#) proponen un conjunto de pasos que permiten identificar las zonas de interés, a fin de desarrollar modelos predictivos que permitan apoyar a los tomadores de decisiones en cuestiones de administración territorial.

Al identificar los pasos propuestos por los autores citados previamente, en esta tesis se sintetizan buscando tanto su homogeneidad como complementación con el objetivo de trabajar con imágenes satelitales y resaltar zonas urbanas utilizando las imágenes provenientes del satélite Landsat 8. En la Figura 4.2 se presenta el proceso de tratamiento de las imágenes satelitales.

**Figura 4.2:** Etapas realizadas en el tratamiento de imágenes satelitales.

4.3.1.1. Ubicación y descarga de zona de estudio

Esta etapa consiste en localizar imágenes satelitales del área de estudio (Ciudad de México) provenientes del satélite Landsat 8, cuyo repositorio se encuentra en (USGS, 2020).

Para descargar imágenes ráster es necesario registrarse posteriormente, localizar la zona de estudio mediante coordenadas en grados. La página web (USGS, 2020) ofrece la opción de cubrir el mapa con una malla que incluye las coordenadas de latitud y longitud, facilitando la ubicación de zonas de estudio. Una vez ingresados los criterios de búsqueda para la imagen satelital se muestran las imágenes que coinciden con los criterios seleccionados.

Como ejemplo, en la Figura 4.3 se realiza una búsqueda para imágenes de la Ciudad de México, con un porcentaje de nubosidad menor al 10 %, para los años 2015 y 2020.

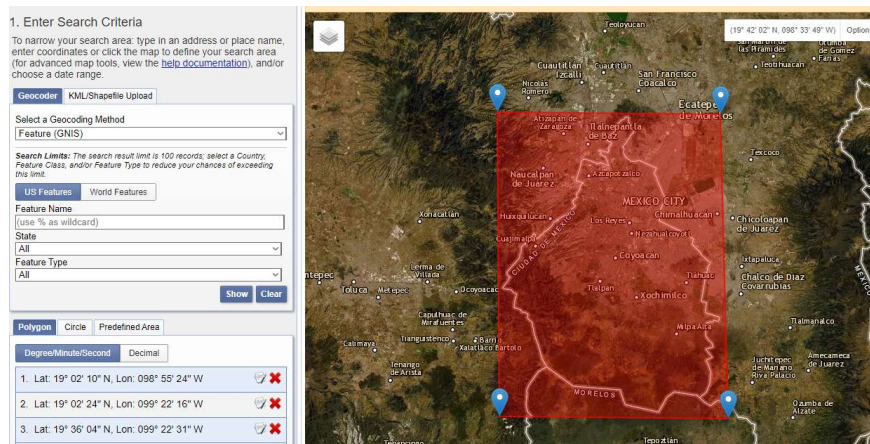


Figura 4.3: Seleccionando como zona de estudio a la Ciudad de México del repositorio del satélite Landsat 8.

4.3.1.2. Preprocesamiento de imágenes

Irons et al. (2012) sugieren que el periodo de vida de los sensores que conforman al satélite Landsat 8 y las características meteorológicas del planeta, provocan errores durante la captura de la imagen. La Tabla 4.3 muestra ejemplos de errores y el proceso de corrección asociado.


Tabla 4.3: Tipos de errores en una imagen satelital y sus tipos de correcciones asociadas.

Tipo de error	Consecuencia	Tipo de corrección
Fallo en los sensores.	Ruido en las imágenes	Radiométrica
Alteración en el movimiento del satélite y el mecanismo de captura de los sensores	Distorsión en la imagen	Geométrica
Interferencia atmosférica	Alteración de valores en pixeles	Atmosférica

Por lo que, una vez descargada la imagen ráster se intenta reducir los errores producidos al tiempo de su captura. Como se observa en la Tabla 4.3 los tipos de correcciones son atmosférica, radiométrica y geométrica, los cuales se describen a continuación:

### Corrección atmosférica

Los efectos atmosféricos en las imágenes satelitales distorsionan la información disponible dentro de las bandas satelitales. Esta corrección se aplica con el propósito de eliminar los efectos de interacción del sensor con la atmósfera, lo que mejora la calidad visual de la imagen reduciendo el ruido atmosférico (Arias et al., 2014), como se muestra en la Figura 4.4.




**Figura 4.4:** Ejemplo de corrección atmosférica en imagen ráster, mediante el proceso de corrección se reduce el ruido ocasionado por la nube.

### Corrección radiométrica

Permite ajustar los niveles digitales erróneamente registrados en la imagen por los sensores del satélite durante la toma (Ver Figura 4.5). Para aplicar una corrección radiométrica se distinguen cuatro posibles soluciones (Yuan and Elvidge, 1996):


- Corrección lineal de los histogramas.
- Ajuste lineal de los valores máximo y mínimo de la imagen a normalizar con respecto a la de referencia.
- Ajuste lineal en función de la media y la desviación típica de los niveles vecinos.
- Interpolación de datos.



**Figura 4.5:** Ejemplo de corrección radiométrica en imagen satelital, a través del ajuste lineal en función de la media de niveles vecinos.

### Corrección geométrica

Requiere de dos imágenes ráster y consiste en la transformación de las coordenadas de los píxeles de la segunda imagen de tal forma que coincidan con las de la primera, la cual es la imagen de referencia (Ambrosio et al., 2002), como se muestra en la Figura 4.6.



**Figura 4.6:** Ejemplo de corrección geométrica en imagen ráster.

Al momento de tomar una imagen satelital se pueden presentar diferentes razones que den motivo a una corrección geométrica, siendo los más comunes: i) Frecuencia de escaneo del sensor, ii) Retraso en tiempo de captura, iii) Variaciones en la velocidad y altura de la plataforma de registro.

#### 4.3.1.3. Combinación de bandas satelitales

Los métodos de combinación de bandas conocidos técnicamente como *Pan-sharpening* permiten fusionar bandas de imágenes satelitales. Con este proceso se consigue mayor resolución en las bandas multispectrales a partir de la información de la banda pancromática, permitiendo resaltar las zonas de interés (Sabater et al., 2016), área urbana para el caso de esta investigación.


En el proceso *Pan-sharpening* combinar bandas satelitales de baja resolución con la banda pancromática (PAN) de alta resolución, creando una imagen de color realizada, por lo que es posible utilizar bandas de distinta resolución para combinarse. Este proceso conserva la fidelidad del color original y permite mejorar la visualización e interpretación de la nueva imagen.

Para combinar las bandas satelitales se utiliza el método ESRI, el cual ha probado tener buenos resultados en la combinación de las bandas satelitales. La transformación de fusión de imágenes de ESRI utiliza un promedio ponderado y la banda infrarroja cercana adicional (opcional) para crear las bandas de salida fusionadas. El resultado del promedio ponderado se utiliza para crear un valor de ajuste que después se utiliza en el cálculo de los valores de salida (ESRI, 2016a).

Para el modelo de crecimiento vertical se utiliza el PCA de la combinación de bandas de la Ciudad de México, las imágenes resultantes se muestran en la Figura 4.7.

#### 4.3.1.4. Extracción de zona urbana

En esta etapa se clasifican diferentes tipos de suelo presentes en una imagen satelital como: área urbana, vegetación, agua, entre otros. Siendo la propuesta por Bhatti and Tripathi (2014) una metodología con buenos resultados de clasificación, la cual calcula tres índices que permiten resaltar zona urbana, estos son: vegetación (NDVI), agua (MNDWI) y superficies edificadas (NDBI).



**Figura 4.7:** Combinación de bandas satelitales de la Ciudad de México. (a) PCA de la combinación de bandas 6-7, (b) PCA de la combinación de bandas 10-11.

### Índice de vegetación (NDVI)

El índice de vegetación de diferencia normalizada continua (*NDVI* por sus siglas en inglés) estima la cantidad, calidad y desarrollo de la vegetación con base en la radiación de ciertas bandas que contemplan el espectro electromagnético de la vegetación (Bhatti and Tripathi, 2014), el cual se define como:

$$NDVI = \frac{Band(4) - Band(3)}{Band(4) + Band(3)} \quad (4.1)$$

El resultado del índice produce valores en un rango de  $-1$  a  $1$  (Ver Figura 4.8(a)), con los umbrales definidos en la Ecuación 4.2 (Bhatti and Tripathi, 2014):

$$NDVI = \begin{cases} \text{Agua y nieve} & \text{si } NDVI < 0.0 \\ \text{Ausencia de vegetación} & \text{si } 0.0 < NDVI < 0.1 \\ \text{Áreas rocosas, arenosas o nevadas} & \text{si } 0.1 \lesssim NDVI \lesssim 0.2 \\ \text{Áreas con arbustos o pasturas} & \text{si } 0.2 \lesssim NDVI \lesssim 0.3 \\ \text{Vegetación frondosa} & \text{si } NDVI > 0.3 \end{cases} \quad (4.2)$$

### Índice de agua (MNDWI)

Reduce el traslape espectral entre las áreas construidas y no construidas, argumentando que en las áreas no construidas es probable que las superficies tengan un mayor contenido de agua que las áreas construidas (Ver Figura 4.8(b)).

Al eliminar las firmas de agua en la imagen de salida y aumentar el contraste espectral entre el área construida, la tierra desnuda y otras clases de cobertura del suelo, se utiliza el índice MNDWI el cual procesa bandas espectrales capturadas por el sensor infrarrojo de Landsat 8 extrayendo áreas de agua (Han-Qiu, 2005), el cálculo de este índice se realiza a partir de:

$$MNDWI = \frac{Band(3) - Band(7)}{Band(3) + Band(7)} \quad (4.3)$$

Los valores del índice MNDWI se encuentran en el intervalo de -1 y 1, con los umbrales definidos en la Ecuación 4.4 (Bhatti and Tripathi, 2014):

$$MNDWI = \begin{cases} \text{Zonas sin vegetación o agua} & \text{si } MNDWI < 0 \\ \text{Zonas con vegetación o agua} & \text{si } MNDWI > 0 \end{cases} \quad (4.4)$$

#### Superficies edificadas (NDBI)

El índice de diferencia normalizada edificada (NDBI, por sus siglas en inglés) se basa en el PCA de los pares de bandas combinadas 6-7 y 10-11 para resaltar áreas construidas (Ver Figura 4.8(c)), se calcula como:

$$NDBI = \frac{PCA(Band(6, 7)) + PCA(Band(10, 11)) - Band(5)}{PCA(Band(6, 7)) + PCA(Band(10, 11)) + Band(5)} \quad (4.5)$$

Los valores del índice NDBI se encuentran en el intervalo de -1 y 1, con los umbrales definidos en la Ecuación 4.6 (Bhatti and Tripathi, 2014):

$$NDBI = \begin{cases} \text{Zonas con vegetación} & \text{si } NDBI < 0 \\ \text{Zonas de cultivos o en fase de construcción} & \text{si } 0 < NDBI < 0.5 \\ \text{Zonas de construcción} & \text{si } NDBI > 0.5 \end{cases} \quad (4.6)$$

#### Índice BAEM

Finalmente, los índices NDVI, MNDWI y NDBI permiten extraer el área edificada libre de áreas de agua y vegetación (Ver Figura 4.8(d)), el cálculo de este índice es:


$$BAEM = NDBI - NDVI - MNDWI \quad (4.7)$$

El resultado de la Ecuación 4.7 produce una imagen en escala de grises donde valores cercanos a 255 indican áreas construidas, mientras que los valores cercanos a 0 representan clases de cobertura terrestre distintas de la urbana (Bhatti and Tripathi, 2014).


#### 4.3.2. Rasterización de datos vectoriales

Convertir mapas vectoriales a formato ráster permite utilizar ambos tipos de datos cuando se desarrolla un modelo urbano, esto incrementa la flexibilidad del modelo, las fuentes de datos y los métodos de procesado para el modelo final (QGIS, 2019). En resumen, la Figura 4.9 muestra los pasos realizados para la rasterización de un mapa vectorial.





**Figura 4.8:** Índices para la Ciudad de México. (a) NDVI, (b) MNDWI, (c) NDBI y (d) BAEM.



**Figura 4.9:** Pasos realizados para la rasterización de mapas vectoriales.

#### 4.3.2.1. Descarga de datos de estudio

En México, el Instituto Nacional de Estadística y Geografía (INEGI) colecta la información de los factores de población y vivienda a través de la Encuesta Intercensal 2015, la cual se lleva a cabo con la finalidad de actualizar la información sociodemográfica a la mitad del periodo comprendido entre los censos de cada diez años, en este caso el Censo de 2010 y el realizado en 2020 (INEGI, 2015).

Los datos pertenecientes a los factores de población económicamente activa e infraestructura de servicios públicos se obtienen del Sistema Estatal y Municipal de Bases de Datos (SIMBAD) propiedad del Instituto Nacional para el Federalismo y el Desarrollo Municipal (INAFED), el cual es un catálogo digital que permite consultar, de forma personalizada, la información de estadísticas que el INEGI genera o recaba, con desagregación por municipio (SIMBAD, 2020).

Los datos de población económicamente activa corresponden a población mayor de 12 años, mientras que los datos de infraestructura de servicios públicos incluye tianguis, aeropuertos, mercados públicos, centrales de abasto, y terminales de autobuses.

#### 4.3.2.2. Creación de shapefiles

La información proveniente del INEGI y el SIMBAD se almacena en archivos tabulares (*.xlsx*) lo que no permite su manipulación espacial. Para solucionar esta limitante los datos se georreferencian utilizando mapas

vectoriales de la zona de interés, para el ejemplo la Ciudad de México.

Para editar los mapas vectoriales (*shp*), se desarrolla un script en Python, el cual permite leer la información de los archivos *.shp* y *.xlsx*, para generar un nuevo archivo *.shp* a partir de los datos contenidos en los archivos *.xlsx*. De esta forma la información queda georreferenciada y puede utilizarse para generar las imágenes ráster (Ver Figura 4.10).

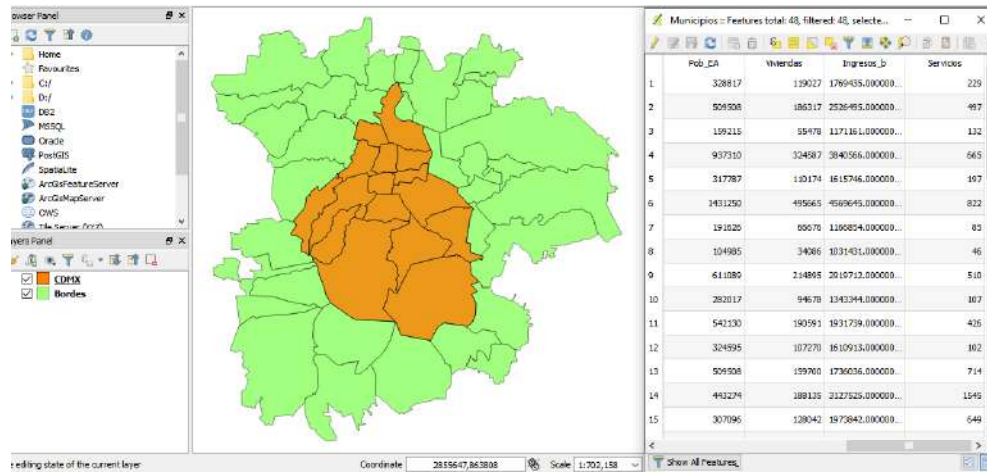


Figura 4.10: Georreferenciación de datos tabulares.

#### 4.3.2.3. Rasterización

Como se muestra en la Figura 4.11, el proceso de rasterización consiste básicamente en situar una malla sobre el mapa vectorial, para codificar los píxeles en función de los datos que posean (Llopis, 2010).





Figura 4.11: Ejemplo rasterización.

Para propósitos de esta investigación la etapa de rasterización hace posible la integración de los factores sociales y económicos en el modelo de red neuronal.

Con los mapas vectoriales generados en la etapa anterior y la herramienta *Rásterize* de QGIS se realiza el proceso de rasterización, las imágenes de los factores rasterizados para la Ciudad de México se muestran en la Figura 4.12.



**Figura 4.12:** Factores rasterizados de la zona urbana de la Ciudad de México. (a) representa el factor de población, (b) observa el factor de vivienda, (c) corresponde al factor de población económicamente activa y (d) representa la infraestructura de servicios municipales.

Para cada uno de los mapas mostrados en la Figura 4.12 los valores cercanos a 1 indican mayor cantidad de servicios, población, viviendas y población económicamente activa, mientras que los valores cercanos a 0 indican una menor cantidad de los mismos.

#### 4.3.2.4. Normalización

La normalización de datos en una imagen consiste en llevar a una escala estándar todos y cada uno de los píxeles sin provocar alguna distorsión significativa (Kotkar and Jadhav, 2015).

Debido a las diferentes unidades entre los factores utilizados, la literatura sugiere escalar los datos con el objetivo de tener mejores resultados (He et al., 2017; Pazos Perez et al., 2017; Zhang et al., 2018).

El normalizado de cada variable trata las entradas con igual importancia en la red neuronal y los hace compatibles con las funciones de activación (Almeida et al., 2008; Li and Yeh, 2001, 2002; Richardson and van Oosterom, 2013), por lo tanto, los datos de las imágenes satelitales se normalizan en el rango de 0 a 1 antes de ser introducidos en la red neuronal, de acuerdo con la Ecuación 4.8.

$$z_{ij} = \frac{x_{ij} - \min}{\max - \min} \quad (4.8)$$

Donde:

- $z_{ij}$  : Valor escalado entre 0 y 1.
- $x_{ij}$  : Valor original en la imagen ráster.
- $\min$  : Valor mínimo en la imagen ráster.
- $\max$  : Valor máximo en la imagen ráster.

Donde uno representa el valor con mayor probabilidad de crecimiento y cero el menos probable. Las imágenes generadas posterior al escalamiento son las imágenes de entrada a la red neuronal.

## 4.4. Modelado

Los modelos y las simulaciones se utilizan para comprender, probar y experimentar con metodologías teóricas relativas a los procesos complejos. Mediante el uso de modelos y simulaciones, se estudian diferentes planes y se examinan de antemano los posibles escenarios (Kaviari et al., 2019).

Tal es el caso del crecimiento urbano vertical, para el cual se han desarrollado modelos con diferentes herramientas privadas aunque aisladas entre sí, lo que aumenta la probabilidad de errores en los cálculos e incompatibilidad de datos, además de no estar vinculadas a Sistemas de Información Geográfica (SIG).

Por lo que se presenta un modelo integrado a un SIG mediante el lenguaje de programación Python que combina redes neuronales con procesos de análisis espacial para proyectar el crecimiento vertical, a través de imágenes ráster y mapas vectoriales de las zonas metropolitanas de: Valle de México, Guadalajara, Monterrey, Puebla-Tlaxcala y Tokio durante los años 2015-2020. La descripción detallada sobre el modelo de crecimiento propuesto se presenta en el capítulo 5.

## 4.5. Simulación y análisis de resultados

La simulación se basa en la red neuronal que calcula un mapa de probabilidad de crecimiento vertical a través de los factores de la investigación, el mapa generado se utiliza por el autómata celular para calcular el crecimiento vertical a partir de un conjunto de reglas propuestas. El modelo se implementa en una plataforma SIG mediante el lenguaje de programación Python en su versión 3.7.

Los resultados de la simulación se validan mediante los índices Kappa y Jaccard. El Índice Kappa ( $k$ ), el cual es una medida de comparación de mapas, en la investigación permite validar la posición en la que se proyectan nuevos edificios y se define por:

$$k = \frac{P_0 - P_e}{1 - P_e} \quad (4.9)$$

Donde  $P_0$  es la proporción de igualdad observada,  $P_e$  es la proporción de igualdad esperada y  $1 - P_e$  representa la igualdad o concordancia máxima.

La similitud entre mapas en diferentes periodos se evalúa utilizando el índice Jaccard ( $J$ ), este índice considera la similitud en valor y posición de lo de los pixeles en las imágenes. Donde se incluyen los elementos de una primera imagen satelital ( $T_{21}$ ), los elementos de una segunda imagen ( $T_{12}$ ), los elementos de la unión de la primera imagen con la segunda se les denomina  $T_{11}$  (Bouchard et al., 2013).

$$J = \frac{T_{11}}{T_{21} + T_{12} + T_{11}} \quad (4.10)$$

La interpretación de los índices  $k$  y  $J$  es una cuestión subjetiva y no existe acuerdo general. Sin embargo, se propone una interpretación basada en la propuesta de Jiménez (2019) con umbrales interpretativos como una guía aceptable pues fue propuesta para trabajar con imágenes satelitales (Ver Tabla 4.4).

**Tabla 4.4:** Interpretación de resultados basada en la propuesta de Jiménez (2019).

Valor	Nivel de igualdad	
	Índice Kappa	Índice Jaccard
$\leq 0.0$	No igualdad	—
$(0.0, 0.2]$	Insignificante	Insignificante
$(0.2, 0.4]$	Baja	Baja
$(0.4, 0.6]$	Moderada	Moderada
$(0.6, 0.8]$	Buena	Buena
$(0.8, 1.0]$	Igualdad total	Igualdad total

## Capítulo 5

# Modelo de crecimiento vertical

En este capítulo se presenta el proceso de diseño del modelo de crecimiento vertical propuesto en la tesis. Incluyendo las etapas de diseño de red neuronal y diseño de autómata celular.

### 5.1. Diseño del modelo

El desarrollo de modelos teóricos integrados a sistemas de software comprende el trabajar con metodologías que guían el proceso de modelado, de forma general autores como [Jacobson et al. \(2000\)](#) o [Kendall \(2005\)](#) proponen el generar modelos a partir de tres pasos principales: i) identificar datos de entrada, ii) detectar procesos involucrados y iii) establecer las salidas deseadas.

#### a) Datos de entrada

La base de datos consiste en un conjunto de seis imágenes por zona metropolitana, donde cada imagen se escala en un rango de 0.0 a 1.0 antes de ingresar en el modelo de red neuronal. Con las imágenes escaladas se forma el archivo para la capa de entrada en la red neuronal, donde los valores de cinco imágenes corresponden a datos de entradas y los valores de la sexta imagen corresponden a datos de salidas como se muestra en la [Figura 5.1](#).

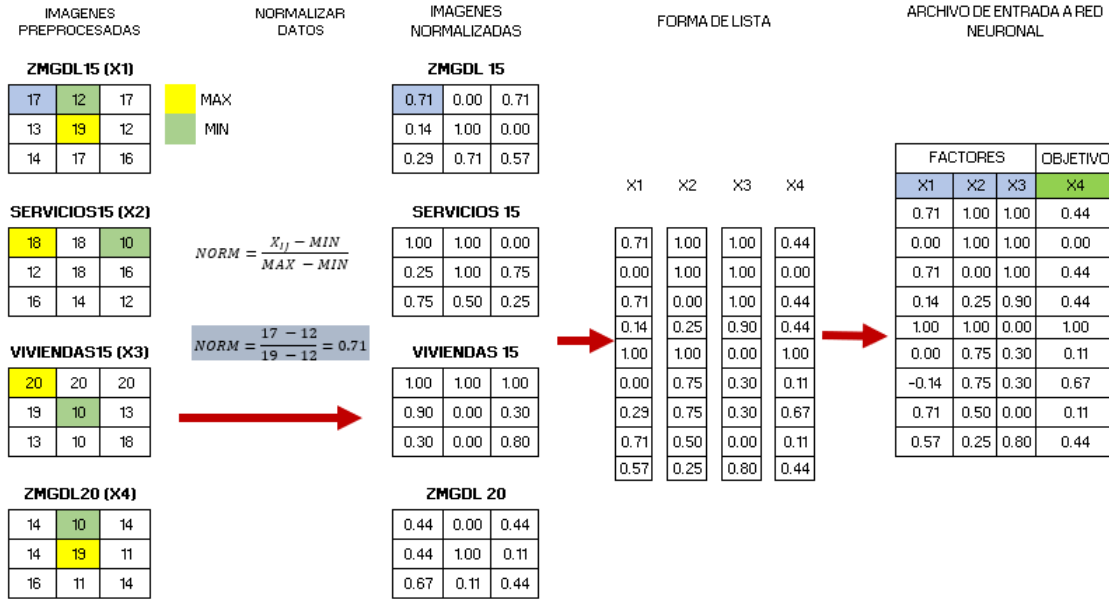


Figura 5.1: Procesamiento de datos para su entrada a la red neuronal.

Se utiliza un 70 % del archivo de datos como conjunto de entrenamiento y un 30 % como conjunto de validación, como es sugerido por autores como (Hoang and Bui, 2017; Li and Yeh, 2002). El proceso mostrado en la Figura 5.1 se repite para cada una de las cinco zonas metropolitanas de estudio.

b) **Proceso**

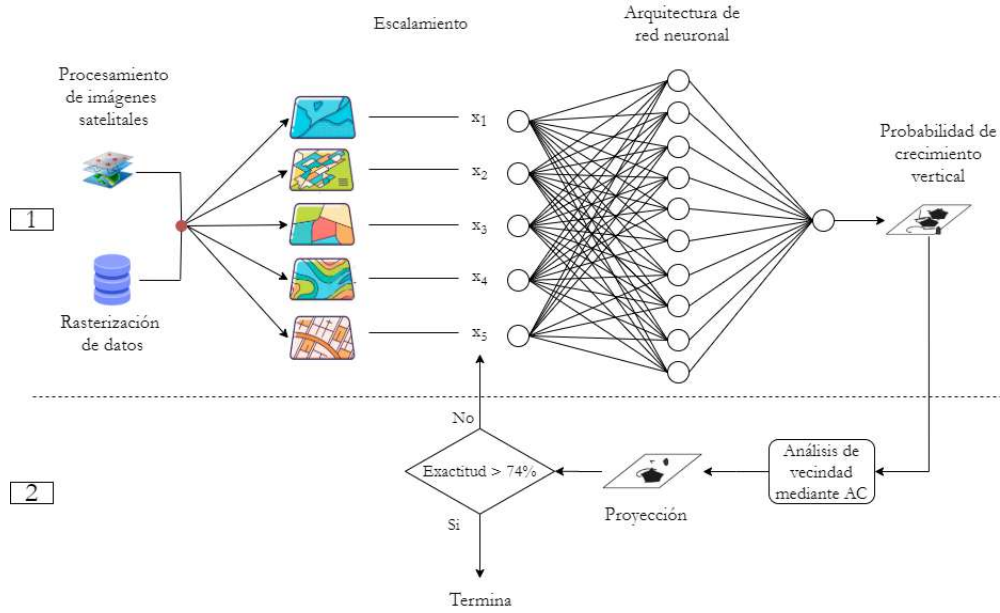
La estructura del modelo propuesto para la proyección del crecimiento vertical que se presenta en la Figura 5.2 consiste de cuatro etapas principales: i) Procesamiento de datos de zonas de estudio, ii) Mapa de probabilidad de crecimiento con factores característicos utilizando la red neuronal de retropropagación, iii) Proyección de crecimiento vertical mediante el autómata celular y iv) Validación de resultados.

El modelo propuesto de red neuronal con autómata celular combina técnicas de inteligencia artificial, con procesos de análisis espacial para proyectar el crecimiento urbano vertical. El proceso se repite durante  $n$  iteraciones hasta que la tasa de error se reduce al mínimo o alcanza un nivel de exactitud aceptable (74 %).

c) **Salida esperada**

Estudios anteriores encuentran que la probabilidad de crecimiento vertical está relacionada con la ubicación, potencial económico, vecindad del territorio, topografía y densidad de población (Hoang and Bui, 2017; Ou et al., 2018).

Una buena ubicación residencial tiene mejores oportunidades médicas, educativas, y un entorno de vida confortable que atrae a más gente a vivir allí. Este crecimiento de la población desencadena un aumento



**Figura 5.2:** Modelo de crecimiento urbano vertical.

en la probabilidad de crecimiento vertical (He et al., 2017).

Se generan resultados de imágenes ráster con el crecimiento vertical, posteriormente los mapas se vectorizan para generar los modelos en 3D con los edificios proyectados.

## 5.2. Diseño de red neuronal

Una red neuronal suele presentar una capa de entrada, una capa de salida y una o más capas ocultas (o ninguna) entre ellas. Estas capas sucesivas de neuronas presentan conexiones que van de neurona a neurona entre las distintas capas de la red. Las conexiones son responsables de enviar la información a través de la red mediante los pesos, que inicialmente se establecen de forma aleatoria y pueden ser positivos o negativos (Bishop et al., 1995).

Estudios muestran que los resultados en redes neuronales están determinados por el número de capas, neuronas y tipo de red a implementar (Openshaw and Openshaw, 1997; Ou et al., 2018). Por lo que se considera que no existe una estructura óptima universal para todas las aplicaciones. Sin embargo, el determinar el tipo de red neuronal y posteriormente la arquitectura de la misma suele ser la mejor opción de diseño.



### 5.2.1. Arquitectura de red neuronal

A partir de los datos de entrada se identifican cinco entradas, una por cada imagen ráster, lo que corresponde a cinco neuronas en la capa de entrada para la red neuronal de retropropagación.

Una vez definido el tipo de red a implementar y el número de neuronas en la capa de entrada la literatura sugiere utilizar el menor número posible de capas ocultas y neuronas e ir aumentando en ellas conforme se disminuya el error en la aproximación buscada (Li et al., 2018b).

El teorema de Kolmogorov sugiere que cualquier red neuronal con  $n$  neuronas en la capa de entrada, tendrá  $2n + 1$  neuronas en la capa oculta, y  $c$  nodos en la capa de salida (Wang, 1994). Por otro lado, los experimentos indican que una red de  $2n/3$  neuronas en la capa oculta puede generar resultados de casi el mismo nivel de precisión, pero requiere menos tiempo para entrenar que la red de  $2n + 1$  neuronas (Hoang and Bui, 2017).

La determinación del número óptimo de capas suele ser una cuestión de experimentación por lo que para comenzar con tal proceso se estudian arquitecturas probadas en diversas investigaciones, en la Tabla 5.1 se resumen algunas de ellas.

**Tabla 5.1:** Búsqueda de arquitectura óptima en la literatura.

Referencia	Iteraciones	Número de datos	Tiempo de procesamiento	Lenguaje	Aplicación
Valle-Cruz et al. (2020)	7	50,000	Una semana por iteración	Python R	Apoyo a decisiones de gobierno
Singh et al. (2018)	270	3,939	Tres meses	MATLAB	Clasificar enfermedades cardiacas
Zeng et al. (2017)	50	2,000	No reportado	MATLAB Scripts SPSS	Predecir consumo de energía eléctrica
He et al. (2017)	3,000	>1,000,000	No reportado	MATLAB	Predecir crecimiento urbano
Wang et al. (2015)	2,000	150,000,000	No reportado	MATLAB	Series de tiempo
Li and Yeh (2002)	56	>1,500,000	8-12 horas por prueba	Visual Basic	Predecir crecimiento urbano
Paola and Schowengerdt (1995)	20,000	810,000	Dos meses	C	Crecimiento urbano y tipo de suelo

A partir de lo anterior se comienza la exploración para encontrar la arquitectura que minimiza el error cuadrático medio tanto en la etapa de entrenamiento como en la de simulación. Para ello se desarrolla una rutina en Python en conjunto con las librerías de TensorFlow y Keras.

El objetivo de la rutina es probar diferentes arquitecturas de red neuronal hasta obtener aquella que tenga el nivel de exactitud más alto, como se describe en el Algoritmo 1.

---

**Algoritmo 1** Buscar arquitectura de red neuronal.

---

```

1: Mientras ( $ex \leq 100\%$ ) Hacer
2:    $red = genera\_modelo(co, nco, fco, fcs, opti, loss)$ ;
3:    $entrena\_modelo(red)$ ;
4:    $ex, est = valida\_modelo(red)$ ;
5:    $guarda\_resultados(est)$ ;
6:    $actualiza\_datos(co, nco, fco, fcs, opti, loss)$ ;
7: Fin Mientras

```

---

Donde:

- $ex$  : Nivel de exactitud.
- $red$  : Modelo de red neuronal.
- $co$  : Número de capas ocultas.
- $nco$  : Número de neuronas en capas ocultas.
- $fco$  : Función de activación en capas ocultas.
- $fcs$  : Función de activación en capa de salida.
- $opti$  : Algoritmo de entrenamiento de la red neuronal.
- $loss$  : Método para calcular el error en la red neuronal.
- $est$  : Estadísticas de la arquitectura red neuronal.

### 5.2.2. Selección de red neuronal


La rutina presentada en el Algoritmo 1 se ejecuta en un equipo de cómputo con procesador Intel Core i7 de 3.1GHz, 16GB de memoria RAM, sistema operativo Windows 10 de 64 bits, durante un periodo de 42 días, probando un total de 501 arquitecturas con 500 épocas de entrenamiento para cada una. En la Tabla 5.2 se presentan los resultados de las arquitecturas con mejores resultados.

**Tabla 5.2:** Resultados de arquitectura de red seleccionada.

Variable	Valle de México	Guadalajara	Monterrey
Capas ocultas	3	4	3
Nodos en capas ocultas	[5, 10, 13]	[5, 8, 10, 12]	[5, 13, 14]
Activación capas ocultas	Rectilínea Lineal Uniforme (RELU)	Tangente Hiperbólica	Rectilínea Lineal Uniforme (RELU)
Activación capas de salida	Sigmoide	Sigmoide	Sigmoide
Exactitud	85.47%	86.32%	84.77%
Épocas	2,000	2,000	2,000

Una vez seleccionada la arquitectura se repite el proceso de entrenamiento esta vez con un total de 2000 épocas, la evolución del proceso de aprendizaje para las arquitecturas seleccionadas se muestra en la Figura

5.3.



**Figura 5.3:** Evolución de aprendizaje en las redes neuronales.

Con las arquitecturas de red neuronal seleccionadas se generan los mapas de probabilidad de crecimiento vertical para las zonas metropolitanas de México, Guadalajara y Monterrey. Los mapas generados se muestran en la Figura 5.4.

### 5.3. Diseño de autómatas celulares

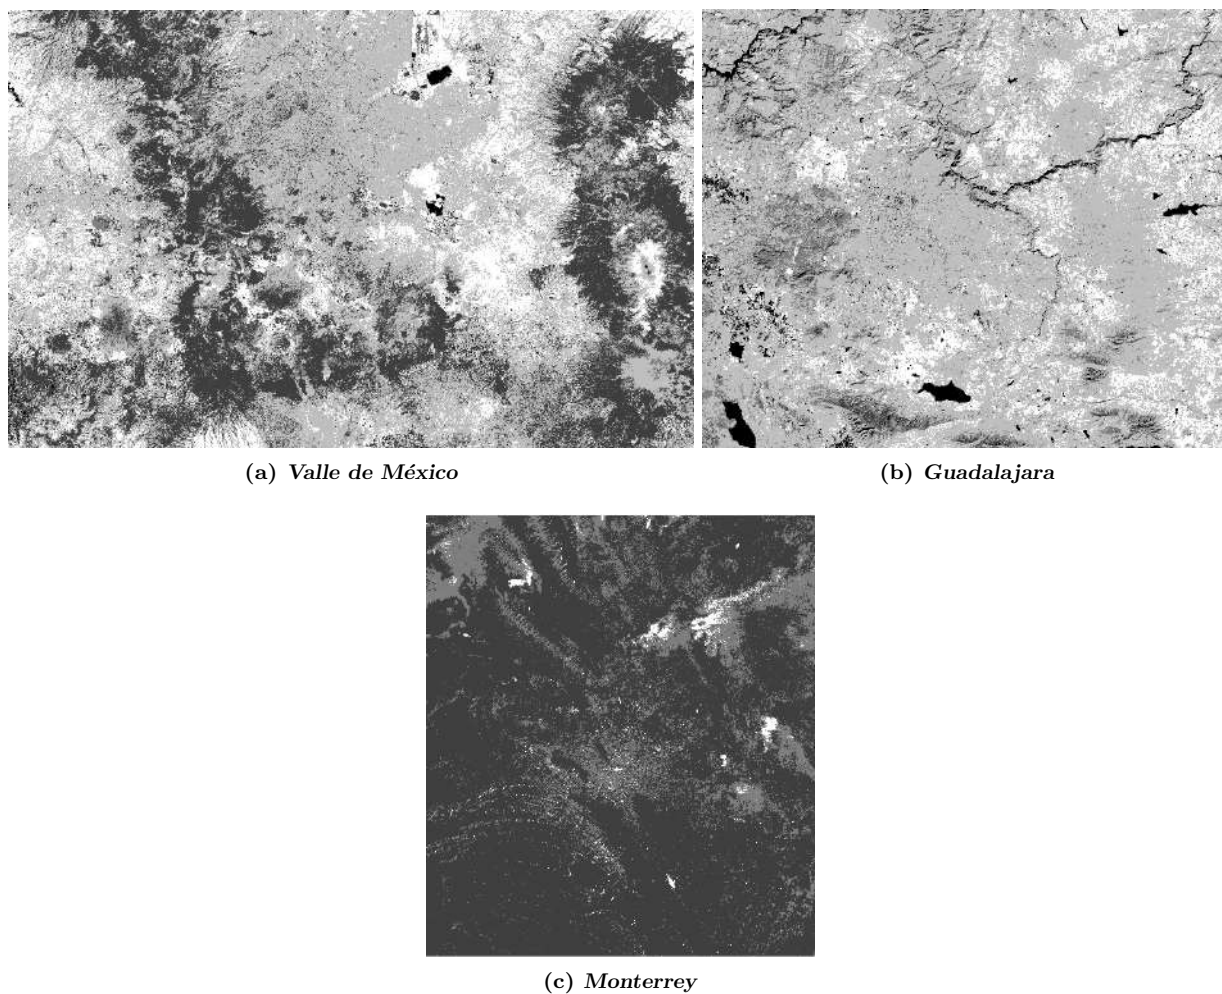
Para diseñar un autómata celular se deben considerar los elementos que lo forman: i. Espacio n-dimensional, ii. Condición inicial del espacio n-dimensional, iii. Conjunto de estados, iv. Espacio de vecindad, v. Reglas de transición (Wolfram, 2018), y un conjunto de condiciones básicas (Adamatzky, 2018):

- a) Debe existir un espacio dimensional dividido en forma de redes o arreglos.
- b) Debe tener un tiempo y estados discretos.
- c) Cada célula toma un número finito de estados y actualiza sus estados en un tiempo discreto, dependiendo de los estados de sus vecinos.
- d) La vecindad de cada célula se define de manera uniforme.
- e) Las células actualizan su estado aplicando las mismas reglas de transición.

#### 5.3.1. Espacio n-dimensional

Es el espacio donde se desarrolla el autómata celular y se divide por un conjunto finito de celdas (Wolfram, 2018). En la literatura se han desarrollado modelos de autómatas celulares con una, dos, tres o más dimensiones (hiperbólicos), algunos ejemplos pueden consultarse en Adamatzky (2018).

En esta investigación se trabaja con imágenes satelitales por lo que el espacio es bidimensional, para cada una de las Zonas Metropolitanas se ajusta el espacio en función del tamaño de la imagen satelital, en la Tabla 5.3 se resume el tamaño del espacio bidimensional.



**Figura 5.4:** Mapas de probabilidad de crecimiento vertical del año 2015: (a) Zona Metropolitana del Valle de México, (b) Zona Metropolitana de Guadalajara, (c) Zona Metropolitana de Monterrey.

**Tabla 5.3:** Dimensión en pixeles de las zonas de estudio.


Zona metropolitana	Renglones	Columnas	Dimensión (px)	Tamaño de celda (m)
Valle de México Norte	4118	2161	8,898,998	30 m.
Valle de México Sur	3823	2448	9,358,704	30 m.
Guadalajara	2923	2434	7,114,582	30 m.
Monterrey	3798	4317	16,395,966	30 m.

### 5.3.2. Condición inicial del espacio n-dimensional

Se define como la distribución de celdas y estados en el espacio dimensional durante el tiempo  $t$  a partir del cual se aplican las reglas de transición (Lin et al., 2014).

El trabajo pionero de Wolfram (1983) propone un autómata celular cuya condición inicial se representa por un valor de uno (punto negro) en el espacio dimensional. Por otro lado, Margenstern (2007) trabaja con espacios hiperbólicos y su condición inicial se determina por las diferentes características de cada espacio.

En esta investigación la condición inicial del espacio n-dimensional se define por el mapa de probabilidad generado a partir de la red neuronal para cada una de las zonas de estudio. En la Figura 5.5 se muestra una comparación entre los diferentes tipos de condiciones iniciales reportadas.



**Figura 5.5:** Tipos de condiciones iniciales en autómatas celulares: (a) Condición inicial propuesta por Wolfram (1983), (b) Condición inicial propuesta por Margenstern (2007), (c) Ejemplo de condición inicial en la investigación.

### 5.3.3. Conjunto de estados

Se refiere a los valores que puede tener una célula durante un periodo de tiempo, se caracterizan por ser finitos y discretos (Fatès, 2018). El autómata propuesto por Wolfram (1983) se caracteriza por tener únicamente dos estados (cero y uno) para cada célula en el espacio dimensional. Por otro lado, el trabajo propuesto por Margenstern (2007) tiene un total de 9 estados obtenidos a partir de los elementos básicos de un circuito ferroviario.

En esta investigación, los estados corresponden a los niveles de intensidad en una escala de 0 a 1 para los píxeles de los mapas de probabilidad de las zonas de estudio, calculados mediante el lenguaje de programación Python.

Debido a las características del lenguaje cada número se redondea con un total de 18 decimales, esto produce un conjunto mayor  $10^{18}$  posibles estados para cada uno de los píxeles en las imágenes satelitales.

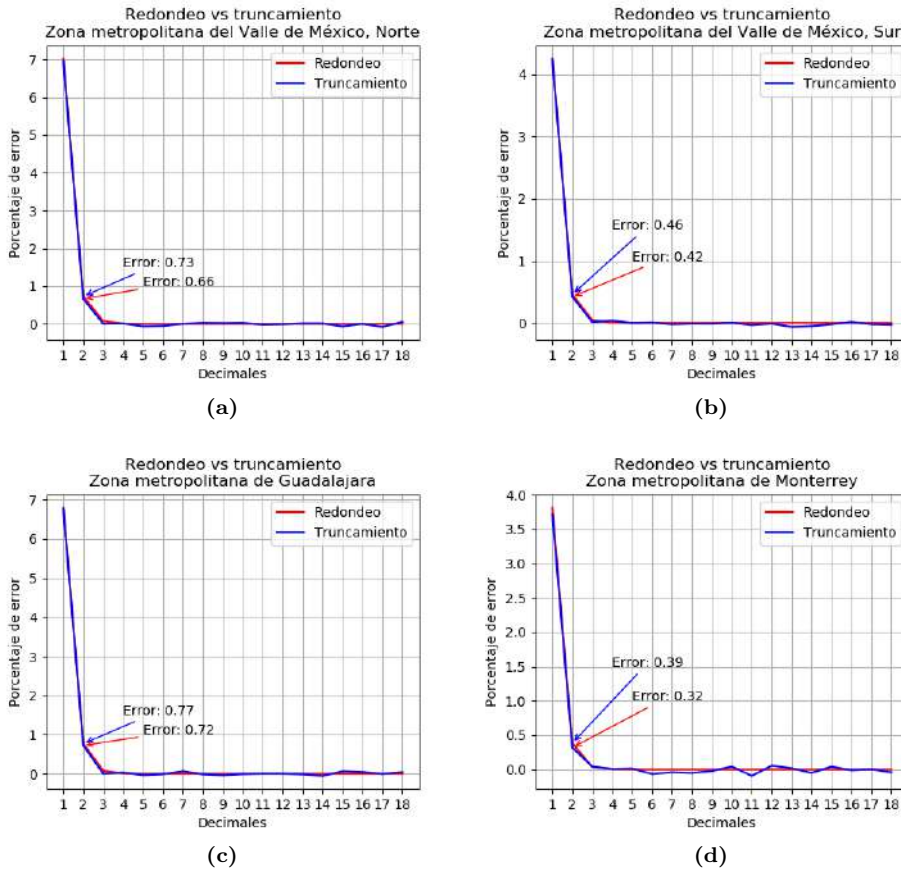
Con el objetivo de reducir este conjunto para tener una cantidad manejable por el lenguaje de programación, optimizar tiempos de ejecución y establecer intervalos adecuados en las reglas del autómata celular se realizan pruebas de truncamiento y redondeo con cada uno de los 18 decimales, posteriormente se calcula el error relativo definido por la ecuación:

$$er = \frac{d_c - d_o}{d_c} \quad (5.1)$$

Donde:

- $er$  : Error relativo.
- $d_c$  : Valor ajustado mediante truncamiento o redondeo.
- $d_o$  : Valor original.

Los resultados se muestran en la Figura 5.6.



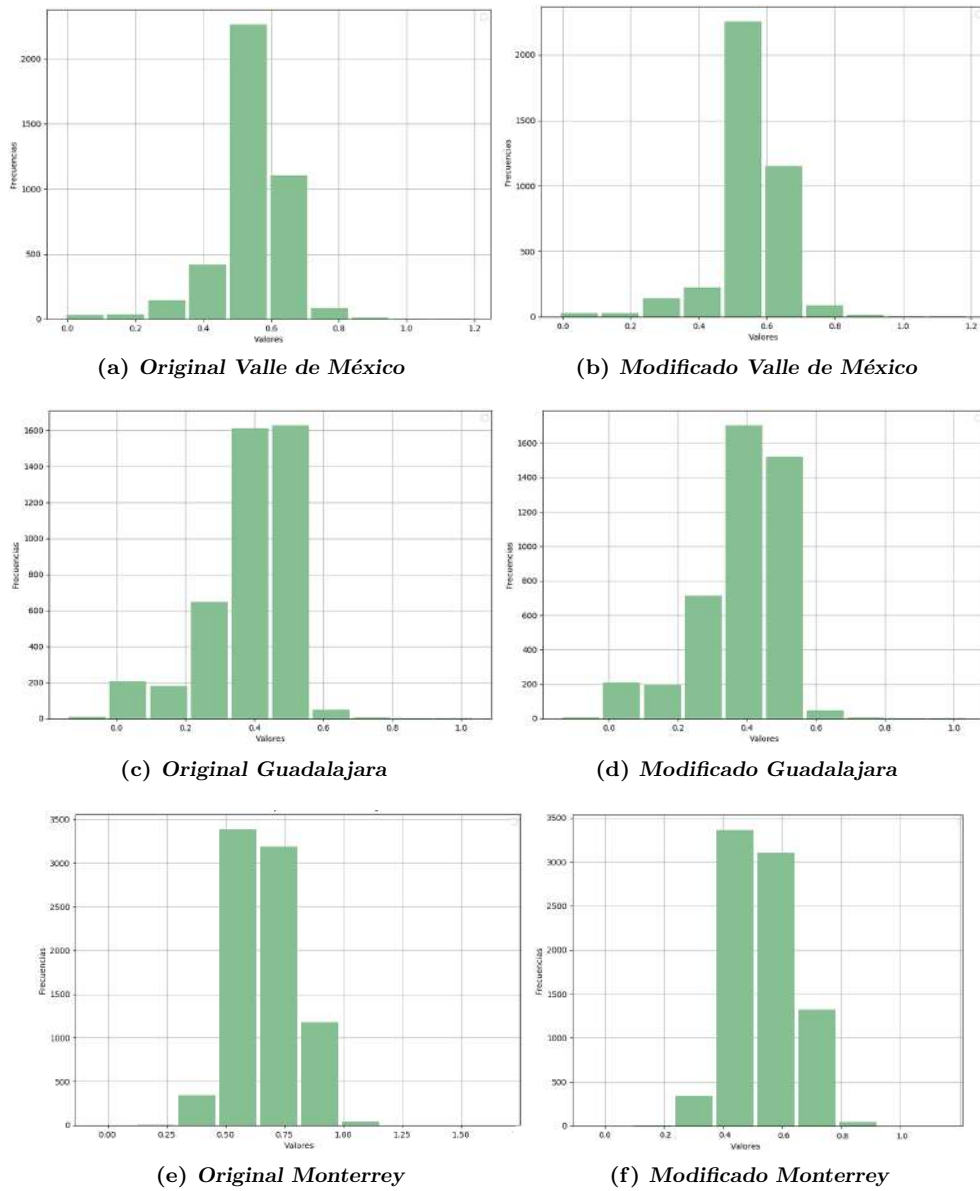
**Figura 5.6:** Gráficas de comparativas entre error producido por truncamiento y redondeo: (a) Zona Metropolitana del Valle de México, Norte, (b) Zona Metropolitana del Valle de México, Sur, (c) Zona Metropolitana de Guadalajara, (d) Zona Metropolitana de Monterrey.

Los resultados permiten determinar que un redondeo a dos decimales es una opción aceptable para limitar el conjunto de estados permitidos para el autómata celular, puesto que el error para las cuatro Zonas Metro-

politanas es inferior al 1%.

Obteniendo así, un conjunto de 101 estados posibles para cada celda con valores discretos de 0.00 a 1.00 con un incremento de 0.01 entre estado.

El redondeo a dos decimales seleccionado modifica la forma de los histogramas de frecuencia para las Zonas Metropolitanas, sin embargo, la alteración es poco significativa al contrastarse con una prueba t de Student. En la Figura 5.7 se muestran los histogramas modificados por el efecto del redondeo.




**Figura 5.7:** Histogramas de las Zonas Metropolitanas antes y después del redondeo.

### 5.3.4. Espacio de vecindad

El espacio de vecindad define la forma en la que interactúa cada célula con las celdas vecinas (Wolfram, 2018).

Para espacios bidimensionales divididos por cuadros se distinguen dos tipos de vecindad principales: i. De Moore y ii. De Von Neuman, ambos pueden adaptarse para agrandar la vecindad mediante el incremento de niveles, como se muestra en la Figura 5.8.



**Figura 5.8:** Ejemplos de niveles para criterios de vecindad en espacios bidimensionales.

En una imagen satelital el espacio de vecindad se obtiene a través de los píxeles que rodean a un píxel central que en este caso representa un edificio. En la Figura 5.9, los edificios se representan por un punto rojo, el objetivo es identificar dónde está ubicado y obtener las celdas vecinas.

El primer paso para obtener la vecindad consiste en definir la distancia dentro de la cual se consideran celdas vecinas, para ello se selecciona el tamaño promedio de una manzana en el territorio mexicano la cual es la unidad mínima del Marco Geoestadístico Nacional del INEGI y se considera para estudios como censos y encuestas (INEGI, 2020a).

Una manzana se define por un espacio de 200 a 500 metros cuadrados aproximadamente dentro del territorio nacional (INEGI, 2020c), por lo que se identifica un espacio de vecindad de 240 metros a partir de un píxel central, lo que equivale a un nivel de vecindad 4, como el mostrado en la Figura 5.8.


Posteriormente, se identifican las posiciones  $(i, j)$  donde se encuentran los edificios en la imagen satelital y se extraen las celdas vecinas.

Para automatizar el proceso se desarrolla una herramienta en Python integrada al sistema de información geográfica QGIS. La herramienta trabaja con dos archivos, la imagen satelital de la Zona Metropolitana (.tif) y el archivo vectorial (.shp) que contiene las ubicaciones de los edificios correspondiente a la zona de estudio. El proceso general se explica en el Algoritmo 2.

Donde:


- *ruta.shp* : Ruta donde se localiza el mapa vectorial.





(a) Valle de México

(b) Guadalajara



(c) Monterrey

Figura 5.9: Ejemplos de edificios en las Zonas Metropolitanas.

---

**Algoritmo 2** Recuperar vecindad de edificios en imagen satelital.

---

```
puntos = leer_puntos_shp(ruta_shp);
img = leer_imagen_tif(ruta_tif);
```

**Para** punto en puntos **Hacer**

**Para**  $i$  en  $img.rows$  **Hacer**

**Para**  $j$  en  $img.cols$  **Hacer**

**Si** coinciden\_coordenadas( $[i, j]$ , punto) **Entonces**

        vecindad = recuperar\_vecindad( $i, j$ );

        guardar\_datos(vecindad);

**Fin Si**

**Fin Para**

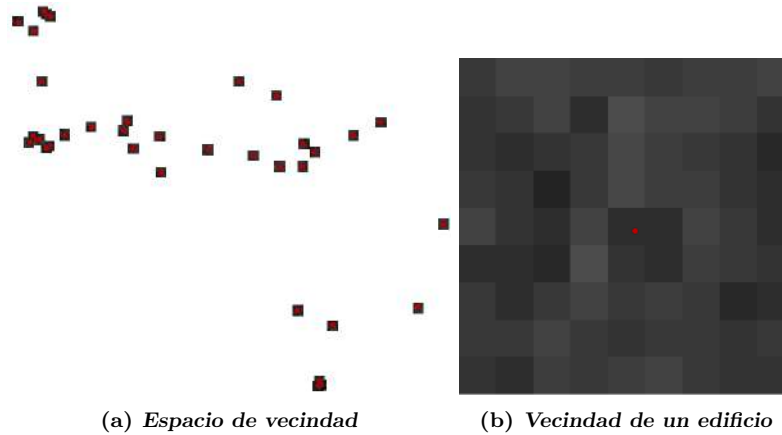
**Fin Para**

**Fin Para**

---

- *ruta.tif* : Ruta donde se localiza la imagen satelital.
- *puntos* : Coordenadas de los edificios en el mapa vectorial.
- *img* : Datos de la imagen satelital.
- *vecindad* : Matriz de vecindad del edificio.

La herramienta identifica un espacio de vecindad para los edificios de las Zonas Metropolitanas del Valle de México, Guadalajara y Monterrey, en la Figura 5.10 se muestra un ejemplo del espacio de vecindad generado por la herramienta.



**Figura 5.10:** Espacio de vecindad para la Zona Metropolitana de Monterrey.

La herramienta también genera archivos donde se almacenan los niveles de intensidad tanto de los edificios como de sus celdas vecinas, lo que permite calcular las reglas de transición entre estados.

### 5.3.5. Reglas de transición

La parte esencial de las reglas de transición en un autómata celular consiste en estimar la probabilidad de conversión entre estados. Por ejemplo, un modelo básico de autómata celular para el crecimiento urbano puede expresarse mediante las reglas de transición mostradas en el Algoritmo 3 (Batty, 1997):

---

**Algoritmo 3** Regla de transición de un autómata celular.

---

- 1: **Si**  $celda(x, y) == 0$  **Entonces**
  - 2:    $P_c(x, y) = \sum P_v(x, y)/8$ ;
  - 3:   **Si**  $P_c(x, y) > \theta$  **Entonces**
  - 4:      $celda(x, y) \leftarrow P_c(x, y)$ ;
  - 5:   **Fin Si**
  - 6: **Fin Si**
- 

Donde:

- $celda(x, y)$  : Celda de interés.
- $P_c(x, y)$  : Nueva probabilidad de transición.

- $P_v(x, y)$  : Probabilidad de celdas vecinas.
- $\theta$  : Umbral.

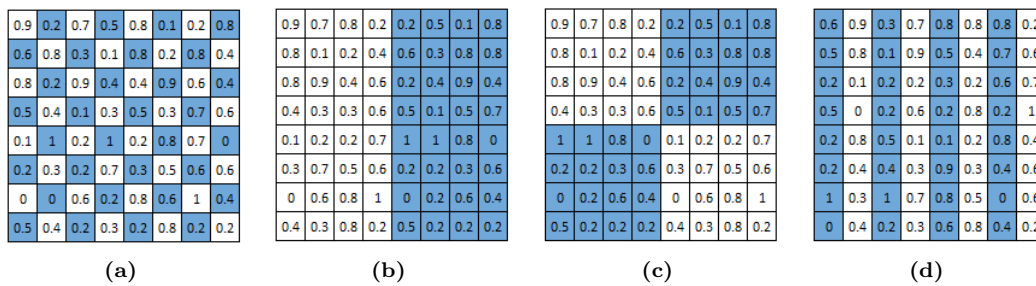
En el modelo de autómata celular propuesto, la estimación de las reglas de transición consiste de dos tipos de estadísticos de probabilidad aplicados a la vecindad de los edificios:

- **Estadísticos no espaciales:** Se compone de dos estadísticos: i. Tipo de suelo, ii. Intervalos de confianza respecto a la media.
- **Estadísticos espaciales:** Se conforma de dos estadísticos propuestos: i. De riesgo, ii. De área de influencia.

El uso de estos estadísticos se relaciona con dos teorías principales de la geografía: i. Unidad espacial modificable (Openshaw and Taylor, 1984) y ii. Ley de Tolber (Tolber, 1970).

La unidad espacial modificable (Openshaw and Taylor, 1984) es una teoría que se puede entender claramente si se ejemplifica mediante el problema del tablero de ajedrez (White, 1983). El ejemplo consiste en imaginar un tablero donde las casillas (blancas y azules) representan pixeles de una imagen satelital cada una asociada a cierto nivel de intensidad.

Si se calculan ciertos estadísticos como media y varianza en el patrón clásico del tablero (ver Figura 5.11(a)) se obtiene cierto resultado (0.5 y 0.1, para el ejemplo). Sin embargo, si se altera el patrón clásico, por ejemplo: mover las casillas azules hacia una mitad del tablero y dejar las casillas blancas en la otra mitad (Ver Figura 5.11(b)), se espera que se detecte esta nueva distribución. Sin embargo, al ser indicadores no-espaciales se producen los mismos resultados para diferentes distribuciones, sucede lo mismo para cualquier otro tipo de distribución como en las Figuras 5.11(c) y 5.11(d).



**Figura 5.11:** Problema del tablero de ajedrez y la unidad espacial modificable.

A pesar de la limitante de los estadísticos no-espaciales, su utilidad permite tener un enfoque general del comportamiento de los datos, por tal motivo se utilizan en las reglas de transición.

Por otro lado, los estadísticos espaciales tienen su sustento en la primera ley de la geografía o ley de Tolber (Tolber, 1970), la cual indica que en el espacio todo está relacionado con todo, pero las cosas más cercanas se

encuentran más relacionadas entre sí.

### 5.3.5.1. Diseño de estadísticos no espaciales

#### Tipo de suelo

La primera etapa para identificar las reglas que determinan la conversión entre estados consiste en clasificar los niveles de intensidad en las imágenes satelitales.

La clasificación consiste en un proceso visual que analiza los valores de los píxeles de cada imagen satelital. Con base en los niveles observados cada valor se clasifica en una de categorías mostradas en la Tabla 5.4.

**Tabla 5.4:** Clasificación de niveles de intensidad para las imágenes satelitales de las Zonas Metropolitanas.

Clasificación	Descripción	Valle de México	Guadalajara	Monterrey
Agua	Zonas como ríos, lagos o lagunas.	[0.00, 0.31]	[0.00, 0.23]	[0.00, 0.29]
Terreno para construcción	Lugares en los que se puede desarrollar zona urbana	(0.31, 0.52]	(0.23, 0.30]	(0.29, 0.43]
Caminos-Carreteras	Vías para la circulación peatonal o de vehículos	(0.52, 0.58]	(0.30, 0.38]	(0.43, 0.48]
Zona urbana	Zonas con construcciones humanas	(0.58, 0.67]	(0.38, 0.54]	(0.57, 0.61]
Áreas verdes	Lugares como bosques, jardines o parques	(0.67, 1.00]	(0.54, 1.00]	(0.61, 1.00]
Edificios	Construcciones con más de 25 pisos o 100 metros	[0.53, 0.63]	[0.25, 0.35]	[0.39, 0.47]

El cálculo de estos intervalos permite al autómata identificar el tipo de suelo al que pertenece un píxel, limitando el crecimiento vertical en suelos clasificados como *Terreno para construcción* y *Zona urbana*, con la idea de respetar cuerpos de agua, áreas verdes y caminos-carreteras, los cuales suelen ser espacios no respetados por un crecimiento horizontal (Duque et al., 2019; He et al., 2017).

#### Intervalos respecto a la media

Para su diseño se realizan pruebas de bondad de ajuste utilizando los procedimientos de Kolmogorov-Smirnov, Anderson-Darling y Chi-cuadrado en los espacios de vecindad de las zonas de estudio, el uso de estas pruebas permite identificar con que distribución de probabilidad se ajustan los datos a fin de calcular estadísticas adecuadas para las reglas del autómata celular.

El cálculo de pruebas de bondad se realizada mediante Scipy, una la librería de Python destinada al cálculo de procesos científicos como interpolación de datos, pruebas de hipótesis, algebra matricial, entre otros (SCIPY, 2020). Adicionalmente, los resultados se validan a través del software EasyFit, especializado en calculos de

pruebas de bondad ([EASYFIT, 2020](#)).

Los resultados de las pruebas de bondad de la Tabla 5.5 muestran los estadísticos obtenidos para cada distribución. Estos estadísticos se contrastan con los valores  $p$  correspondientes para determinar si la distribución se ajusta o no a los datos.

**Tabla 5.5:** Comparación de estadísticos de bondad de ajuste.

Zona Metropolitana	Distribucion	Kolgomorov-Smirnov		Anderson-Darling		Chi-cuadrado	
		EasyFit	Scipy	EasyFit	Scipy	EasyFit	Scipy
Valle de México	Lognormal	0.04087	0.05851	9.65710	13.62287	270.57000	-
	Beta	0.04475	0.06166	9.80880	13.62287	266.06000	-
	Normal	0.05828	0.05827	13.71200	13.71230	429.88000	-
	Logistic	0.07000	0.07611	18.74800	14.83700	124.54000	-
Guadalajara	Lognormal	0.28918	0.00178	204.65000	204.72486	641.92000	-
	Beta	0.29270	0.11337	200.14000	200.56623	636.77000	-
	Normal	0.30552	0.30551	201.38000	201.38054	635.42000	-
	Logistic	0.32179	0.29626	216.89000	209.37516	633.52000	-
Monterrey	Lognormal	0.07232	0.00162	14.74300	37.61776	247.96000	-
	Beta	0.07116	0.05409	15.11600	90.83248	248.02000	-
	Normal	0.08415	0.08414	17.81800	17.81751	288.45000	-
	Logistic	0.07893	0.16421	15.60200	13.83221	314.79000	-

Como se observa en la Tabla 5.5, los resultados de Scipy y EasyFit son consistentes en el cálculo de la distribución normal con los procedimientos de Kolmogorov-Smirnov y Anderson-Darling, por lo que se selecciona esta distribución para estimar los intervalos de confianza en la regla del autómata celular.

El cálculo de intervalos de confianza proporciona un conjunto de valores dentro de los cuales se espera estén incluidos los parámetros de interés ([Douglas et al., 2002](#)). Cuando se conoce la media ( $\mu$ ) y la desviación estándar ( $\sigma$ ), el cálculo de los intervalos esta dado por:

$$\bar{y} - Z_{\frac{\alpha}{2}} * \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{y} + Z_{\frac{\alpha}{2}} * \frac{\sigma}{\sqrt{n}} \quad (5.2)$$

Donde:

- $\bar{y}$  : Media muestral.
- $Z_{\frac{\alpha}{2}}$  : Valor Z.
- $\alpha$  : Nivel de confianza.
- $\sigma$  : Desviación estandar de la muestra.
- $n$  : Total de elementos de la muestra.
- $\mu$  : Media poblacional.

Se calculan los intervalos de confianza para las Zonas Metropolitanas de del Valle de México, Guadalajara y Monterrey con un nivel de confianza ( $\alpha$ ) del 95 %. En la Figura 5.12 se muestran los resultados resaltando en color rojo los intervalos correspondientes.




Figura 5.12: Intervalos de confianza para las Zonas Metropolitanas.

Las reglas formadas con estos intervalos permiten descartar zonas que de forma general no cumplen con el criterio de vecindad de un edificio, por lo que no es necesario analizarlas con los estadísticos espaciales. Los intervalos para las reglas de cada ciudad se presentan en la Tabla 5.6, Donde  $\mu$  corresponde al valor de la media de la vecindad del pixel en estudio.

Tabla 5.6: Niveles de confianza para las Zonas Metropolitanas.

Zona Metropolitana	Intervalo	Regla en autómata
Valle de México	[0.48 - 0.72]	Si $0.48 \leq \mu \leq 0.72$ Entonces
Guadalajara	[0.22 - 0.43]	Si $0.22 \leq \mu \leq 0.43$ Entonces
Monterrey	[0.52 - 0.72]	Si $0.52 \leq \mu \leq 0.72$ Entonces

### 5.3.5.2. Diseño de estadísticos espaciales

Para tratar de reducir el problema de la unidad espacial modificable referido en la Figura 5.11, se proponen tres estadísticos espaciales como parte de las reglas de transición que forman el autómata celular.

#### a) Estadístico de riesgo

Se propone el uso de un estadístico de riesgo, el cual consiste en analizar los niveles de intensidad vecinos de un pixel con probabilidad de ser edificio y estimar que tanto riesgo existe en caso de que se realice un crecimiento vertical.

Para cada una de las categorías referidas en la Tabla 5.4, se asocia un valor de nivel de *riesgo* el cual determina qué tan viable es el construir en función del tipo de suelo que se presenta. La escala de riesgo propuesta se diseña teniendo en cuenta parte de los tipos de suelo y sus características dadas por el servicio de edafología del INEGI (INEGI, 2020b) y la SEMARNAT (SEMARNAT, 2010), la escala se muestra en la Tabla 5.7.

**Tabla 5.7:** Niveles de riesgo asociados a la clasificación de suelo.

Clasificación	Riesgo	Valor	Color
Terreno para construcción	Minimo	0.2	
Caminos-Carreteras	Moderado	0.4	
Zona Urbana	Ligero	0.6	
Areas verdes	Alto	0.8	
Agua	Muy alto	1.0	


El estadístico se calcula a través de una suma ponderada entre el total de pixeles para cada categoría y el valor de riesgo correspondiente, dividida entre el total de pixeles de la vecindad sin considerar el pixel central, es decir:

$$nr = \frac{tc * 0.2 + ca * 0.4 + zu * 0.6 + av * 0.8 + ag * 1.0}{80} \tag{5.3}$$

Donde:

- $nr$  : Nivel de riesgo calculado.
- $tc$  : Total de pixeles identificados como terreno para construcción.
- $ca$  : Total de pixeles identificados como caminos-carreteras.
- $zu$  : Total de pixeles identificados como zona urbana.
- $av$  : Total de pixeles identificados como áreas verdes.
- $ag$  : Total de pixeles identificados como agua.

Por ejemplo, para calcular el nivel de riesgo en la vecindad del edificio Torre Lux, ubicado en la Residencial Vidalta al suroeste de la Zona Metropolitana del Valle de México en la delegación Cuajimalpa de Morelos. Se identifican los niveles de intensidad de sus vecinos (Ver Figura 5.13(a)) y se contabilizan conforme a su categoría (Ver Figura 5.13(b)).



**Figura 5.13:** Vecindad del edificio Torre Lux, como ejemplo para calcular el nivel de riesgo propuesto.

Posteriormente se aplica la Ecuación 5.3 y se calcula el riesgo de la vecindad.

$$\begin{aligned}
nr &= \frac{tc * 0.2 + ca * 0.4 + zu * 0.6 + av * 0.8 + ag * 1.0}{80} \\
&= \frac{0 * 0.2 + 12 * 0.4 + 32 * 0.6 + 36 * 0.8 + 0 * 1.0}{80} \\
&= \frac{52.8}{80} \\
nr &= 0.66
\end{aligned} \tag{5.4}$$

Para obtener el umbral de riesgo permitido en cada Zona Metropolitana se calculan los riesgos en la vecindad de los edificios correspondientes y se estiman intervalos de confianza considerando el nivel superior como valor de umbral permitido. Los resultados se muestran en la Tabla 5.8.

**Tabla 5.8:** Nivel de riesgo permitido en vecindad para las Zonas Metropolitanas de estudio.

Zona Metropolitana	Umbral	Regla en autómatas
Valle de México	riesgo $\leq$ 0.7363	<b>Si</b> riesgo $\leq$ 0.7363 <b>entonces</b>
Guadalajara	riesgo $\leq$ 0.4250	<b>Si</b> riesgo $\leq$ 0.4250 <b>entonces</b>
Monterrey	riesgo $\leq$ 0.7100	<b>Si</b> riesgo $\leq$ 0.7100 <b>entonces</b>

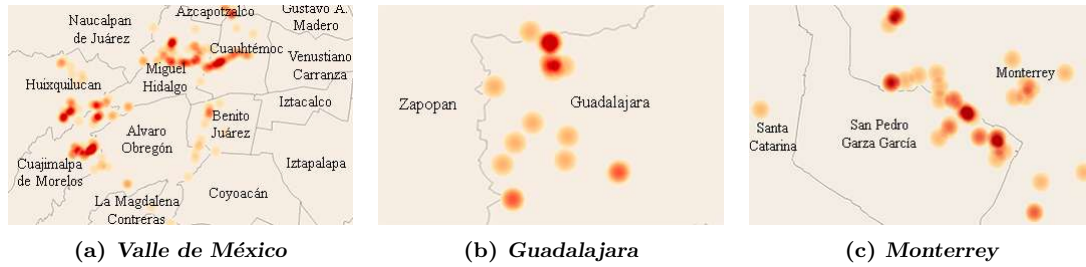
### c) Estadístico de área de influencia

El estadístico propuesto consiste en determinar la densidad de edificios que existe en el área máxima aproximada para una manzana determinada por el [INEGI \(2020c\)](#) es decir, 500 metros.

Para el cálculo del estadístico de área edificada se utiliza el enfoque estimación por densidad de núcleo (KDE, por sus siglas en Inglés). En resumen, el enfoque KDE consiste en estimar la cantidad de puntos que existen dentro de un área determinada, la influencia de los puntos dentro del área disminuye conforme se incrementa la distancia ([Lampe and Hauser, 2011](#)), lo cual se relaciona con la ley expuesta por Tolber ([Tolber, 1970](#)).

Al utilizar KDE se identifican las áreas con el mayor número de edificios en cada zona de estudio, los cuales se representan a través de mapas de calor cuyos valores rojos representan una mayor cantidad de edificios, mientras que valores claros representan una menor cantidad. Los mapas de calor generados tienen las mismas características de tamaño de celda (30 metros), ancho y alto para cada una de las zonas de estudio, lo que facilita la codificación. Estos mapas se muestran en la Figura 5.14.





**Figura 5.14:** Mapas de calor para las Zonas Metropolitanas de estudio, cuyos valores rojos representan una mayor cantidad de edificios.

El estadístico se codifica en el lenguaje Python y los resultados de los intervalos de niveles de intensidad en los mapas de calor se clasifican conforme a la escala propuesta en la Tabla 5.9.

**Tabla 5.9:** Categorías propuestas para la clasificación de niveles de influencia en los mapas de calor de las zonas de estudio.

Influencia	Valle de México	Guadalajara	Monterrey
Muy alta	$[3.1945, +\infty)$	$[2.2386, +\infty)$	$[2.9554, +\infty)$
Alta	$[2.3958, 3.1945)$	$[1.6789, 2.2386)$	$[2.2165, 2.9554)$
Media	$[1.5972, 2.3958)$	$[1.1193, 1.6789)$	$[1.4777, 2.2165)$
Baja	$[0.7986, 1.5972)$	$[0.5596, 1.1193)$	$[0.7388, 1.4777)$
Muy baja	$[-\infty, 0.7986)$	$[-\infty, 0.5596)$	$[-\infty, 0.7388)$

El estadístico de área de influencia permite que edificios cercanos se desarrollen sin importar la restricción del estadístico de distancia mínima, favoreciendo el crecimiento vertical en áreas con una influencia *Alta*, *Muy alta* y *Media* de edificios.

### 5.3.6. Autómata Celular propuesto

En la Tabla 5.10 se presentan los componentes del autómata celular propuesto, con el propósito de resumir el trabajo expuesto en la sección 5.3.

Tabla 5.10: Estructura del autómata celular propuesto.

Componente	Descripción	Valle de México	Guadalajara	Monterrey
Espacio n-dimensional	Dimensión (px)	9,358,704	7,114,582	16,395,966
Condición inicial	Datos de red neuronal	Mapa de probabilidad	Mapa de probabilidad	Mapa de probabilidad
Conjunto de estados	101 estados discretos	[0.00, 1.00]	[0.00, 1.00]	[0.00, 1.00]
Espacio de vecindad	Vecindad nivel 4, criterio de reina	80 pixeles	80 pixeles	80 pixeles
Regla 1: Tipo de suelo	Agua	[0.00, 0.31]	[0.00, 0.23]	[0.00, 0.29]
	Terreno para construcción	(0.31, 0.52]	(0.23, 0.30]	(0.29, 0.43]
	Caminos-Carreteras	(0.52, 0.58]	(0.30, 0.38]	(0.43, 0.48]
	Zona urbana	(0.58, 0.67]	(0.38, 0.54]	(0.57, 0.61]
	Áreas verdes	(0.67, 1.00]	(0.54, 1.00]	(0.61, 1.00]
	Edificios	[0.53, 0.63]	[0.25, 0.35]	[0.39, 0.47]
Regla 2	Confianza respecto a la media	[0.48 - 0.73]	[0.22 - 0.43]	[0.52 - 0.72]
Regla 3	Parámetro de riesgo	riesgo $\leq 0.7275$	riesgo $\leq 0.4250$	riesgo $\leq 0.7100$
Regla 4: Parámetro de área de influencia	Muy alto	[5.3282, $+\infty$ )	[2.7599, $+\infty$ )	[2.9554, $+\infty$ )
	Alto	[3.5523, 5.3282)	[2.0700, 2.7599)	[2.2348, 2.9554)
	Medio	[1.7764, 3.5523)	[1.3802, 2.0700)	[1.4911, 2.2348)
	Bajo	[0.0005, 1.7764)	[0.6903, 1.3802)	[0.7474, 1.4911)
	Muy bajo	$[-\infty, 0.0005)$	$[-\infty, 0.6903)$	$[-\infty, 0.7474)$

A partir de la estructura resumida en la Tabla 5.10 se genera el autómata celular considerando cada uno de los intervalos en los conjuntos de reglas propuestos, lo que permite la proyección del crecimiento urbano vertical. El Algoritmo 4 describe las reglas del autómata celular para la proyección del crecimiento vertical en las zonas de estudio, tomando como ejemplo las reglas del Valle de México presentadas en la Tabla 5.10.

---

**Algoritmo 4** Reglas para proyectar crecimiento vertical en el Valle de México.

---

```

1: Entradas:
1:   $p$  : Float array, Mapa de probabilidad.
1:  Float, Intervalos de datos.

2: Salidas:
2:   $P$  : Float array, Proyección de crecimiento vertical.

3: Variables:
3:   $p[x, y]$  : Float, Pixel a analizar.
3:   $v$  : Float array, Vecindad nivel 4 del pixel  $x, y$ .
3:   $icm$  : Float, Parámetro de intervalo respecto a la media de la vecindad  $v$ .
3:   $r$  : Float, Valor de riesgo de la vecindad  $v$ .
3:   $ai$  : Float, Parámetro de área de influencia en el pixel  $x, y$ .

4: Inicio
5:
6:   $P = p$ 
7:  Si  $0.31 < p[x, y] \leq 0.52$  O  $0.58 < p[x, y] \leq 0.67$  Entonces
8:     $v = detecta\_vecindad(p[x, y]);$ 
9:     $icm = calcula\_intervalo\_media(v);$ 
10:
11:   Si  $0.48 < icm \leq 0.72$  Entonces
12:      $r = calcula\_riesgo(v)$ 
13:
14:     Si  $r \leq 0.7275$  Entonces
15:        $ai = calcula\_area\_influencia(p[x, y]);$ 
16:        $dm = calcula\_distancia\_minima(p[x, y]);$ 
17:
18:       Si  $ai \geq 2.3958$  Entonces
19:          $P[x, y] \leftarrow EDIFICIO;$ 
20:       Fin Si
21:
22:     Fin Si
23:
24:   Fin Si
25:
26: Fin Si
27:
28: Fin

```

---

## Capítulo 6

# Experimentación y análisis de resultados

En el presente capítulo se pone a prueba el modelo propuesto para la proyección de crecimiento vertical en las zonas metropolitanas del Valle de México, Guadalajara, Monterrey, Puebla-Tlaxcala y Tokio. Posteriormente, se analizan los resultados obtenidos con el propósito de validar la capacidad del modelo para ofrecer datos que apoyen la planeación urbana.

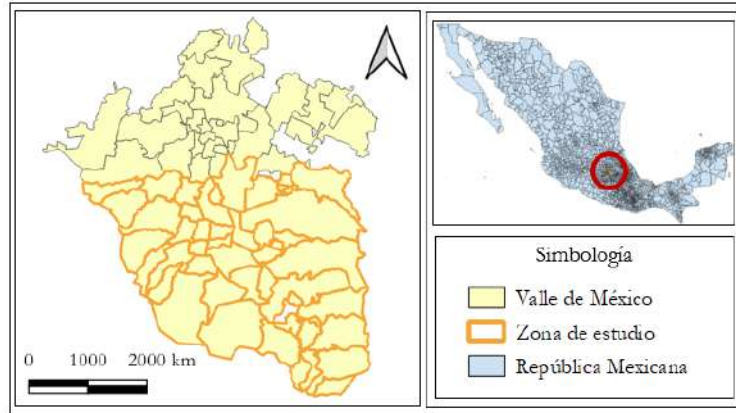
### 6.1. Zona metropolitana del Valle de México (México)

El Valle de México (ZMVM) es la zona metropolitana más grande y poblada de la República Mexicana (Ver Figura 6.1) con un total de 25,916,842 habitantes (INEGI, 2015) y una superficie de 7,854 Km<sup>2</sup>, se conforma por un total de 60 municipios pertenecientes al Estado de México e Hidalgo y las 16 alcaldías de la Ciudad de México (Sedatu, 2018).

Desde el año 2001, ha sido la primera zona en recibir presupuesto para el financiamiento de obras metropolitanas, con la característica que durante 2006 se asignó el presupuesto únicamente a ella. Posee una tasa de crecimiento medio anual del 0.8 % respecto a los años 2010-2015 y es la zona con la mayor densidad de habitantes por hectárea, con un total de 160 (Sedatu, 2018).

#### 6.1.1. Datos de trabajo

A continuación, se describen los datos que se utilizan en el modelo para la proyección de crecimiento vertical en la zona metropolitana del Valle de México.




**Figura 6.1:** Zona metropolitana del Valle de México, delimitación 2015.

## Imágenes satelitales


Para cubrir en su totalidad la ZMVM se requiere de dos imágenes ráster del satélite Landsat 8, se asume que una corresponde a la región norte y otra a la región sur.

Se trabaja únicamente con el área resaltada en la Figura 6.1 debido a la falta de edificios en la región norte los cuales son necesarios por el modelo para realizar la proyección de crecimiento vertical y a la incompatibilidad en los niveles de intensidad de las imágenes, como se observa en la Figura 6.2.



**Figura 6.2:** Limitante de la zona metropolitana del Valle de México.

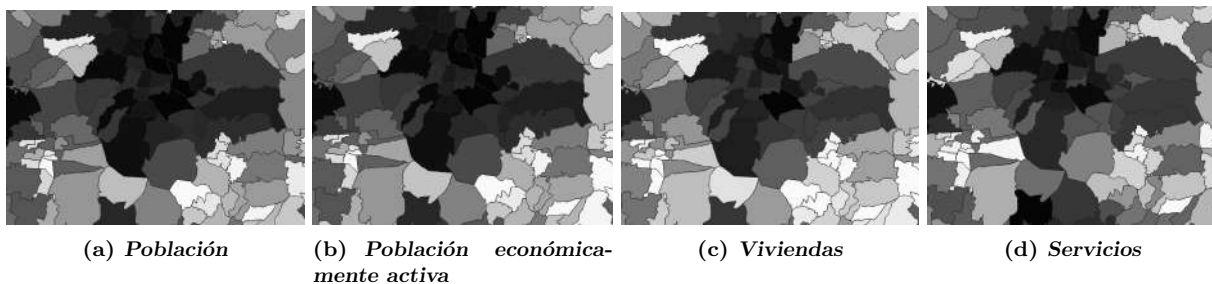
Por lo que, para el proceso experimental en la ZMVM se utilizan dos imágenes satelitales de la zona sur, una correspondiente al año 2015 (Ver Figura 6.3(a)) y otra al año 2020 (Ver Figura 6.3(b)), ambas con valores normalizados en un rango de 0-1 con un tamaño de  $3823 \times 2448$  píxeles.



**Figura 6.3:** Imágenes ráster de la zona metropolitana del Valle de México.

## Factores de crecimiento vertical

Los factores de población, viviendas, servicios y población económicamente activa descritos en la Tabla 4.2, se rasterizan conforme al proceso descrito en la sección 4.3.2. En la Figura 6.4 se presentan los factores rasterizados.



**Figura 6.4:** Imágenes ráster de factores para la zona metropolitana del Valle de México.

Las imágenes de estos factores tienen una dimensión de  $3823 \times 2448$  píxeles y se encuentran estandarizadas en un rango de 0-1, donde valores cercanos a 1 representan una mayor cantidad de población, servicios, etc. mientras que valores cercanos a 0 representan lo opuesto.

## Edificios seleccionados

De acuerdo con el Consejo de Edificios Altos y Hábitat Urbano (CTBUH), puede considerarse rascacielos a una edificación que tiene como mínimo 20 pisos o 100 metros de altura, sin embargo, los criterios pueden adaptarse según la ciudad (CTBUH, 2020).

La zona metropolitana del Valle de México cuenta con un total de 248 rascacielos registrados con las características de la definición del CTBUH para el año 2015 y 339 para el año 2020, estos se muestran en la

Figura 6.5. Los edificios del año 2015 son la base para la proyección de crecimiento vertical.

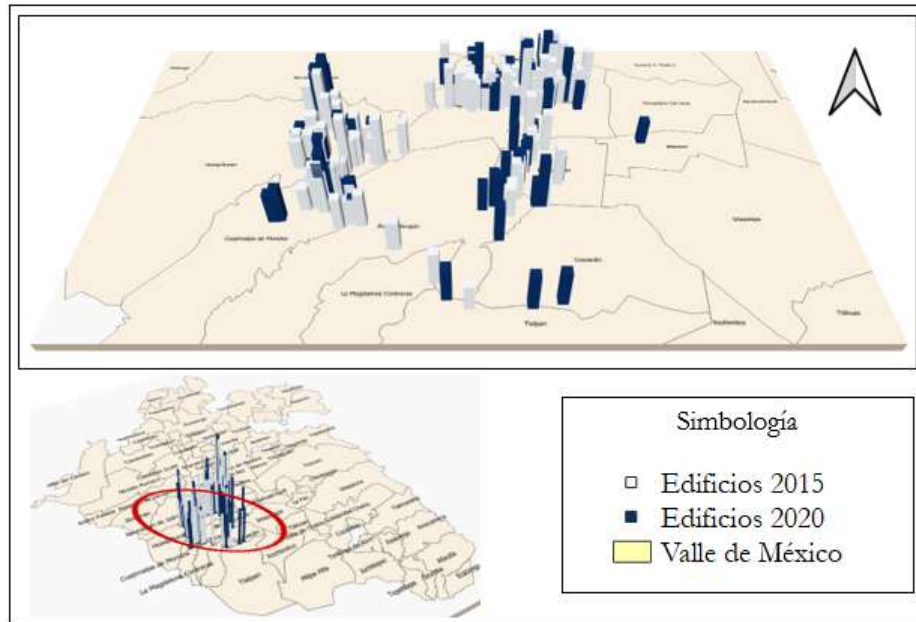


Figura 6.5: Edificios en la zona metropolitana del Valle de México.

### 6.1.2. Resultados

En la Figura 6.6 se contrastan los resultados de las proyecciones para los años 2020 y 2025 con el año 2015. Los resultados muestran una concentración de edificios en el municipio de Huixquilucan, y las delegaciones de Miguel Hidalgo y Cuauhtémoc. También se observa que el crecimiento vertical comienza a presentarse en las delegaciones de Gustavo A. Madero, Iztacalco, Tlalnepantla, Naucalpan, La Magdalena Contreras y Tlalpan.

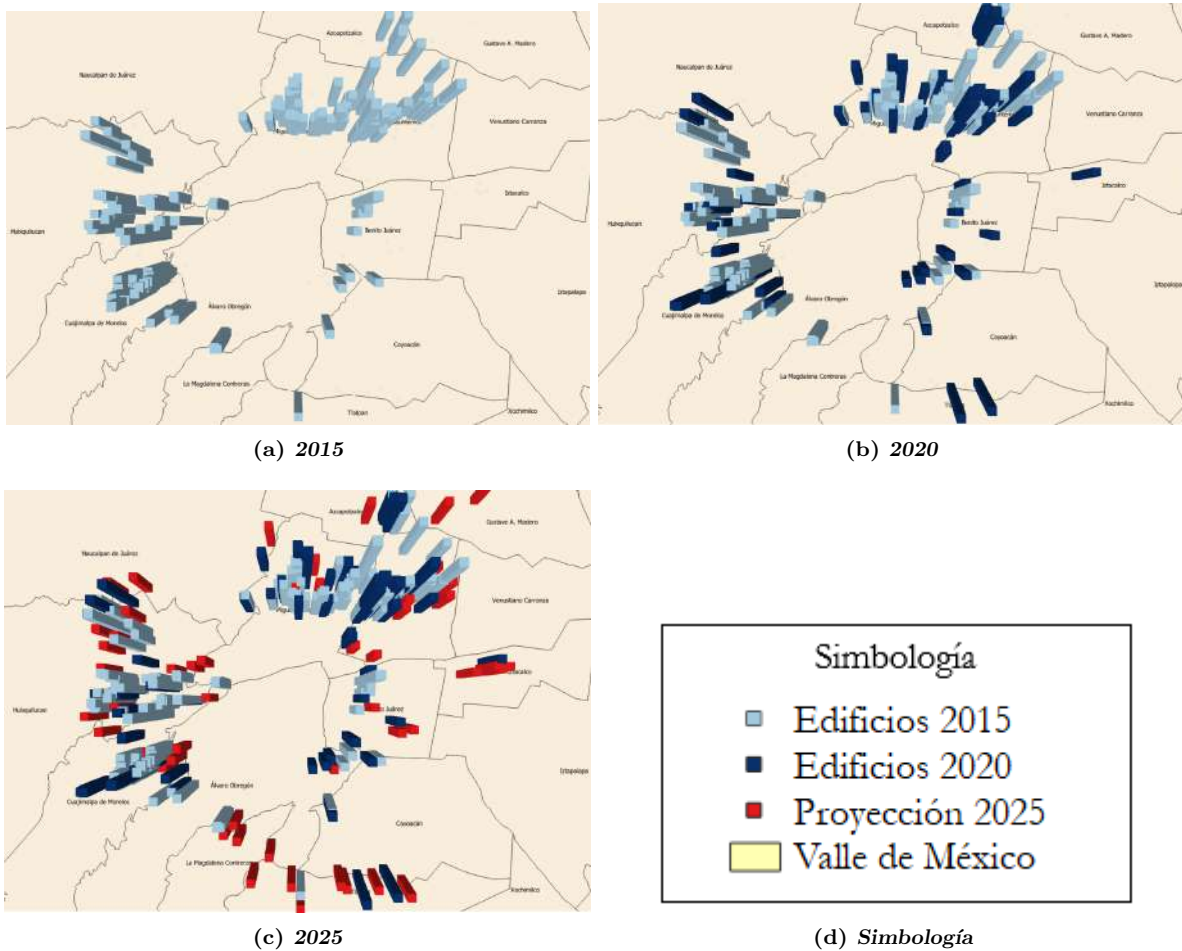


Figura 6.6: Resultados de proyección para la zona metropolitana del Valle de México.

La proyección correspondiente al año 2015-2020 para el Valle de México en cuanto al número de edificios es de un promedio del 75.81 % al proyectar correctamente 257 de los 339 edificios de ejemplo. Al contrastar los mapas del año 2020 real con el año 2020 proyectado se obtiene un índice Kappa de 0.7317 y un índice Jaccard de 0.7606, lo que corresponde a *buenos* resultados, conforme a la Tabla 4.4 propuesta. La proyección 2020-2025, estima una tasa de crecimiento vertical del 15.63 %, una tasa inferior al ser comparada con el 36.69 % de 2015 a 2020, como se muestra en la Tabla 6.1.

Tabla 6.1: Resultados de crecimiento vertical para el Valle de México.

Año	Edificios	Promedio	Índice Kappa	Índice Jaccard
2020	257/339	75.81 %	0.7317	0.7606
2025	392	—	—	—

El modelo proyecta crecimiento vertical en la zona de Santa Fe, debido a la concentración de edificios y que los factores de población y economía son altos en comparación con otras áreas de la zona metropolitana.



Adicionalmente esta zona es privilegiada, pues se encuentra entre dos de los caminos más importantes de la ciudad: Avenida Santa Fe y Prolongación Paseo de la Reforma.

En la proyección para 2025 se observa que el crecimiento vertical comienza a expandirse hacia las delegaciones de Gustavo A. Madero, Iztacalco, Tlalnepantla, Naucalpan, La Magdalena Contreras y Tlalpan, con un total de 339 edificios que superan los 100 metros de altura. Siendo las delegaciones de Huixquilucan y Miguel Hidalgo las que presentan mayor crecimiento vertical con una proyección de 9 y edificios más respectivamente para el año 2025 en relación al 2020, como se muestra en la Figura 6.7.

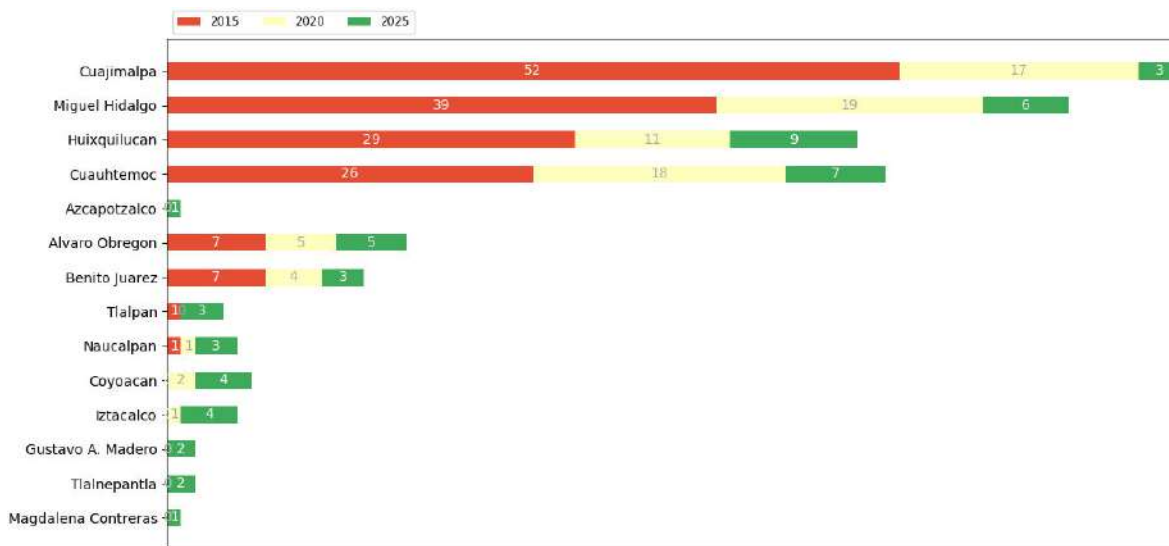


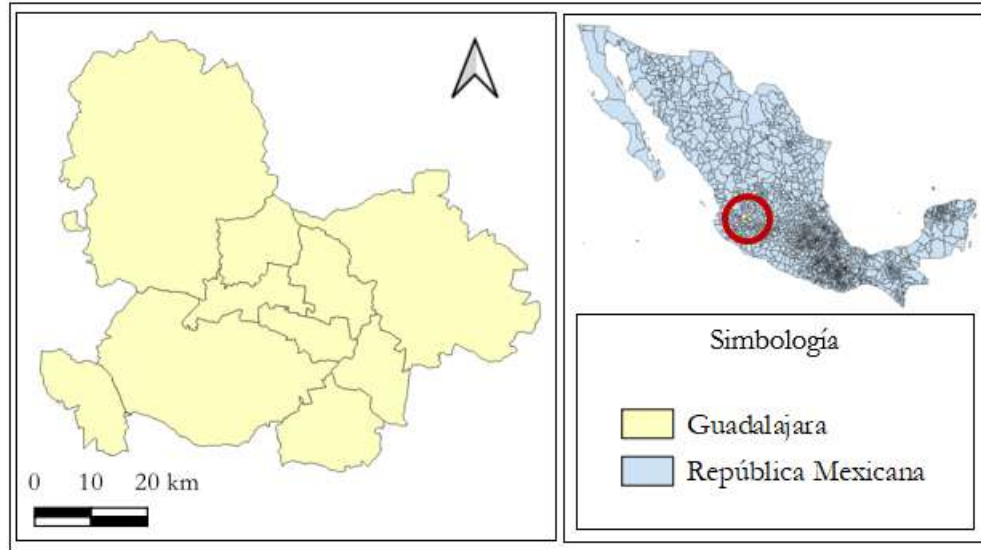
Figura 6.7: Edificios en la zona metropolitana del Valle de México.

Adicionalmente se generan animaciones en JavaScript para facilitar la visualización de los mapas 3D generados por el modelo de crecimiento vertical, las cuales se adjuntan en el disco que acompaña la presente tesis.

## 6.2. Zona metropolitana de Guadalajara (México)

La zona metropolitana de Guadalajara (Ver Figura 6.8) se localiza en el centro del estado de Jalisco y oficialmente se conforma por un total de 10 municipios (Sedatu, 2018). Datos de la encuesta intercensal 2015 la posicionan como la segunda zona más poblada del país con un total de 4,887,383 habitantes (INEGI, 2015).

En esta zona se concentra un 75% de las industrias del estado de Jalisco, las cuales en su mayoría son empresas tecnológicas (INEGI, 2015). Estadísticas del Nacional de México (2018) la ubican como el primer lugar en objetivos de desarrollo sostenible y la primera zona en tener un plan de acción climática para los municipios donde se concentre la mayor cantidad de población.



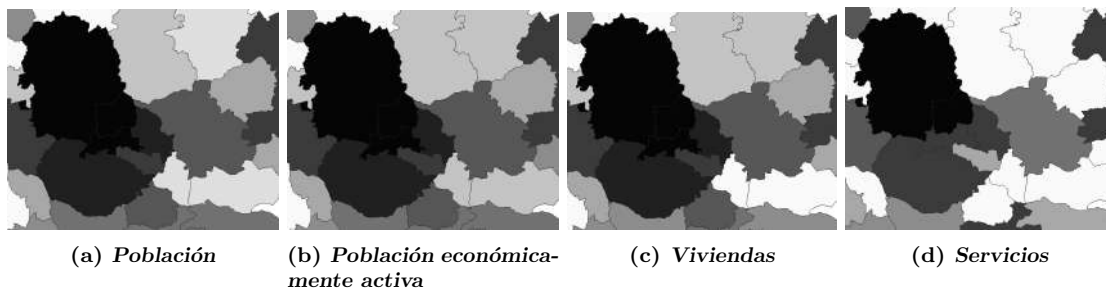
**Figura 6.8:** Zona metropolitana de Guadalajara, delimitación 2015.

### 6.2.1. Datos de trabajo

A continuación, se describen los datos que se utilizan en el modelo para la proyección de crecimiento vertical en la zona metropolitana de Guadalajara.

## Factores de crecimiento vertical

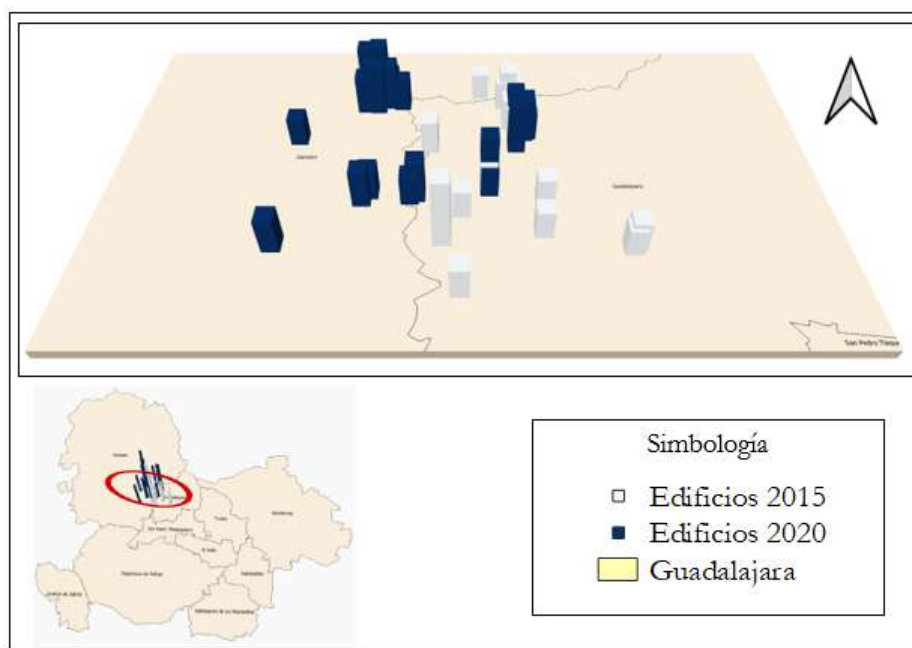
Los factores de población, viviendas, servicios y población económicamente activa descritos en la Tabla 4.2, se rasterizan conforme al proceso descrito en la sección 4.3.2. En la Figura 6.9 se presentan los factores rasterizados.



**Figura 6.9:** Imágenes ráster de factores para la zona metropolitana de Guadalajara.

## Edificios seleccionados

La zona metropolitana de Guadalajara cuenta con un total de 19 rascacielos registrados con las características de la definición del CTBUH (20 pisos o altura superior a 100 metros) para el año 2015 y 42 para el año 2020, estos se muestran en la Figura 6.10. Los edificios del año 2015 son la base para la proyección de crecimiento vertical.



**Figura 6.10:** Edificios en la zona metropolitana de Guadalajara.

### 6.2.2. Resultados

En la Figura 6.11 se contrastan los resultados de las proyecciones para los años 2020 y 2025 con el año 2015. Los resultados muestran una ligera tendencia de crecimiento vertical hacia el centro del municipio de Zapopan, lo cual puede deberse a que los datos de factores de población, vivienda y PEA del INEGI (2015) es apenas inferior a 1%, en comparación con Guadalajara.

La proyección correspondiente al año 2015-2020 para la zona metropolitana de Guadalajara en cuanto al número de edificios es de un promedio del 78.57% al proyectar correctamente 33 de los 42 edificios de ejemplo. Al contrastar los mapas del año 2020 real con el año 2020 proyectado se obtiene un índice Kappa de 0.7472 y un índice Jaccard de 0.7723, lo que corresponde a *buenos* resultados, conforme a la Tabla 4.4 propuesta. La proyección 2020-2025 produce 15 edificios adicionales, una cantidad inferior a los 23 generados de 2015 a 2020, como se muestra en la Tabla 6.2.

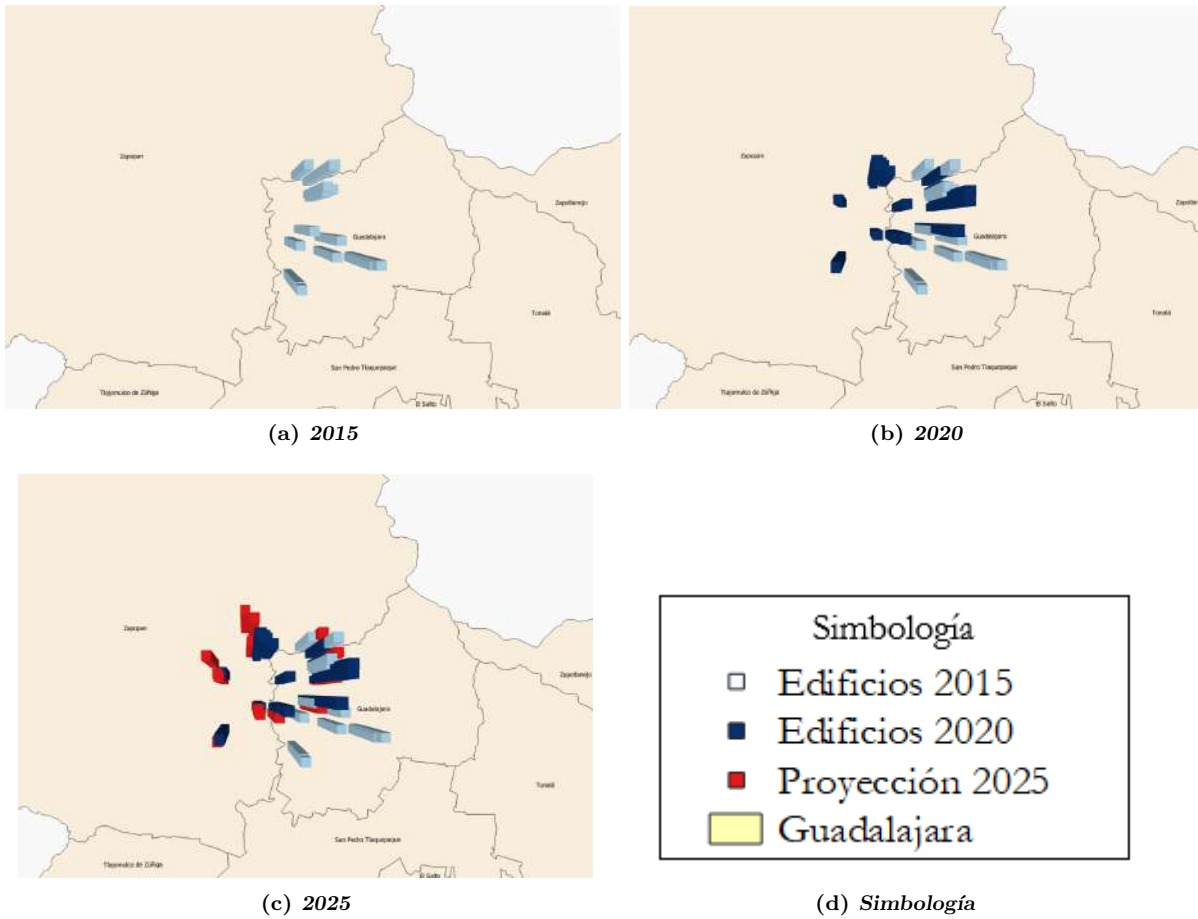


Figura 6.11: Resultados de proyección para la zona metropolitana de Guadalajara.

Tabla 6.2: Resultados de crecimiento vertical para la zona metropolitana de Guadalajara.

Año	Edificios	Promedio	Índice Kappa	Índice Jaccard
2020	33/42	78.57 %	0.7472	0.7723
2025	57	—	—	—

Los factores de la zona metropolitana de Guadalajara, en los municipios de Zapopan y Guadalajara son superiores al resto de los municipios, lo que aumenta la probabilidad de crecimiento vertical en esas zonas, con una distribución de edificios del 81 % y 19 % respectivamente 6.12. Prevalece la tendencia de superioridad del municipio de Guadalajara sobre el de Zapopan, pues en este último se proyecta un cuarto (3) de los edificios del primer municipio (12).

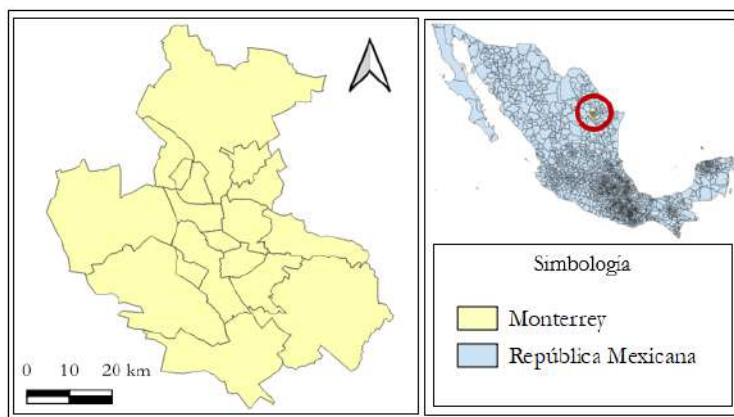


**Figura 6.12:** Edificios en la zona metropolitana de Guadalajara.

Esta concentración ha producido que la Asociación Mexicana de FIBRAS Inmobiliarias (AMEFIBRA), invierta en terrenos para edificios comerciales, hoteleros y de oficinas en el municipio de Guadalajara (Zafra, 2021).

### 6.3. Zona metropolitana de Monterrey (México)

La zona metropolitana de Monterrey (Ver Figura 6.13) se conforma por 18 municipios, representa el segundo lugar en el producto interno bruto del país y cuenta con una extensión territorial de 7,657 Km<sup>2</sup> (Sedatu, 2018). Conforme a los datos del INEGI (2015) la zona metropolitana presenta un crecimiento poblacional *Muy alto* con tasas de crecimiento que superan el 10 por ciento en los municipios de: Pesquería (35.1), El Carmen (20.2), Ciénega de Flores (12.4), García (12.1) y Salinas Victoria (11.2).



**Figura 6.13:** Zona metropolitana de Monterrey, delimitación 2015.

Destaca la economía de la zona principalmente por la capital de Monterrey considerada como la segunda

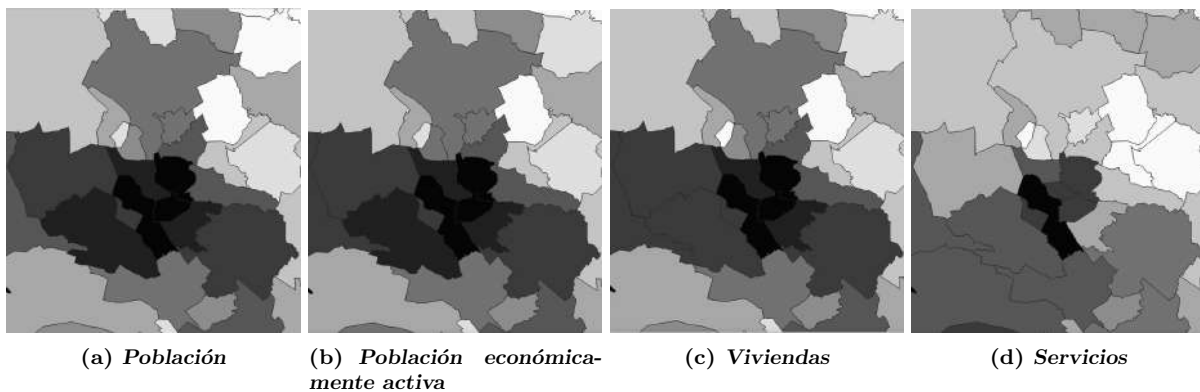
ciudad más rica de México y la novena en América Latina (INEGI, 2015). Consideraciones del *Nacional de México* (2018) determinan que es una de las zonas metropolitanas con mejor administración en el manejo del agua.

### 6.3.1. Datos de trabajo

A continuación, se describen los datos que se utilizan en el modelo para la proyección de crecimiento vertical en la zona metropolitana de Monterrey.

## Factores de crecimiento vertical

Los factores de población, viviendas, servicios y población económicamente activa descritos en la Tabla 4.2, se rasterizan conforme al proceso descrito en la sección 4.3.2. En la Figura 6.14 se presentan los factores rasterizados.



**Figura 6.14:** Imágenes ráster de factores para la zona metropolitana de Monterrey.

## Edificios seleccionados

La zona metropolitana de Monterrey cuenta con un total de 41 rascacielos registrados con las características de la definición del CTBUH (20 pisos o altura superior a 100 metros) para el año 2015 y 72 para el año 2020 (Ver Figura 6.15). Los edificios del año 2015 son la base para la proyección de crecimiento vertical.

### 6.3.2. Resultados

La Figura 6.16 contrasta los resultados de las proyecciones en los años 2020 y 2025 con el año 2015, se observa un crecimiento constante en los diferentes periodos, además de la expansión hacia municipios cercanos.

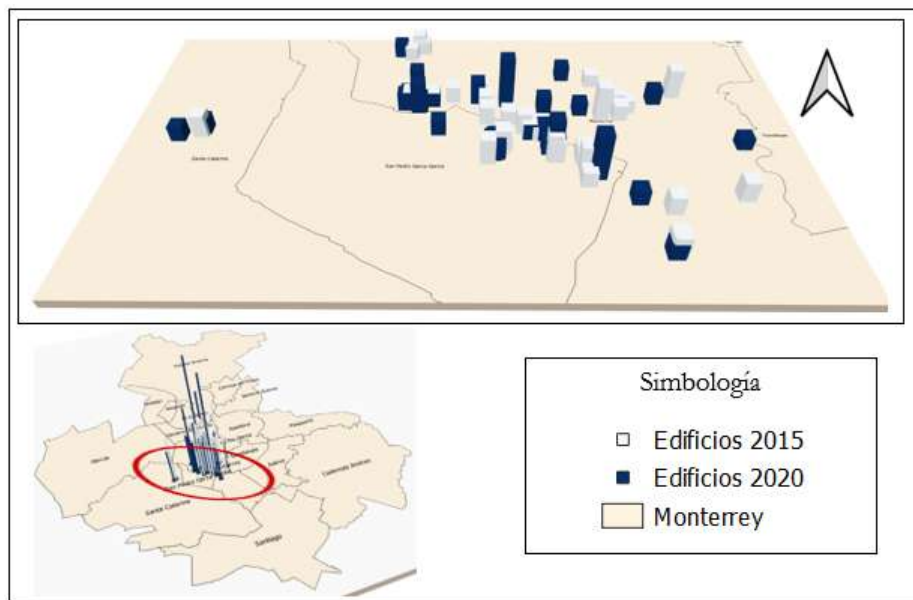


Figura 6.15: Edificios en la zona metropolitana de Monterrey.

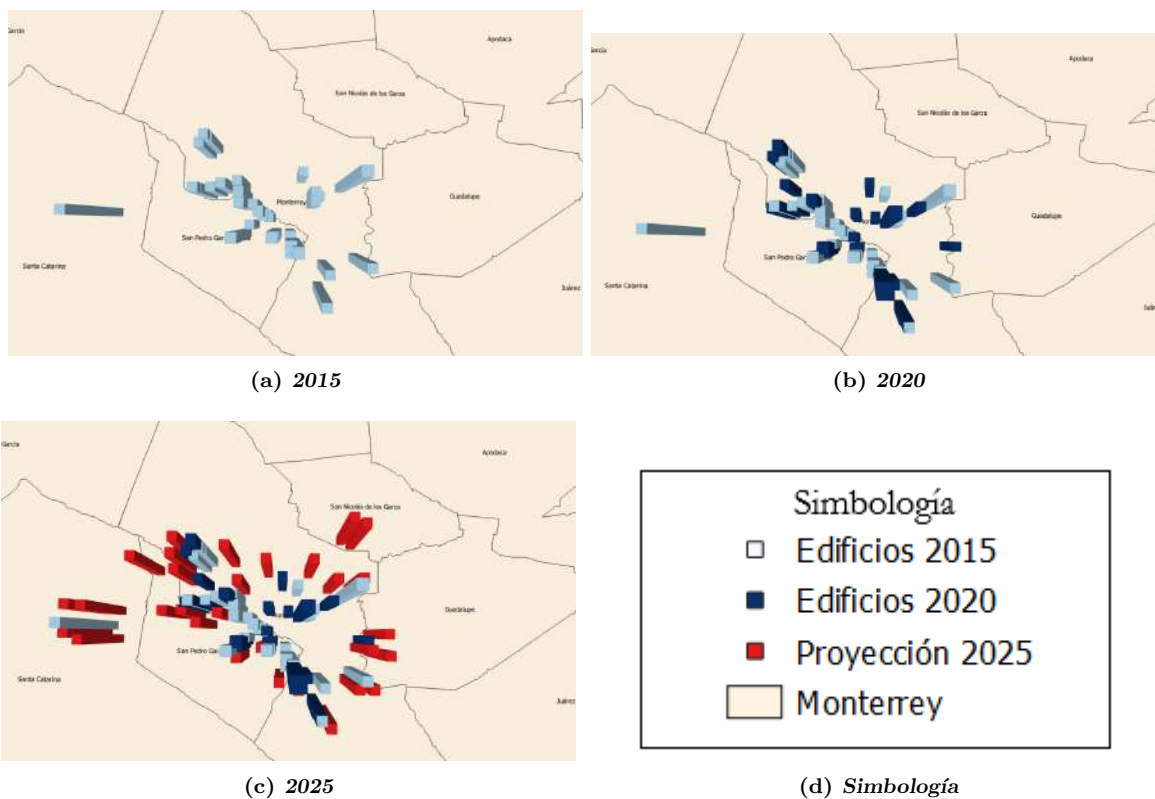


Figura 6.16: Resultados de proyección para la zona metropolitana de Monterrey.


La proyección correspondiente al año 2015-2020 para la zona metropolitana de Monterrey en cuanto al número de edificios es de un promedio del 73.61 % al proyectar correctamente 53 de los 72 edificios de ejemplo.

Al contrastar los mapas del año 2020 real con el año 2020 proyectado se obtiene un índice Kappa de 0.6866 y un índice Jaccard de 0.7109, lo que corresponde a *buenos* resultados, conforme a la Tabla 4.4 propuesta. La proyección 2020-2025 estima una tasa de crecimiento vertical del 41.66 % o 30 rascacielos, constante al periodo 2015-2020 donde se genera un total de 31 nuevos rascacielos, como se muestra en la Tabla 6.3.

**Tabla 6.3:** Resultados de crecimiento vertical para la zona metropolitana de Monterrey.

Año	Edificios	Promedio	Índice Kappa	Índice Jaccard
2020	53/72	73.61 %	0.6866	0.7109
2025	102	—	—	—

El crecimiento vertical en la zona metropolitana de Monterrey se concentra en 5 de los 18 municipios que la forman, siendo Monterrey y Garza García, los predominantes con un 93 % del total de los edificios de la zona. Sin embargo, datos del INEGI (2015) muestran un crecimiento acelerado en población y vivienda en el municipio de Guadalupe, lo que ha incrementado el dinamismo del mercado inmobiliario. Al tener colindancia con Garza García y Monterrey, el crecimiento vertical en el municipio de Santa Catarina está en aumento, con cuatro nuevos edificios para el año 2025, caso similar al de San Nicolas de los Garza con dos edificios proyectados, lo que muestra un crecimiento vertical hacia el norte y sur de la zona, como se muestra en la Figura 6.17.



**Figura 6.17:** Edificios en la zona metropolitana de Monterrey.

Para el año 2025 se proyectan 30 nuevos edificios adicionales a los 42 ya existentes en 2020, por lo que en 2025 se proyecta un total de 102 edificios, lo que equivale a un crecimiento vertical del 41.66 %.



## 6.4. Zona metropolitana de Puebla-Tlaxcala (México)

La zona metropolitana de Puebla-Tlaxcala (ZMPT) se ubica en la zona centro del estado de Puebla y al sur del Estado de Tlaxcala (Ver Figura 6.18), se compone por un total de 38 municipios 18 del estado de Puebla y 20 de Tlaxcala. Datos del INEGI (2015) estiman un total de 2,941,988 habitantes, siendo la cuarta zona con mayor población en la República Mexicana.

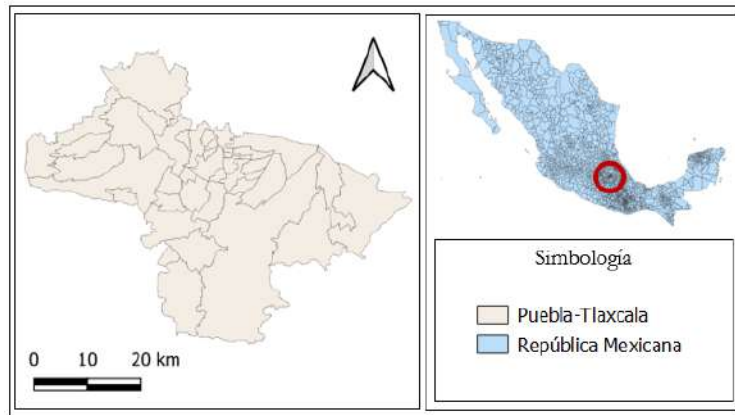


Figura 6.18: Zona metropolitana de Puebla-Tlaxcala, delimitación 2015.

Estadísticas de la Secretaría de Economía muestran que las inversiones en el estado de Puebla generan rendimientos de hasta el 30 %, lo que ha incrementado la inversión inmobiliaria del estado, lo que ha aumentado su crecimiento vertical (Zafra, 2019).

### 6.4.1. Datos de trabajo

A continuación, se describen los datos que se utilizan en el modelo para la proyección de crecimiento vertical en la zona metropolitana de Puebla-Tlaxcala.

## Factores de crecimiento vertical

Los factores de población, viviendas, servicios y población económicamente activa descritos en la Tabla 4.2, se rasterizan conforme al proceso descrito en la sección 4.3.2. En la Figura 6.19 se presentan los factores rasterizados.

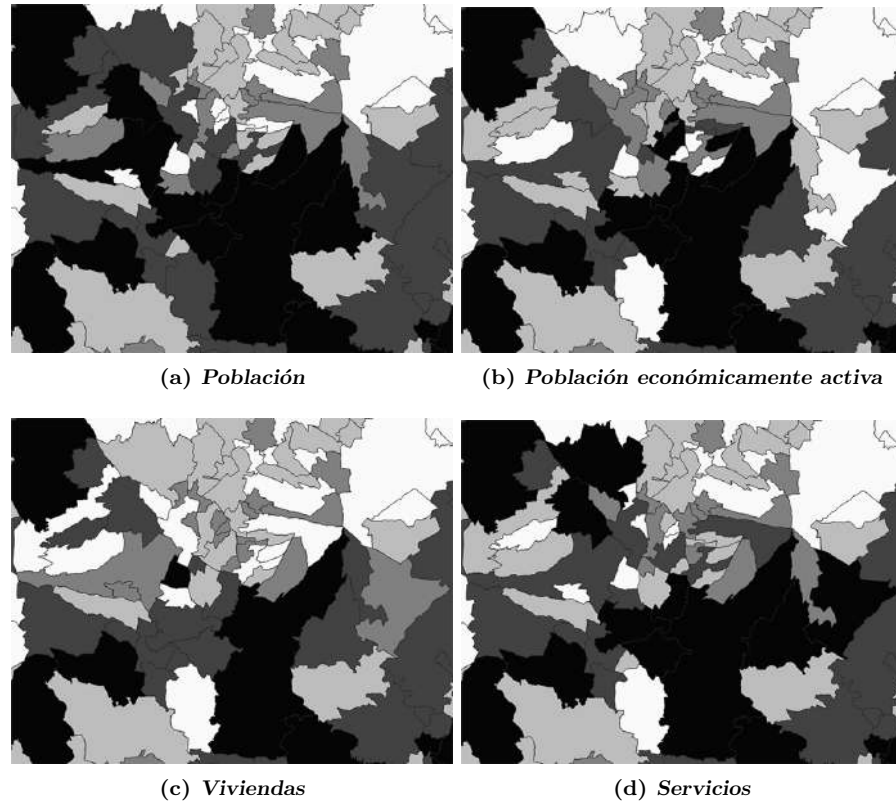


Figura 6.19: Imágenes ráster de factores para la zona metropolitana de Puebla-Tlaxcala.

## Edificios seleccionados

La ZMPT cuenta con un total de 11 rascacielos registrados con las características de la definición del CTBUH (20 pisos o altura superior a 100 metros) para el año 2015 y 25 para el año 2020, estos se muestran en la Figura 6.20. Los edificios del año 2015 son la base para la proyección de crecimiento vertical.

### 6.4.2. Resultados

En la Figura 6.21 se contrastan los resultados de las proyecciones para los años 2020 y 2025 con el año 2015, se observa que hasta el año 2015 la mayoría de los edificios se concentraban en San Andrés Cholula sin embargo, después de ese año el crecimiento vertical se concentra en el municipio de Puebla y comienza a presentarse en el municipio de Huejotzingo.

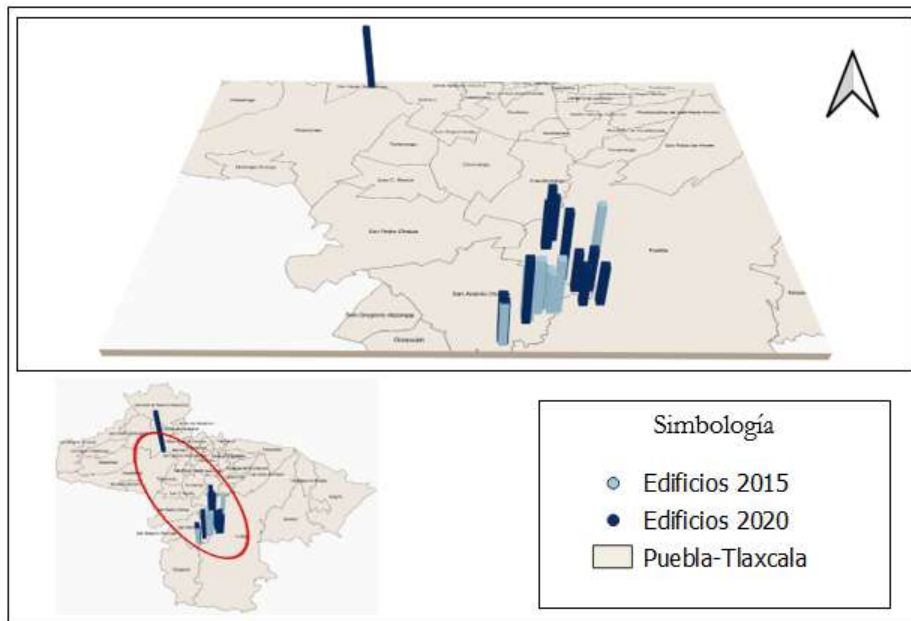


Figura 6.20: Edificios en la zona metropolitana de Puebla-Tlaxcala.

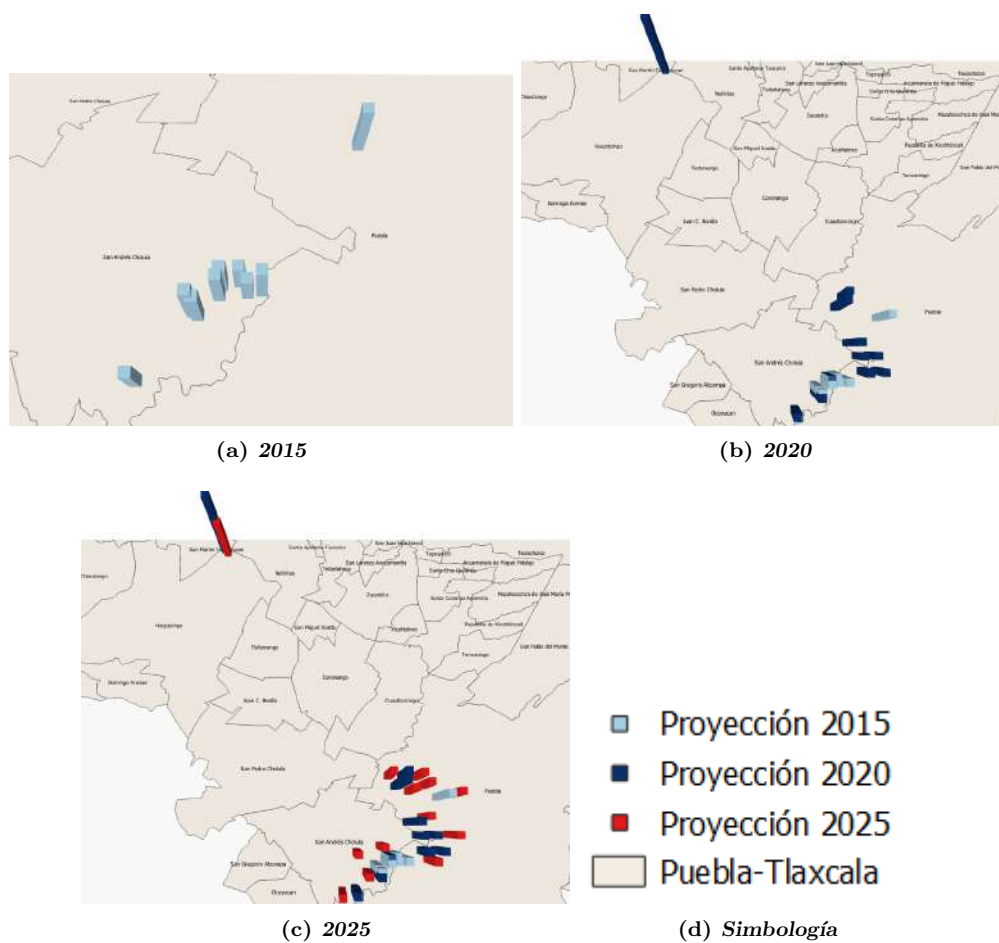


Figura 6.21: Resultados de proyección para la zona metropolitana de Puebla-Tlaxcala.

La proyección correspondiente al año 2015-2020 para la zona metropolitana de Puebla-Tlaxcala en cuanto al número de edificios es de un promedio del 64 % al proyectar correctamente 16 de los 25 edificios de ejemplo. Al contrastar los mapas del año 2020 real con el año 2020 proyectado se obtiene un índice Kappa de 0.6721 y un índice Jaccard de 0.6848, lo que corresponde a *buenos* resultados, conforme a la Tabla 4.4 propuesta. La proyección 2020-2025 estima una tasa de crecimiento vertical del 52 % o 13 rascacielos, constante al periodo 2015-2020 donde se genera un total de 14 nuevos rascacielos, como se muestra en la Tabla 6.4.

**Tabla 6.4:** Resultados de crecimiento vertical para la zona metropolitana de Puebla-Tlaxcala.

Año	Edificios	Promedio	Índice Kappa	Índice Jaccard
2020	16/25	64 %	06721	0.6848
2025	38	—	—	—

El crecimiento vertical en la ZMPT se concentra en 2 de los 38 municipios que la forman, siendo el único caso de estudio en el que la capital no tiene la mayor cantidad de rascacielos. Hasta el año 2018 que comienza a surgir crecimiento vertical en el municipio de Huejotzingo con la Torre Santa Júlía.

Al contrastar los factores de crecimiento vertical se observa la superioridad de los municipios del estado de Puebla sobre los de Tlaxcala, razón por que quizá no se presente crecimiento vertical en sus municipios. Por otro lado, el gobierno de Puebla describe que el crecimiento vertical consiste de desarrollos privados y aislados de la dinámica pública, debido a la falta de comunicación y regulación (Flores and Vélez, 2020).

La proyección 2025 mantiene la disparidad de crecimiento vertical en la ZMPT con cuatro nuevos rascacielos en el municipio de San Andrés Cholula, ocho en Puebla y uno en Huejotzingo como se muestra en la Figura 6.22.



**Figura 6.22:** Edificios en la zona metropolitana de Puebla-Tlaxcala.

El crecimiento vertical favorece al municipio de Puebla y San Andr s Cholula lo cual puede deberse a la superioridad de sus factores de poblaci n, servicios, viviendas y poblaci n econ micamente activa (INEGI, 2015). Sin embargo, el crecimiento vertical no ha sido planificado y ha generado problemas de sobreoferta de viviendas, y congestionamiento por las nuevas construcciones (Flores and V lez, 2020).

## 6.5. Metr polis de Tokio (Jap n)

Tokio, nombrada oficialmente como metr polis de Tokio (Zhang et al., 2018) es la capital de Jap n y el  rea geogr fica con mayor cantidad de poblaci n del pa s, con una cantidad que supera los 13.42 millones de habitantes y una superficie de 1,402.32 km<sup>2</sup> (Statistics of Tokyo, 2016). La metr polis se divide en 23 barrios especiales (*ku*), 26 ciudades (*shi*) y cuatro pueblos (*machi*) (Metropolitan Library, 2021), esta se muestra en la Figura 6.23.

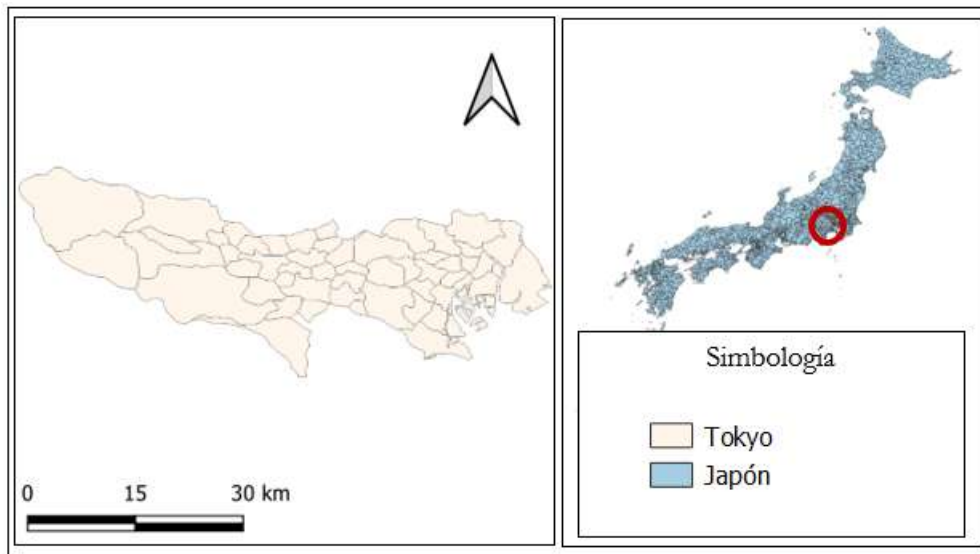


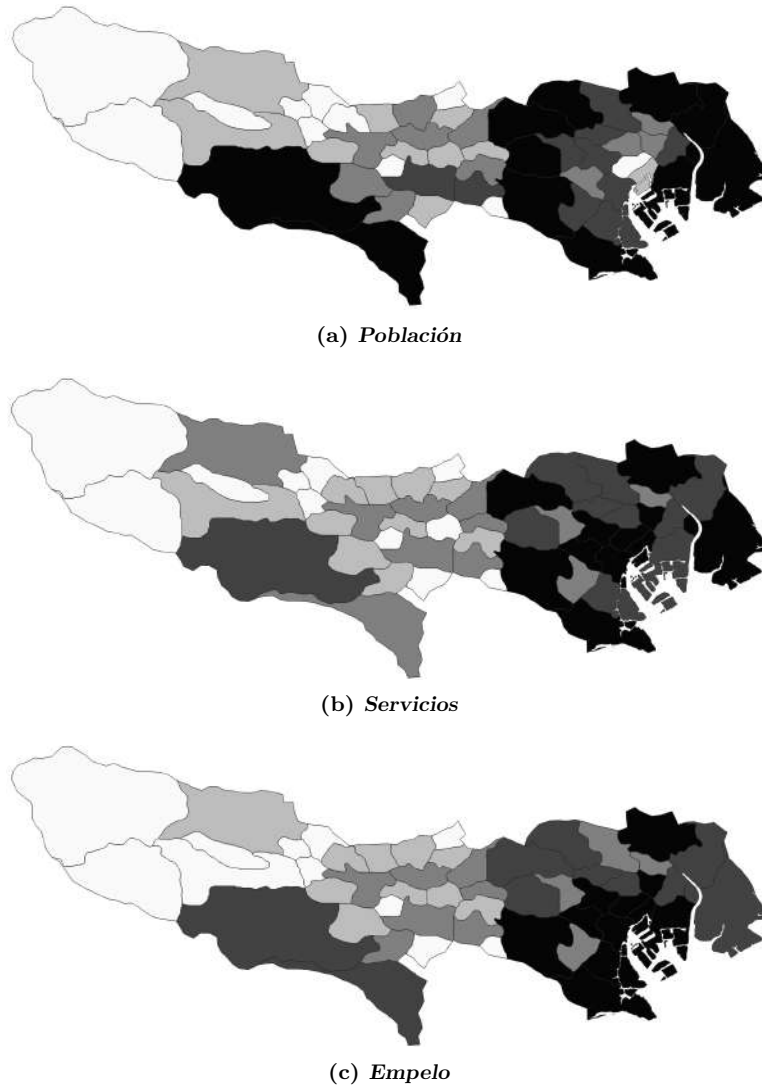
Figura 6.23: Metr polis de Tokyo.

### 6.5.1. Datos de trabajo

A continuaci n, se describen los datos que se utilizan en el modelo para la proyecci n de crecimiento vertical en la metr polis de Tokio.

### Factores de crecimiento vertical

Los factores de poblaci n, servicios y empleo provenientes del Tokyo Statistical Yearbook (Statistics of Tokyo, 2016) se rasterizan conforme al proceso descrito en la secci n 4.3.2, para ser utilizados en el modelo. En la Figura 6.24 se presentan los factores rasterizados.



**Figura 6.24:** Imágenes ráster de factores para la metrópolis de Tokio.

### Edificios seleccionados

La metrópolis de Tokio cuenta con un total de 644 rascacielos registrados con las características de la definición del CTBUH (20 pisos o altura superior a 100 metros) para el año 2015 y 79 para el año 2020, estos se muestran en la Figura 6.25. Los edificios del año 2015 son la base para la proyección de crecimiento vertical.

#### 6.5.2. Resultados

En la Figura 6.26 se contrastan los resultados de las proyecciones para los años 2020 y 2025 con el año 2015. El crecimiento se concentra en los barrios de Minato y Chiyoda, sin embargo, debido a la limitación de espacio el crecimiento vertical se expande hacia nuevos barrios.

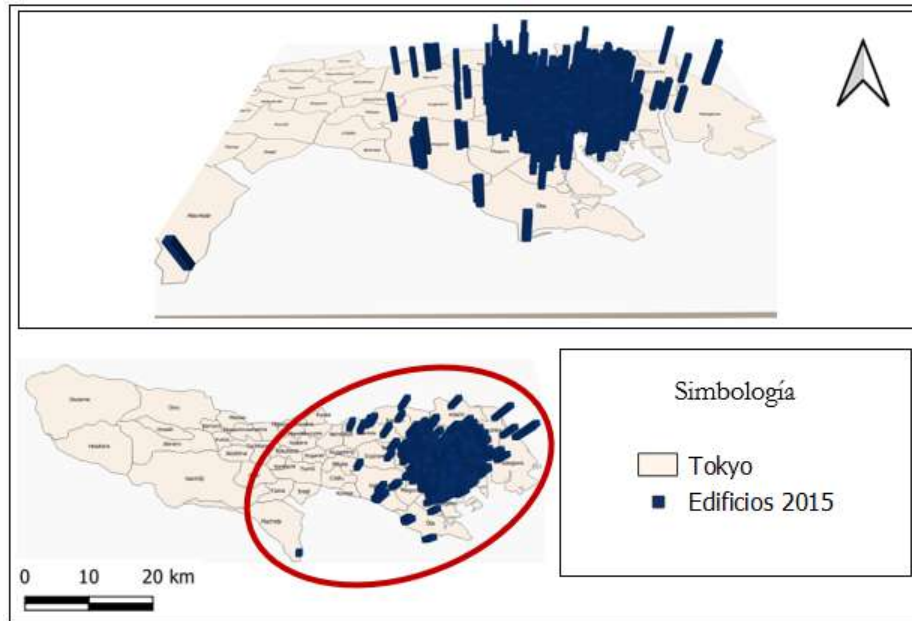


Figura 6.25: Edificios en la metr polis de Tokio.

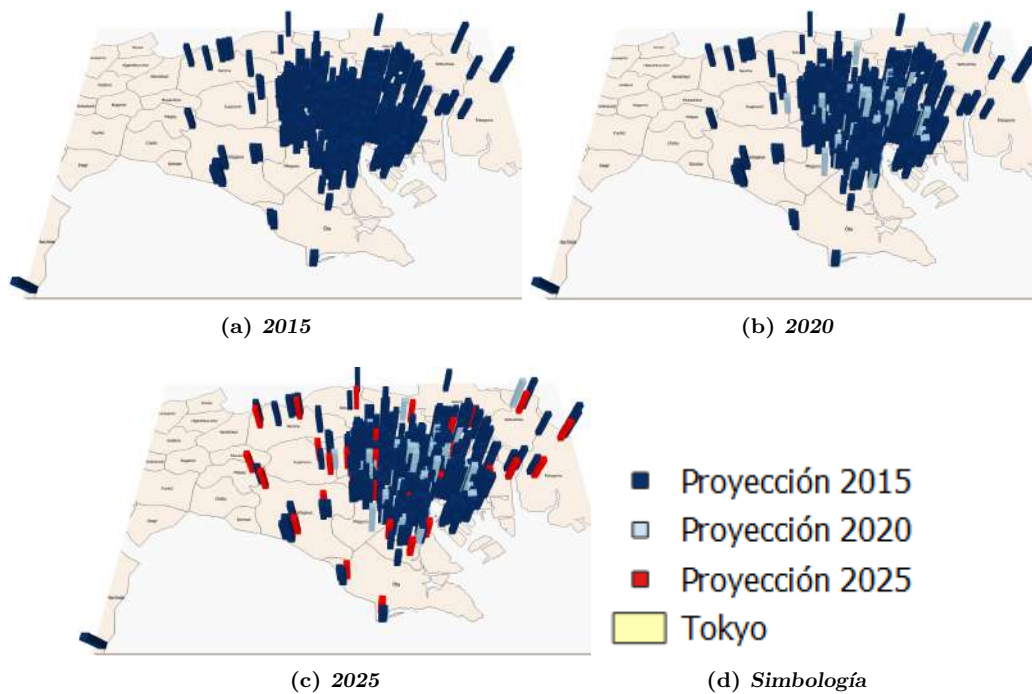


Figura 6.26: Resultados de proyecci n para la metr polis de Tokio.


La proyecci n correspondiente al a o 2015-2020 para Tokio en cuanto al n mero de edificios tiene una exactitud del 79.80 % al proyectar correctamente 577 de los 723 edificios de ejemplo. Al contrastar los mapas

del año 2020 real con el año 2020 proyectado se obtiene un índice Kappa de 0.8003 y un índice Jaccard de 0.7986, lo que corresponde a una exactitud *buena*, conforme a la Tabla 4.4 propuesta. La proyección 2020-2025 estima un total de 32 nuevos rascacielos, como se muestra en la Tabla 6.5.

**Tabla 6.5:** Resultados de crecimiento vertical para la metrópolis de Tokio.

Año	Edificios	Promedio	Índice Kappa	Índice Jaccard
2020	577/723	0.7980%	0.8003	0.7986
2025	755	—	—	—

El crecimiento vertical en Tokio ha experimentado diversas etapas, siendo su mayor crecimiento durante los años 2000-2010, sin embargo, después de esa fecha el crecimiento se ha visto limitado manteniendo un promedio que ronda entre 30 y cuarenta nuevos rascacielos anualmente, como se observa en la Figura 6.27.



**Figura 6.27:** Crecimiento vertical en Tokio por año. Imagen obtenida de (Metropolitan Government, 2019).

Al analizar la vecindad de los edificios de ejemplo se observa que a partir de 2015 comienzan a tener una mayor concentración de áreas verdes en su periferia. Lo cual ha reducido el crecimiento vertical de Tokio pues antes de la construcción de un edificio el gobierno exige un Plan Medioambiental del Edificio con el propósito de fomentar esfuerzos de conservación del medio ambiente (Metropolitan Government, 2019), considerando cuatro áreas medioambientales: gestión de energía, uso adecuado de recursos, conservación del entorno natural y reducción de efectos de isla de calor (Machimura, 2021).

Por otro lado, el modelo proyecta crecimiento vertical en la zona Este, donde se concentra la mayor canti-



dad de edificios y economía del país, por lo que se mantiene la constante de concentrarse en zonas limitadas en lugar de expandirse sobre el territorio, siendo Setagaya y Shinagawa los *ku* con mayor crecimiento vertical, al presentar tres nuevos edificios cada uno, como se observa en la Figura 6.28.



Figura 6.28: Edificios en Tokio.

Lo cual es parte de la organización del gobierno de Tokio, manteniendo el crecimiento vertical en los barrios especiales, mientras que en las ciudades se concentra el área urbana donde viven los trabajadores (Machimura, 2021).

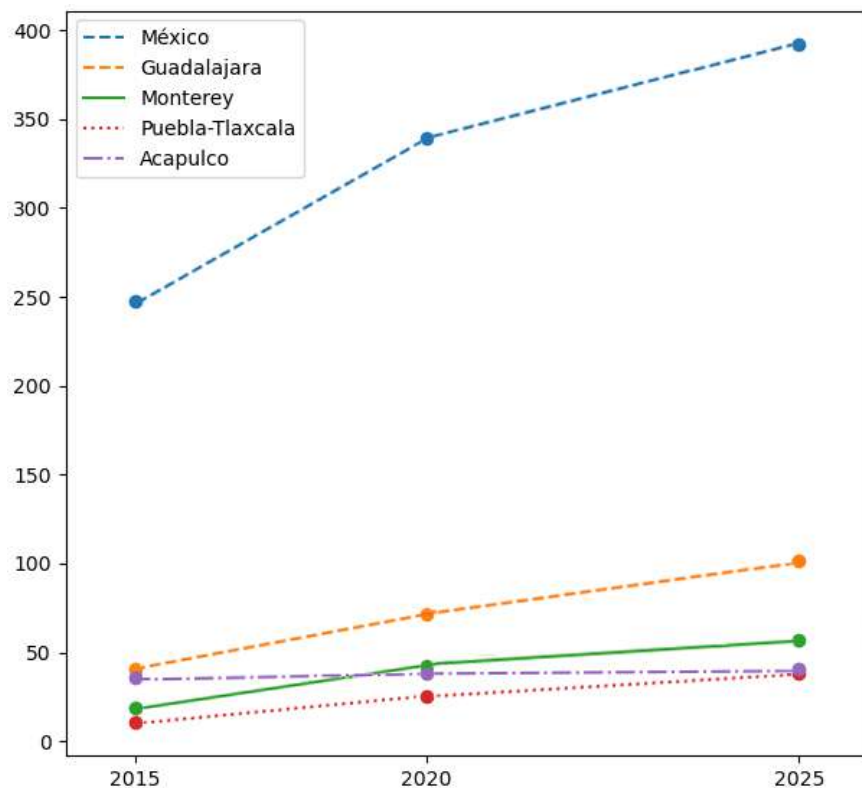
## 6.6. Resumen de resultados

En la Tabla 6.6 se presentan los resultados de las proyecciones para cada una de las zonas de estudio. De forma general, el modelo propuesto presenta una exactitud promedio respecto a la proyección del número de edificios del 74.35 %, con un índice Kappa de 0.7275 para evaluar la posición de crecimiento vertical y un índice Jaccard de 0.7454, lo cual conforme a la Tabla 4.4 propuesta representan *buenos* resultados, superando la exactitud en los modelos del estado del arte con un 2.35 %.

**Tabla 6.6:** Resumen de resultados de crecimiento vertical proyectado.

Zona metropolitana	Año	Edificios	Promedio	Índice Kappa	Índice Jaccard
Valle de México (ZMVM)	2020	257/339	75.81 %	0.7317	0.7606
	2025	392	—	—	—
Guadalajara (ZMGDL)	2020	33/42	78.57 %	0.7472	0.7723
	2025	57	—	—	—
Monterrey (ZMMTY)	2020	53/72	73.61 %	0.6866	0.7109
	2025	102	—	—	—
Puebla-Tlaxcala (ZMPT)	2020	16/25	64.00 %	0.6721	0.6848
	2025	38	—	—	—
Tokio	2020	577/723	79.80 %	0.8003	0.7986
	2025	755	—	—	—
<b>General</b>			74.35 %	0.7275	0.7454

El crecimiento vertical en México tiende a concentrarse en las zonas metropolitanas con mejores factores económicos y sociales. Siendo la ZMVT el área con mayor concentración vertical del país, en la Figura 6.29, se muestra el crecimiento vertical a través de los años de estudio.

**Figura 6.29:** Crecimiento vertical en zonas metropolitanas de México.

Al comparar los resultados de la Tabla 6.6 con investigaciones del estado del arte se observa que el modelo

es superior a las investigaciones en el desempeño general de predicción, como se muestra en la Tabla 6.7.

**Tabla 6.7:** Comparación entre investigaciones de la literatura con el trabajo propuesto.

Referencia	Técnica	Datos	Exactitud
Modelo propuesto	RNA + AC	Ráster Vectorial	74.35 %
(Chen et al., 2020)	RNC + ST	Ráster	73.00 %
(Shi et al., 2020)	InSAR*	Fotogramétricos	69.97 %
(Zambon et al., 2019)	APC	Ráster	60.00 %
(Zhang et al., 2018)	CM	Ráster	72.00 %
(He et al., 2017)	RNA+AC	Ráster	65.20 %
(Koziatek and Dragičević, 2017)	CityEngine	Ráster	63.10 %
(Pazos Perez et al., 2017)	AG	Fotogramétricos	66.70 %
(Zhang et al., 2017)	SVM+CM+OM	Ráster	66.00 %
(Lin et al., 2014)	AC	Ráster	68.80 %

\*Multi-baseline interferometric synthetic aperture radar techniques.

En la Tabla 6.7 se presentan dos investigaciones del año 2020, el trabajo de Chen et al. (2020) presenta una exactitud del 73 % de exactitud, para la proyección utiliza redes neuronales convolucionales y series de tiempo. Por otro lado, el trabajo de Shi et al. (2020) presenta una exactitud del 69.97 % con técnicas de geodesia y en teledetección (InSAR). Estos trabajos muestran que la investigación en crecimiento vertical es un tema que continúa siendo explorado y presenta múltiples áreas de oportunidad.

Al comparar el modelo con otros trabajos se observa que se encuentra limitado por el número de factores que se trabajan en la red neuronal. Por ejemplo, el trabajo de (He et al., 2017) incorpora doce factores y su método de calibración supera en rapidez al modelo generado.

Pazos Perez et al. (2017) presenta un modelo basado en algoritmos genéticos, siendo una de sus conclusiones descritas la limitación de métricas de validación en el modelo, por lo que el modelo propuesto puede considerarse *confiable* al contar con tres métricas de validación.

El trabajo de Koziatek and Dragičević (2017) realizado en el lenguaje *Computer Generated Architecture* se limita a un al SIG privado ARCGIS y trabaja únicamente con datos vectoriales, por lo que la herramienta generada a partir del modelo es más flexible al trabajar con imágenes ráster y datos vectoriales, por otro lado es de código abierto.

## Capítulo 7

# Conclusiones y trabajo futuro

En esta tesis se presentó un modelo de crecimiento vertical integrado al Sistema de Información Geográfico QGIS, el cuál esta basado en una red neuronal y un autómata celular. Para validar este modelo se modelo se proyectaron zonas metropoliatanas nacionales e internacionales.

### 7.1. Conclusiones

En esta investigación se realizó la proyección de crecimiento vertical en zonas metropolitanas nacionales e internacionales. Las áreas urbanas nacionales experimentadas fueron: Valle de México, Guadalajara, Monterrey y Puebla-Tlaxcala, mientras que para el caso internacional se experimentó en la zona metropolitana de Tokio (Japón).

El modelo propuesto es novedoso porque esta basado en el estudio de factores que impulsan el crecimiento vertical, el procesamiento de imágenes satelitales, la rasterización de datos vectoriales, redes neuronales y autómatas celulares. Por otro lado, la herramienta se encuentra integrada al SIG libre QGIS (Codigo <https://github.com/luyzLopez/GIS.git>) y permite simular múltiples escenarios, lo que brinda a planeadores urbanos e investigadores centrar su interés en el análisis de resultados más no en la generación de los mismos.

De acuerdo a los resultados presentados en el Capítulo 6, se observa que el crecimiento vertical se concentra alrededor de las ciudades principales de México; sin embargo, con el paso de los años comienza a expandirse hacia los municipios cercanos debido a la relación entre los factores de crecimiento vertical.

En la Tabla 6.7 se muestra que el modelo propuesto en esta tesis tiene una exactitud del 74.36 %, superando en un 2.35 % a los modelos de crecimiento vertical del estado del arte, aceptandose así la hipótesis planteada en esta investigación. Además, los objetivos planteados para esta investigación se cumplen al:

- Analizar factores de crecimiento vertical y e integrarlos al modelo.

- Proyectar el crecimiento vertical con técnicas de inteligencia artificial.
- Codificar el modelo en el lenguaje Python e integrarlo al SIG QGIS.

A partir de estos resultados existe una oportunidad para planificar los futuros patrones de urbanización, dado que el crecimiento vertical se origina en el centro de las zonas metropolitanas y poco a poco se expande, por otro lado, las proyecciones generadas en esta investigación permiten anticiparse en la toma de decisiones de los asentamientos verticales del país.

Desde la perspectiva de los posibles residentes de una ciudad vertical, los tomadores de decisiones deben lograr un equilibrio para garantizar en la medida de lo posible seguridad en los edificios, accesibilidad a servicios y reducción de daño a la naturaleza.

Mediante la simulación de escenarios de crecimiento vertical con el modelo propuesto, los planificadores urbanos podrán tomar decisiones fundamentadas para los futuros cambios en las ciudades y anticipar nuevas necesidades tanto políticas, como sociales.

## 7.2. Trabajo futuro

Al concluir esta tesis se observan diferentes líneas de trabajo futuro, las cuales se puntualizan a continuación.

Analizar los resultados de varios escenarios de crecimiento vertical modificando los factores de crecimiento o las reglas del autómata celular, lo cual permitiría a planificadores urbanos tomar decisiones fundamentadas para los futuros cambios en las ciudades y anticipar nuevas necesidades de infraestructuras o reglamentos.

La investigación en crecimiento vertical tiene áreas de oportunidad con técnicas tanto de inteligencia artificial como de análisis espacial, por lo que, es posible mejorar el trabajo propuesto ya sea con el tratamiento de imágenes satelitales, estadísticas de factores de crecimiento, arquitecturas de redes neuronales, o nuevas reglas para el autómata celular.

Específicamente, algunas mejoras para el modelo propuesto son:

- A partir de redes Bayesianas, identificar la correlación con mayor significancia de factores adicionales como distancia a servicios, tasa de empleo, desarrollo económico entre otros, para integrarlos al modelo propuesto.
- Utilizar redes neuronales convolucionales o *Support Vector Machines*, para automatizar el procesamiento de imágenes satelitales y la clasificación de los diferentes tipos de suelo. Mejorando la extracción de zona urbana en menor tiempo de procesamiento.

- Integrar reglas de crecimiento con parámetros de accesibilidad o interacción espacial a fin de orientar el crecimiento conforme las necesidades sociales.
- Desarrollar la herramienta en los Sistemas de Información Geográfica ArcGIS y MappingGIS para permitir que un mayor número de investigadores, planificadores urbanos o cualquier persona interesada en el tema pueda utilizar la herramienta.

# Referencias

- Abdalla, R. and Esmail, M. (2019). *Artificial Intelligence and WebGIS for Disaster and Emergency Management*, pages 57–62. Springer. [3](#), [4](#), [22](#)
- Abhishek, N., Jenamani, M., and Mahanty, B. (2017). Urban growth in Indian cities: Are the driving forces really changing? *Habitat International*, 69:48–57. [22](#), [23](#)
- Adamatzky, A. (2018). *Cellular Automata: A Volume in the Encyclopedia of Complexity and Systems Science*. Springer. [47](#)
- Agyemang, F. S., Silva, E., and Anokye, P. A. (2018). Towards sustainable urban development: the social acceptability of high-rise buildings in a Ghanaian city. *GeoJournal*, 83(6). [27](#)
- Almeida, C. d., Gleriani, J., Castejon, E. F., and Soares-Filho, B. S. (2008). Using neural networks and cellular automata for modelling intra-urban land-use dynamics. *International Journal of Geographical Information Science*, 22(9):943–963. [39](#)
- Ambrosio, G., González, J., and Arévalo, V. (2002). Corrección radiométrica y geométrica de imágenes para la detección de cambios en una serie temporal. *Málaga, España*. [33](#)
- Angel, S., Shepherd, S., and Civco, D. (2008). The dynamics of global urban expansion. Transport and Urban Development Department, Washington. The World Bank. [4](#)
- Arias, H. A., Zamora, R. M., and Bolaños, C. V. (2014). Metodología para la corrección atmosférica de imágenes Aster, RapidEye, Spot 2 y Landsat 8 con el módulo FLAASH del software ENVI. *Revista Geográfica de América Central*, 2(53):39–59. [33](#)
- Batty, M. (1997). Cellular automata and urban form: a primer. *Journal of the American Planning Association*, 63(2):266–274. [54](#)
- Batty, M. (2018). Artificial intelligence and smart cities. [4](#)
- Benguigui, L., Czamanski, D., and Roth, R. (2008). Modeling cities in 3D: a cellular automaton approach. *Environment and Planning B: Planning and Design*, 35(3):413–430. [27](#)
- Bharne, V. (2012). *The Emerging Asian City: Concomitant Urbanities & Urbanisms*. Taylor & Francis. [28](#)
- Bhatti, S. S. and Tripathi, N. K. (2014). Built-up area extraction using Landsat 8 OLI imagery. *GIScience & Remote Sensing*, 51(4):445–467. [34](#), [35](#), [36](#)
- Bičik, I., Jeleček, L., and Štěpánek, V. (2001). Land-use changes and their social driving forces in Czechia in the 19th and 20th centuries. *Land use policy*, 18(1):65–73. [23](#)
- Bishop, C. M. et al. (1995). *Neural networks for pattern recognition*. Oxford university press. [44](#)

- Bouchard, M., Joussetme, A.-L., and Doré, P.-E. (2013). A proof for the positive definiteness of the jaccard index matrix. *International Journal of Approximate Reasoning*, 54(5):615–626. [40](#)
- Boulos, M. N. K., Peng, G., and VoPham, T. (2019). An overview of GeoAI applications in health and healthcare. *International Journal of Health Geographics*. [3](#), [22](#)
- Bunge, M. (2016). Qué es ya qué puede aplicarse el método científico. *Revista de filosofía DIÁNOIA*, 23(23):88–101. [28](#)
- Bürgi, M., Hersperger, A. M., and Schneeberger, N. (2005). Driving forces of landscape change-current and new directions. *Landscape Ecology*, 19(8):857–868. [21](#), [22](#), [23](#), [29](#)
- Burrough, P. (1998). *Principles of Geographical Information Systems*. Oxford University, 3rd edition. [3](#)
- Burton-Johnson, A., Black, M., Fretwell, P., and Kaluza-Gilbert, J. (2016). An automated methodology for differentiating rock from snow, clouds and sea in Antarctica from Landsat 8 imagery: a new rock outcrop map and area estimation for the entire Antarctic continent. *The Cryosphere*, 10:1665–1677. [31](#)
- Buzai, G. D. (2015). *Análisis espacial en Geografía de la Salud*. Lugar Editorial. [7](#)
- Buzai, G. D. (2018). Crecimiento urbano y potenciales conflictos entre usos del suelo en el municipio de Luján (Provincia de Buenos Aires, Argentina). Modelado espacial 2016-2030. *Cuadernos Geográficos*, 57(1):155–176. [2](#), [21](#), [29](#)
- Camagni, R., Gibelli, M. C., and Rigamonti, P. (2002). Urban mobility and urban form: the social and environmental costs of different patterns of urban expansion. *Ecological economics*, 40(2):199–216. [9](#)
- Campbell, J., Shin, M., et al. (2018). Geographic information system basics. . [VIII](#), [8](#)
- Carter, B. and Meyers, R. (2009). Cellular automata on triangular, pentagonal and hexagonal tessellations. In *Encyclopedia of Complexity and Systems Sciences*, pages 892–900. Springer. [19](#)
- Catanese, A. and Steiss, A. (1968). Systemic planning for very complex systems. *Planning outlook*, 5(1-2):7–27. [6](#), [7](#)
- Chakraborti, S., Das, D. N., Mondal, B., Shafizadeh-Moghadam, H., and Feng, Y. (2018). A neural network and landscape metrics to propose a flexible urban growth boundary: A case study. *Ecological indicators*, 93:952–965. [1](#), [15](#), [23](#), [29](#)
- Chaparro, J. J. G. (2014). Balance del modelo de la planeación urbana en México: orientaciones teóricas para evaluar experiencias de intervención en América Latina. *Cuadernos del CENDES*, 31(86):27–48. [6](#)
- Chávez, T. and Garrocho, C. (2018). Christaller: Estación de Inteligencia Territorial. *Geografía y Sistemas de Información Geográfica*, 10:29–50. [3](#)
- Chen, T.-H. K., Qiu, C., Schmitt, M., Zhu, X. X., Sabel, C. E., and Prishchepov, A. V. (2020). Mapping horizontal and vertical urban densification in denmark with landsat time-series from 1985 to 2018: a semantic segmentation solution. *Remote Sensing of Environment*, 251:112096. [87](#)
- Chow, T. E. (2018). When GeoAI Meets the Crowd. In *Proceedings of the 2nd ACM SIGSPATIAL International Workshop on AI for Geographic Knowledge Discovery*, pages 52–53. ACM. [22](#)
- Cowardin, Arnold, Shaffer, Pywell, and Miller (1988). Artificial intelligence and natural resource management. *Science*, page 262–267. [11](#)
- Cruz, P. P. (2011). *Inteligencia artificial con aplicaciones a la ingeniería*. Alfaomega. [3](#), [11](#)



- Culik II, K. and Yu, S. (1988). Undecidability of CA classification schemes. *Complex Systems*, 2(2):177–190. [20](#)
- de Graaf, C. N., Koster, A. S., Vincken, K. L., and Viergever, M. A. (1992). A methodology for the validation of image segmentation methods. In *[1992] Proceedings Fifth Annual IEEE Symposium on Computer-Based Medical Systems*, pages 17–24. IEEE. [31](#)
- De la Luz Hernández, M., Otazo-Sánchez, E. M., Galeana-Pizana, M., Roldán-Cruz, E. I., Razo-Zárate, R., González-Ramírez, C. A., Galindo-Castillo, E., and Gordillo-Martínez, A. J. (2017). Urban driving forces and megacity expansion threats. Study case in the Mexico City periphery. *Habitat International*, 64:109–122. [4](#), [21](#), [22](#), [23](#), [29](#)
- De Sa, J. M. (2012). *Pattern recognition: concepts, methods and applications*. Springer Science & Business Media. [14](#), [15](#)
- Douglas, M. et al. (2002). *Diseño y análisis de experimentos*. Limusa Wiley, México, segunda edición. [57](#)
- Duque, J. C., Lozano-Gracia, N., Patino, J. E., Restrepo, P., and Velasquez, W. A. (2019). *Spatio-Temporal Dynamics of Urban Growth in Latin American Cities: An Analysis Using Nighttime Lights Imagery*. The World Bank. [4](#), [21](#), [23](#), [56](#)
- Fatès, N. (2018). Asynchronous cellular automata. In *Encyclopedia of Complexity and Systems Sciences*, pages 73–92. Springer. [19](#), [49](#)
- Félix, A. d. M. (2015). Impactos del crecimiento vertical en la expansión de la zona conurbada de Querétaro. Master's thesis, Universidad Autónoma de Nuevo León. [27](#)
- Flores, O. and Vélez, F. (2020). Crecimiento vertical en Puebla: un caos de altura. Obtenido de: <https://www.milenio.com/politica/comunidad/crecimiento-vertical-en-puebla-un-caos-de-altura>. Consultado el 19 de Marzo de 2021. [80](#), [81](#)
- Forman (2014). *Land Mosaics: The ecology of landscapes and regions (1995)*. Springer. [9](#)
- Garrocho, C. (2016). Ciencias sociales espacialmente integradas: la tendencia de Economía, Sociedad y Territorio. *Economía, sociedad y territorio*, 16(50):0–0. [2](#)
- Ghosh, t., Mukhopadhyay, t., Chanda, A., Mondal, P., Akhand, A., Mukherjee, S., Nayak, S., Ghosh, S., Mitra, D., Ghosh, T., et al. (2017). Application of Cellular automata and Markov-chain model in geospatial environmental modeling-A review. *Remote Sensing Applications: Society and Environment*, 5:64–77. [19](#)
- Gómez Vargas, E., Obregón Neira, N., and Rocha Arango, D. F. (2013). Cloud segmentation methods applied to satellite images. *Tecnura*, 17(36):96–110. [31](#)
- Goodchild, M. F., Anselin, L., and Deichmann, U. (1993). A framework for the areal interpolation of socio-economic data. *Environment and planning A*, 25(3):383–397.
- Gounaridis, D., Choriantopoulos, I., and Koukoulas, S. (2018). Exploring prospective urban growth trends under different economic outlooks and land-use planning scenarios: The case of Athens. *Applied geography*, 90:134–144. [23](#)
- Hajian, A. and Styles, P. (2018). *Application of soft computing and intelligent methods in geophysics*. Springer. [11](#), [13](#)

- Han-Qiu, X. (2005). A study on information extraction of water body with the modified normalized difference water index (MNDWI). *Journal of remote sensing*, 5:589–595. [35](#)
- Handayani, H., Murayama, Y., Ranagalage, M., Liu, F., and Dissanayake, t. (2018). Geospatial analysis of horizontal and vertical urban expansion using multi-spatial resolution data: A case study of Surabaya, Indonesia. *Remote Sensing*, 10(10). [27](#)
- Hao, R., Su, W., and Yu, D. (2012). Quantifying the type of urban sprawl and dynamic changes in shenzhen. In *International Conference on Computer and Computing Technologies in Agriculture*, pages 407–415. Springer. [10](#)
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*. Prentice Hall. [11](#), [13](#)
- Haykin, S. (2010). *Neural Networks and Learning Machines*. Pearson Education. [13](#), [15](#)
- Haykin, S. and Network, N. (2004). A comprehensive foundation. *Neural networks*, 2(2004):41. [16](#), [17](#), [18](#)
- He, Q., Liu, Y., Zeng, C., Chaohui, Y., and Tan, R. (2017). Simultaneously simulate vertical and horizontal expansions of a future urban landscape: A case study in Wuhan, Central China. *International Journal of Geographical Information Science*, 31(10):1907–1928. [1](#), [2](#), [10](#), [24](#), [27](#), [39](#), [44](#), [45](#), [56](#), [87](#)
- Hester, J. (1971). *Systems Models of Urban Growth and Development—Urban Systems Laboratory*. [9](#)
- Hoang, N.-D. and Bui, D. T. (2017). GIS-based landslide spatial modeling using batch-training back-propagation artificial neural network: a study of model parameters. In *International Conference on Geospatial Technologies and Earth Resources*, pages 239–254. Springer. [15](#), [43](#), [45](#)
- Hu, Y., Gao, S., Newsam, S., and Lunga, D. (2019). GeoAI 2018 workshop report the 2nd ACM SIGSPATIAL international workshop on GeoAI: AI for geographic knowledge discovery seattle, GeoWA, USA–November 6, 2018. *SIGSPATIAL special*, 10(3). [11](#)
- Irons, J. R., Dwyer, J. L., and Barsi, J. A. (2012). The next Landsat satellite: The Landsat data continuity mission. *Remote Sensing of Environment*, 122:11–21. [32](#)
- Jacobson, I., Booch, G., and Rumbaugh, J. (2000). *The unified software development process*. Pearson educación,. [42](#)
- Jiménez, E. (2019). Cadenas de Markov espaciales para simular el crecimiento del Área Metropolitana de Toluca, 2017-2031. *Economía, sociedad y territorio*, 19(60):109–140. [xi](#), [1](#), [41](#)
- Jones, C. B. (2014). *Geographical information systems and computer cartography*. Routledge. [8](#)
- Kari, J. (2005). Theory of cellular automata: A survey. *Theoretical computer science*, 334(1-3):3–33. [19](#)
- Karlik, B. and Olgac, A. V. (2011). Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4):111–122. [13](#)
- Kaviari, F., Mesgari, M. S., Seidi, E., and Motieyan, H. (2019). Simulation of urban growth using agent-based modeling and game theory with different temporal resolutions. *Cities*, 95. [1](#), [11](#), [22](#), [40](#)
- Kendall, K. E. (2005). *Análisis y diseño de sistemas*. Pearson educación. [42](#)
- Kotkar, S. R. and Jadhav, B. (2015). Analysis of various change detection techniques using satellite images. In *2015 International Conference on Information Processing*, pages 664–668. IEEE. [39](#)

- Koziatek, O. and Dragičević, S. (2017). iCity 3D: A geosimulation method and tool for three-dimensional modeling of vertical urban development. *Landscape and Urban Planning*, 167:356–367. [1](#), [2](#), [10](#), [24](#), [27](#), [87](#)
- Koziatek, O. and Dragičević, S. (2019). A local and regional spatial index for measuring three-dimensional urban compactness growth. *Environment and Planning B: Urban Analytics and City Science*, 46(1):143–164. [10](#), [11](#), [27](#)
- Kristollari, V. and Karathanassi, V. (2020). Artificial neural networks for cloud masking of Sentinel-2 ocean images with noise and sunglint. *International Journal of Remote Sensing*, 41(11):4102–4135. [11](#), [15](#)
- Lampe, O. D. and Hauser, H. (2011). Interactive visualization of streaming data with kernel density estimation. In *2011 IEEE Pacific Visualization Symposium*, pages 171–178. IEEE. [60](#)
- Lee, C. (2016). *Models in planning: an introduction to the use of quantitative models in planning*. Elsevier. [7](#)
- Li, C., Li, J., and Wu, J. (2018a). What drives urban growth in China? A multi-scale comparative analysis. *Applied Geography*, 98:43–51. [21](#), [22](#), [23](#)
- Li, S., Dragicevic, S., Castro, F. A., Sester, M., Winter, S., Coltekin, A., Pettit, C., Jiang, B., Haworth, J., Stein, A., et al. (2016). Geospatial big data handling theory and methods: A review and research challenges. *ISPRS journal of Photogrammetry and Remote Sensing*, 115:119–133. [3](#)
- Li, X. and Gong, P. (2016). Urban growth models: progress and perspective. *Science Bulletin*, 61(21):1637–1650. [2](#)
- Li, X., Wu, J., and Li, X. (2018b). Cellular Neural Networks. In *Theory of Practical Cellular Automaton*, pages 193–232. Springer. [45](#)
- Li, X., Wu, J., Li, X., et al. (2018c). *Theory of Practical Cellular Automaton*. Springer. [16](#), [17](#), [18](#)
- Li, X. and Yeh, A. G.-O. (2001). Calibration of cellular automata by using neural networks for the simulation of complex urban systems. *Environment and Planning A*, 33(8):1445–1462. [39](#)
- Li, X. and Yeh, A. G.-O. (2002). Neural-network-based cellular automata for simulating multiple land use changes using GIS. *International Journal of Geographical Information Science*, 16(4):323–343. [39](#), [43](#), [45](#)
- Lin, J., Huang, B., Chen, M., and Huang, Z. (2014). Modeling urban vertical growth using cellular automata—Guangzhou as a case study. *Applied Geography*, 53:172–186. [1](#), [2](#), [11](#), [24](#), [27](#), [49](#), [87](#)
- Llopis, J. P. (2010). *Sistemas de información geográfica aplicados a la gestión del territorio*. Editorial Club Universitario. [38](#)
- Longley, P. A., Goodchild, M. F., Maguire, D. J., and Rhind, D. W. (2005). *Geographic information systems and science*. John Wiley & Sons. [7](#)
- Machimura, T. (2021). Gentrification without gentry in a declining global city?: Vertical expansion of Tokyo and its urban meaning 1. *International Journal of Japanese Sociology*, 30(1):6–22. [84](#), [85](#)
- Makse, H. A., Andrade, J. S., Batty, M., Havlin, S., Stanley, H. E., et al. (1998). Modeling urban growth patterns with correlated percolation. *Physical Review*, 58(6):7054. [10](#)
- Margenstern, M. (2007). *Cellular Automata in Hyperbolic Spaces: Theory*, volume 1. Archives contemporaines. [ix](#), [19](#), [49](#)
- McCulloch, W. S. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133. [12](#)

- Meade, N. et al. (1995). Neural network time series forecasting of financial markets. *International Journal of Forecasting*, 11(4):601–602. 11, 15
- Minsky, M. and Papert, S. A. (2017). *Perceptrons: An introduction to computational geometry*. MIT Press. 14
- Mualam, N., Salinger, E., and Max, D. (2019). Increasing the urban mix through vertical allocations: Public floorspace in mixed use development. *Cities*, 87:131–141. 25, 26
- Mustafa, A., Cools, M., Saadi, I., and Teller, J. (2017). Coupling agent-based, cellular automata and logistic regression into a hybrid urban expansion model (HUEM). *Land Use Policy*, 69:529–540. 1, 23, 29
- NCGIA (2018). Fundamental Research in Geographic Information Analysis. [http://www.ncgia.ucsb.edu/pubs/pubs\\_cd.html](http://www.ncgia.ucsb.edu/pubs/pubs_cd.html). Consultado el 09 de Enero 2020. 7
- ONU (2011). Estado de las ciudades de Mexico 2010-2011. <http://bibliotecadigital.imipens.org/uploads/Estado%20de%20las%20Ciudades%20de-Mexico%202010-2011%20-%20SEDESOL.pdf>. Consultado el 23 de Octubre de 2019. 3
- Openshaw, S. and Openshaw, C. (1997). *Artificial intelligence in geography*. John Wiley & Sons, Inc. 44
- Openshaw, S. and Taylor, P. (1984). The modifiable unit areal problem. *Norwich: Geobooks*. 55
- Orellana, J., Best, S., and Claret, M. (2006). Sistemas de Información Geográfica (SIG). PROCISUR, *Agricultura de Presición: Integrando Conocimientos para una Agricultura Moderna y Sustentable*, 1:133–146. 3
- Ou, C., Yang, J., Du, Z., Li, P., and Zhu, D. (2018). Simulating Multiple Land Use Changes by Incorporating Deep Belief Network into Cellular Automata: A Case Study in Beijing, China. 43, 44
- Palma Méndez, J. T. and Morales, R. M. (2008). Inteligencia artificial. Técnicas, métodos y aplicaciones. *Edit McGraw-Hill*. VIII, VIII, 12, 14
- Paola, J. D. and Schowengerdt, R. A. (1995). A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification. *IEEE Transactions on Geoscience and remote sensing*, 33(4):981–996. 45
- Pazos Perez, R. I., Carballal, A., Rabuñal, J. R., Mures, O. A., and García-Vidaurrázaga, M. D. (2017). Predicting vertical urban growth using genetic evolutionary algorithms in Tokyo’s Minato ward. *Journal of Urban Planning and Development*, 144(1). 1, 24, 27, 39, 87
- Ramachandran, P., Zoph, B., and Le, Q. V. (2017). Searching for activation functions. *Cornell University*. 13
- Rashed, T., Weeks, J. R., Stow, D., and Fugate, D. (2005). Measuring temporal compositions of urban morphology through spectral mixture analysis: toward a soft approach to change analysis in crowded cities. *International Journal of Remote Sensing*, 26(4):699–718. 23
- Rathore, M. M., Ahmad, A., Paul, A., and Rho, S. (2016). Urban planning and building smart cities based on the internet of things using big data analytics. *Computer Networks*, 101:63–80. 7
- Richardson, D. and van Oosterom, P. (2013). *Advances in Spatial Data Handling: 10th International Symposium on Spatial Data Handling*. Springer Science & Business Media. 39
- Romero, J. J., Dafonte, C., Gómez, A., and Penousal, F. (2007). Inteligencia artificial y computación avanzada. *Santiago de Compostela: Fundación Alfredo Brañas*. 11

- Ron, F., Prill, E., and Elaine, W. (2001). The use of Geographic Information Systems by corporate real estate executives. *Journal of Real Estate Research*, 22(1-2):153–164. 7
- Rook, D. and Monk, A. t. (2018). Deep Geography: Implications of the Socio-Spatial Structure in Artificial-Intelligence Research for Financial Institutions. *Stanford University*. 4
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, pages 533–536. 15, 16, 18
- Sabater, N., Ruiz-Verdú, A., Delegido, J., Fernández-Beltrán, R., Latorre-Carmona, P., Pla, F., González-Audicana, M., Álvarez-Mozos, J., Sola, I., Villa, G., et al. (2016). Development of advanced products for the SEOSAT/Ingenio mission. *Revista de Teledetección*, pages 23–40. 34
- Salvati, L., Zitti, M., and Sateriano, A. (2013). Changes in city vertical profile as an indicator of sprawl: Evidence from a Mediterranean urban region. *Habitat International*, 38:119–125. 10, 11
- Sandercock, L. and Lyssiotis, P. (2003). *Cosmopolis II: Mongrel cities of the 21st century*. A&C Black. 6
- Schalkoff, R. J. (1990). *Artificial intelligence: an engineering approach*. McGraw-Hill New York. 11
- Sedatu, C. (2018). Inegi (2018). *Delimitación de las zonas metropolitanas de México*. 64, 69, 73
- Shi, Y., Bamler, R., Wang, Y., and Zhu, X. X. (2020). Sar tomography at the limit: Building height reconstruction using only 3-5 tandem-x bistatic interferograms. *arXiv preprint arXiv:2003.07803*. 87
- Shim, J.-H., Park, S., and Park, E.-J. (2004). Public space planning of mixed use highrise buildings focusing on the use and impact of deck structure in an urban development in seoul. *Council of Tall Buildings and Urban Habitat*, 13(2004):764–771. 26
- Silva, E. A. (2004). The DNA of our regions: artificial intelligence in regional planning. *Futures*, 36(10):1077–1094. 1
- Singh, A. K., Kumar, B., Singh, S. K., Ghrera, S., and Mohan, A. (2018). Multiple watermarking technique for securing online social network contents using back propagation neural network. *Future Generation Computer Systems*, 86:926–939. 45
- Stanton-Chapman, T. L. and Chapman, D. A. (2006). Using GIS to investigate the role of recreation and leisure activities in the prevention of emotional and behavioral disorders. *International Review of Research in Mental Retardation*, 33:191–211. 7
- Statistics of Tokyo, T. (2016). Tokyo statistical yearbook (in English). Obtenido de: [www.toukei.metro.tokyo.lg.jp/tnenkan/tn-eindex.htm](http://www.toukei.metro.tokyo.lg.jp/tnenkan/tn-eindex.htm). Consultado el 13 de Abril de 2021. 81
- CTBUH (2020). CTBUH Height criteria. Obtenido de: <https://www.ctbuh.org/resource/height>. Consultado el 16 de Junio de 2020. 66
- EASYFIT (2020). Easyfit. Obtenido de: <https://www.scientec.com.mx/easyfit/>. Consultado el 10 de Noviembre de 2020. 57
- ESRI (1998). ESRI Shapefile Technical Description. <https://www.esri.com/library/whitepapers/pdfs/shapefile.pdf>. Consultado el 06 de Enero de 2020. 9
- ESRI (2016a). Fundamentals of panchromatic sharpening. <https://desktop.arcgis.com/es/arcmap/10.3/manage-data/raster-and-images/fundamentals-of-panchromatic-sharpening.htm>. Consultado el 21 de Febrero de 2020. 34

- ESRI (2016b). ¿qué son los datos ráster? <https://desktop.arcgis.com/es/arcmap/10.3/manage-data/raster-and-images/what-is-raster-data.htm>. Consultado el 08 de Enero de 2020. VIII, 7, 8
- ESRI (2019). Plataforma de representación cartográfica SIG basada en la nube. <https://www.esri.com/es-es/arcgis/products/arcgis-online/overview>. Consultado el 13 de Febrero de 2020. 7
- INEC (1978). Glosario de términos sobre asentamientos humanos. [https://www.inecc.gob.mx/repositorio/ae/ae\\_005797.pdf](https://www.inecc.gob.mx/repositorio/ae/ae_005797.pdf). Consultado el 04 de Diciembre de 2019. 9
- INEGI (2015). Encuesta Intersensal. Obtenido de: [http://internet.contenidos.inegi.org.mx/contenidos/productos/prod\\_serv/contenidos/espanol/bvinegi/productos/nueva\\_estruc/promo/eic\\_2015\\_presentacion.pdf](http://internet.contenidos.inegi.org.mx/contenidos/productos/prod_serv/contenidos/espanol/bvinegi/productos/nueva_estruc/promo/eic_2015_presentacion.pdf). Consultado el 12 de Septiembre de 2019. 37, 64, 69, 71, 73, 74, 76, 77, 81
- INEGI (2020a). Cartografía censal. Obtenido de: [https://www.inegi.org.mx/contenidos/temas/mapas/mg/metadatos/manual\\_cartografia\\_censal.pdf](https://www.inegi.org.mx/contenidos/temas/mapas/mg/metadatos/manual_cartografia_censal.pdf). Consultado el 15 de Noviembre de 2020. 52
- INEGI (2020b). Edafología. Obtenido de: <https://www.inegi.org.mx/temas/edafologia/>. Consultado el 07 de Noviembre de 2020. 58
- INEGI (2020c). Marco Geoestadístico. Obtenido de: <https://www.inegi.org.mx/temas/mg/>. Consultado el 15 de Noviembre de 2020. 52, 60
- Metropolitan Government, T. (2019). Tokyo Metropolitan Government's Annual Report on Architectural Statistics 2018. Obtenido de: <https://www.metro.tokyo.lg.jp/ENGLISH/ABOUT/APPENDIX/appendix02.htm>. Consultado el 26 de Abril de 2021. x, 84
- Metropolitan Library, T. (2021). History of Tokyo. Obtenido de: <https://www.library.metro.tokyo.lg.jp/english/>. Consultado el 13 de Abril de 2021. 81
- Nacional de México, B. (2018). Índice de Ciudades Sostenibles. Obtenido de: [https://indexdecidadesostenibles2018.lnpp.cide.edu/resources/Informaci\unhbox\voidb\group\let\unhbox\voidb\setbox\@tempboxa\hbox{o\global\mathchardef\accent@spacefactor\spacefactor}\accent19o\egroup\spacefactor\accent@spacefactor\futurelet\@let@token\protect\penalty\@M\hskip\z@skipn\\_por\\_zona\\_metropolitana.pdf](https://indexdecidadesostenibles2018.lnpp.cide.edu/resources/Informaci\unhbox\voidb\group\let\unhbox\voidb\setbox\@tempboxa\hbox{o\global\mathchardef\accent@spacefactor\spacefactor}\accent19o\egroup\spacefactor\accent@spacefactor\futurelet\@let@token\protect\penalty\@M\hskip\z@skipn_por_zona_metropolitana.pdf). Consultado el 27 de Junio de 2020. 69, 74
- NASA (2018). Landsat 8. Obtenido de: [https://arset.gsfc.nasa.gov/sites/default/files/land/webinars/Advanced\\_](https://arset.gsfc.nasa.gov/sites/default/files/land/webinars/Advanced_). Consultado el 06 de Marzo de 2020.
- ONU (2018). Las ciudades seguirán creciendo, sobre todo en los países en desarrollo, ONU. Obtenido de: <https://www.un.org/development/desa/es/news/population/2018-world-urbanization-prospects.html>. Consultado el 13 de Septiembre de 2019. 2
- QGIS (2018). Descubre QGIS. <https://www.qgis.org/es/site/about/index.html{#}>. Consultado el 13 de Febrero de 2020. 7
- QGIS (2019). La herramienta vectorial a raster. [https://docs.qgis.org/2.18/es/docs/training\\_manual/complete\\_analysis/raster\\_to\\_vector.html](https://docs.qgis.org/2.18/es/docs/training_manual/complete_analysis/raster_to_vector.html). Consultado el 28 de Mayo de 2020. 36
- SCIPY (2020). Scipy. Obtenido de: <https://www.scipy.org/scipylib/index.html>. Consultado el 10 de Noviembre de 2020. 56

- SEMARNAT (2010). Suelos de México. Obtenido de: [https://apps1.semarnat.gob.mx:8443/dgeia/informe\\_12/pdf/Cap3\\_suelos.pdf](https://apps1.semarnat.gob.mx:8443/dgeia/informe_12/pdf/Cap3_suelos.pdf). Consultado el 07 de Noviembre de 2020. 58
- SIMBAD (2020). Sistema Estatal y Municipal de Bases de Datos. Obtenido de: <https://sc.inegi.org.mx/cobdem/>. Consultado el 20 de Mayo de 2020. 37
- USGS (2020). Earthexplorer. Repositorio online: <https://earthexplorer.usgs.gov>. 32
- Thakuriah, P. V., Tilahun, N. Y., and Zellner, M. (2017). Big data and urban informatics: innovations and challenges to urban planning and knowledge discovery. In *Seeing cities through big data*, pages 11–45. Springer. 7
- Tolber, W. (1970). A computer model simulation of urban growth in the Detroit region. *Economic Geography*, 46(2):234–240. 55, 60
- Torres, E. J., Quintana, F. L. G., and Huertas, M. R. (2019). Local Linear Regression Model implemented in GIS. In *Proceedings of the International Conference on Scientific Computing (CSC)*, pages 151–157. The Steering Committee of The World Congress in Computer Science. 1, 4
- Tranfield, D., Denyer, D., and Smart, P. (2003). Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *British journal of management*, 14(3):207–222. 29
- Valle-Cruz, D., Gil-García, J. R., and Fernández-Cortez, V. (2020). Towards Smarter Public Budgeting? Understanding the Potential of Artificial Intelligence Techniques to Support Decision Making in Government. In *The 21st Annual International Conference on Digital Government Research*, pages 232–242. 45
- van Oort, F. (2017). *Urban Growth and Innovation: Spatially Bounded Externalities in the Netherlands*. Taylor & Francis. 28
- VoPham, T., Hart, J. E., Laden, F., and Chiang, Y.-Y. (2018). Emerging trends in geospatial artificial intelligence (geoai): potential applications for environmental epidemiology. *Environmental Health*, 17(1):1–6. 3, 22
- Voženilek, V. (2009). Artificial intelligence and GIS: mutual meeting and passing. In *2009 International Conference on Intelligent Networking and Collaborative Systems*, pages 279–284. IEEE. 11
- Wahyudi, A. and Liu, Y. (2016). Cellular automata for urban growth modelling. *International Review for Spatial Planning and Sustainable Development*, 4(2):60–75. 11, 23
- Wang, F. (1994). The use of artificial neural networks in a geographical information system for agricultural land-suitability assessment. *Environment and planning A*, 26(2):265–284. 45
- Wang, L., Zeng, Y., and Chen, T. (2015). Back propagation neural network with adaptive differential evolution algorithm for time series forecasting. *Expert Systems with Applications*, 42(2):855–863. 45
- White, M. J. (1983). The measurement of spatial segregation. *American journal of sociology*, 88(5):1008–1018. 55
- Wilson, E. H., Hurd, J. D., Civco, D. L., Prisloe, M. P., and Arnold, C. (2003). Development of a geospatial model to quantify, describe and map urban growth. *Remote sensing of environment*, 86(3):275–285. VIII, 9, 10

- Wolfram, S. (1983). Statistical mechanics of cellular automata. *Reviews of modern physics*, 55(3):601. [ix](#), [19](#), [49](#)
- Wolfram, S. (2018). *Cellular automata and complexity: collected papers*. CRC Press. [xi](#), [19](#), [20](#), [47](#), [52](#)
- Wong, K. G. (2004). Vertical cities as a solution for land scarcity: the tallest public housing development in singapore. *Urban Design International*, 9(1):17–30. [25](#), [26](#)
- Wu, N. and Silva, E. A. (2010). Artificial intelligence solutions for urban land dynamics: a review. *Journal of Planning Literature*, 24(3):246–265. [1](#)
- Xiao, L., Zhang, G., Zhu, Y., and Lin, T. (2017). Promoting public participation in household waste management: A survey based method and case study in Xiamen city, China. *Journal of cleaner production*, 144:313–322. [3](#)
- Xu, C., Liu, M., Zhang, C., An, S., Yu, W., and Chen, J. M. (2007). The spatiotemporal dynamics of rapid urban growth in the Nanjing metropolitan region of China. *Landscape ecology*, 22(6):925–937. [9](#), [10](#)
- Yuan, D. and Elvidge, C. D. (1996). Comparison of relative radiometric normalization techniques. *ISPRS Journal of Photogrammetry and Remote Sensing*, 51(3):117–126. [33](#)
- Zafra, X. (2019). Inmobiliare Latam. *Inmobiliare*, 112:1–190. [77](#)
- Zafra, X. (2021). Inmobiliare Latam. *Inmobiliare*, 123:1–190. [73](#)
- Zambon, I., Colantoni, A., and Salvati, L. (2019). Horizontal vs vertical growth: Understanding latent patterns of urban expansion in large metropolitan regions. *Science of The Total Environment*, 654:778–785. [11](#), [27](#), [87](#)
- Zeng, Y.-R., Zeng, Y., Choi, B., and Wang, L. (2017). Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network. *Energy*, 127:381–396. [45](#)
- Zhang, W., Li, W., Zhang, C., Hanink, D. M., Liu, Y., and Zhai, R. (2018). Analyzing horizontal and vertical urban expansions in three East Asian megacities with the SS-coMCRF model. *Landscape and urban planning*, 177:114–127. [10](#), [27](#), [39](#), [81](#), [87](#)
- Zhang, W., Li, W., Zhang, C., and Ouimet, W. B. (2017). Detecting horizontal and vertical urban growth from medium resolution imagery and its relationships with major socioeconomic factors. *International Journal of Remote Sensing*, 38(12). [2](#), [4](#), [10](#), [11](#), [22](#), [25](#), [27](#), [87](#)
- Zhao, C., Jensen, J., and Zhan, B. (2017). A comparison of urban growth and their influencing factors of two border cities: Laredo in the US and Nuevo Laredo in Mexico. *Applied geography*, 79:223–234. [21](#), [23](#)