

Probabilidad de crecimiento de la mancha urbana de Toluca con autómatas celulares

Growth Probability of the Toluca Urban Spot with Cellular Automata

Eduardo Jiménez López*

Universidad Autónoma del Estado de México, México

ejimenezlopez333@gmail.com

 <http://orcid.org/0000-0002-1883-3890>

Recepción: 5 de julio de 2023

Aprobación: 6 de noviembre de 2023



Edel Gilberto Cadena Vargas

Universidad Autónoma del Estado de México, México

edelcadena@yahoo.com.mx

 <http://orcid.org/0000-0002-3131-9597>

RESUMEN

Se busca unir autómatas celulares con filtro inverso a una técnica llamada *regresión geográficamente ponderada*. Esta técnica matemática determina “potenciales de transición espacialmente diferenciados”, un insumo que se adhiere al modelo de autómatas celulares. Identifica pesos o influencia de los factores clave que inciden en la expansión de la ciudad en escala de pixel en imágenes satelitales procesadas. Se encuentran reglas de vecindad más realistas que registran un buen nivel de bondad de ajuste a la simulación de la expansión de la mancha urbana. Todo este modelo de expansión de la mancha urbana es aplicado al área metropolitana de Toluca.

PALABRAS CLAVE: autómata celular, filtro inverso, regresión geográficamente ponderada, área metropolitana de Toluca.

ABSTRACT

This work seeks to join Inverse Filter Cellular Automata to a technique called Geographically Weighted Regression. This mathematical technique determines “spatially differentiated transition potentials”, which is an input that adheres to the cellular automata model. Determines weights or influence of the key factors that affect the expansion of the city at pixel scale in processed satellite images. More realistic neighborhood rules are found that register a good level of goodness of fit to the simulation of the expansion of the urban sprawl. All this model of expansion of the urban sprawl is applied to the metropolitan area of Toluca.

KEYWORDS: cellular automaton, inverse filter, geographically weighted regression, metropolitan area of Toluca.

INTRODUCCIÓN

Existen factores que afectan la expansión urbana y tienen un impacto diferenciado en el espacio urbano. Por tanto, el potencial de transición cambia en cada territorio en la ciudad en estudio. A menudo, los factores clave de la expansión urbana se identifican heurísticamente. En tal sentido, este artículo trata de avanzar e identificar matemáticamente los factores clave de la expansión urbana del Área Metropolitana de Toluca (AMT) y sus efectos espacialmente diferenciados. Para lograrlo se aplicará el método de regresión geográficamente ponderada por sus siglas en inglés). El resultado de este análisis, para construir potenciales de transición espacialmente diferenciados que se unen a autómatas celulares (AC), es elaborar un modelo de proyección de la mancha urbana. Además, se evalúa la bondad de ajuste del modelo que incorpora potenciales de transición variables en el espacio.

La expansión urbana es el resultado de la participación de factores fundamentales como el crecimiento de la población y de la economía (Seto *et al.*, 2012). Determinar cuáles son los factores clave o impulsores de la expansión es un requisito previo para la simulación de escenarios del crecimiento urbano futuro, pero la selección de factores

*AUTOR PARA CORRESPONDENCIA

ejimenezlopez333@gmail.com

en muchos estudios actuales es subjetiva (Zhang *et al.*, 2018a). Las variables utilizadas en muchos de los modelos de AC son sobre todo variables de proximidad como la distancias a los centros de las ciudades, a la infraestructura, a carreteras (Feng *et al.*, 2018). Además, se aplican otras variables como las socioeconómicas, la distribución de la población y físicas, como elevación y pendiente (Li *et al.*, 2018). La pregunta fundamental en este contexto es la siguiente: ¿Cuáles son los factores clave que verdaderamente aportan en el crecimiento de la ciudad?

Para responder a esta pregunta aplicaremos la regresión geográficamente ponderada (GWR). Esta técnica evalúa modelos locales de variables en proceso que trata de comprender o predecir ajustando una ecuación de regresión lineal para todos los datos generados por el análisis que se estudia. La regresión geográficamente ponderada GWR es una técnica con ecuaciones individuales que incorpora variables dependientes y explicativas de los datos que están dentro de la vecindad en el destino. La forma de las vecindades que se analizan se basa en los parámetros de vecindad cercana (ArcGis, 2022).

Entre varios métodos estadísticos locales, GWR tiene la capacidad para explorar relaciones no estacionarias entre variables dependientes y explicativas (Brunsdon *et al.* 1996; Pellegrini y Fotheringham, 2002). Estudios de GWR que se suman a modelos espaciales integran las relaciones empíricas entre el uso de la tierra, tipos de cobertura y los factores impulsores bajo la premisa de que no se estacionan en el espacial (Wang y Stephenson 2018). Cuando estos estudios se unen al AC para identificar la variación espacial de relaciones entre la expansión urbana y sus factores impulsores, los resultados muestran que las uniones de las técnicas ajustan mejor la expansión futura simulada que se adhiere a la heterogeneidad espacial en la predicción de la expansión de la mancha urbana (Mirbagheri y Alimohammadi, 2017; Feng y Tong, 2018; Mayfield *et al.*, 2018; Park *et al.*, 2018; Gao *et al.* 2020).

En la práctica, las correlaciones fijas entre las variables explicativas y la expansión de la mancha urbana no pueden reflejar la variación espacial de las normas de transición a lo largo del área de estudio (Shu *et al.* 2017). Se ha demostrado que las relaciones entre los factores impulsores y la expansión de las ciudades varía dependiendo de la ciudad en estudio o lugar donde se desea analizar (Wang *et al.* 2011; Du *et al.* 2014; Maimaitijiang *et al.* 2015). La autocorrelación espacial de los factores determinantes, como el cambio de uso del suelo, da como resultado reglas de transición de cobertura/vecindad que varían espacialmente. Comprender las tendencias que presentan la expansión de la mancha urbana pasadas y simular el panorama futuro permiten a los tomadores de decisiones formular políticas apropiadas para la gestión sostenible del desarrollo (Liu *et al.*, 2020).

Se han desarrollado diferentes modelos de crecimiento urbano para comprender y modelar los procesos de expansión de la mancha urbana (Batty 2012; Aburas *et al.*, 2016; Gounaridis *et al.*, 2019). Los modelos con AC han demostrado su gran potencial para representar y simular la complejidad del proceso de urbanización (Dietzel y Clarke 2007; Aburas *et al.*, 2016; Berberoglu *et al.*, 2016). Los AC capturan la dinámica del crecimiento urbano con reglas locales simples que influyen en el estado de células o celda en un tiempo discreto. Sus principales ventajas son su sencillez, transparencia y potentes capacidades para ser manejado con sistemas de información geográfica (SIG) (Clarke *et al.*; 1997; Leao *et al.*, 2004; Wu *et al.*, 2010; Aburas *et al.*, 2016; Mustafa *et al.*, 2018; Gounaridis *et al.*, 2019).

La alta flexibilidad de modelos con AC permite el acoplamiento con otros modelos para mejorar las capacidades de simulación en aplicaciones específicas (Aburas *et al.*, 2016). Estos incluyen, por ejemplo, la integración con redes neuronales artificiales y aprendizaje profundo para encontrar reglas de transición (Li y Yeh, 2002; Almeida *et al.*, 2008; Mustafa *et al.*, 2018; Liang *et al.*, 2018; Gounaridis *et al.*, 2019). El acoplar modelos como las cadenas de Markov que dan una proyección en el tiempo discreto (Kamusoko *et al.*, 2009, Jiménez López, 2019; Mohamed y Worku, 2020), modelos socioeconómicos (Wu *et al.*, 2010), modelos analíticos de proceso jerárquico (Aburas *et al.*, 2017; Martellozzo *et al.*, 2018), evaluación multicriterio (Mahiny & Clarke, 2012), regresión logística (LR) (Ozdemir, 2011; Jafari *et al.*, 2016), máquina de soporte vectorial (Yang *et al.*, 2008; Rienow y Goetzke, 2015), bosques aleatorios (Gounaridis *et al.*, 2019), lógica difusa (Liu *et al.*, 2010; Ntinis *et al.*, 2017) y otras muchas técnicas que están probando su valor en mostrar qué factores intervienen en la expansión de la mancha urbana, fortalece el planteamiento de escenarios para estudiar la ciudad.

El artículo se conforma como sigue: la sección 1 contiene la información de partida, la metodología desarrollada, mostrando el análisis exploratorio de datos, en la técnica GWR las variables independientes y dependientes, la calibración de AC. Se muestra la evaluación del modelo propuesto mediante la comparación de los resultados y la aplicación del filtro inverso para encontrar la mejor regla de vecindad en el AC. En la sección 2 se exponen los resultados obtenidos y, por último, en la sección 3, se presentan las conclusiones.

1. MATERIALES Y TÉCNICAS

La figura 1 muestra el flujo general de este trabajo. En este estudio la técnica de GWR que se acopla con los AC incorpora factores que influyen en el crecimiento de la mancha urbana y se obtiene un mapa de probabilidad de transición, que hace hincapié en la definición de las reglas de transición y el incremento de la precisión en las simulaciones para mejorar modelos de simulación del crecimiento urbano basados en AC (Mirbagheri y Alimohammadi, 2017).

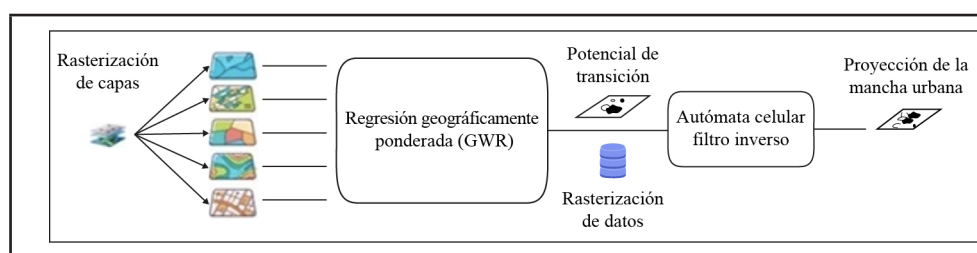


FIGURA 1

Diagrama de flujo del modelo de crecimiento de la mancha urbana

Fuente: elaboración propia.

Para probar el rendimiento del uso de GWR-AC usamos métricas como el índice de Kappa de Cohen, el índice de Jaccard, la dimensión fractal y la entropía de Shannon. Estos cuatro índices estiman las similitudes globales y locales de las proyecciones de cada regla de AC para encontrar cuál se acerca más a la imagen real (es una etapa de entrenamiento del modelo). Los índices entran en juego al mismo tiempo en el filtro inverso, lo cual reduce el tiempo de estimación o procesamiento en la simulación. Para más detalle acerca del filtro inverso, consúltese Jiménez-López (2022).

Como área de estudio se ha elegido la ciudad de Toluca, capital del Estado de México, ubicada en el centro de México. En el periodo 2003-2017 aumentó de 834 399 a 1 338 126 habitantes (INEGI, 2021). Para el desarrollo de esta investigación, se utilizan imágenes satelitales obtenidas del satélite Landsat 8. Estas imágenes contienen bandas espectrales, imágenes que capturan la energía reflejada en un rango electromagnético. Se emplearon las bandas 4, 6, 7 y 9. Al unir estas bandas espectrales dan como resultado la mancha urbana en los colores primarios. Las imágenes de entrada al AC son el resultado (Jardón *et al.*, 2018).

1. 1. Regresión geográficamente ponderada (GWR)

El análisis de la expansión urbana es un desarrollo espacio-temporal que muestra los datos destacados de localización de la población y sus actividades. GWR es un modelo ajustado al espacio con el que es posible observar las variaciones en el espacio de los factores que influyen en el crecimiento-expansión de la mancha urbana y saber dónde ocurren los efectos de la variable independiente sobre la dependiente. Se obtiene información precisa acerca de los factores explicativos del crecimiento de la ciudad en estudio (Molinero-Parejo *et al.*, 2021).

El componente espacial de los datos de acuerdo con las coordenadas geográficas permite que el análisis se lleve a cabo en un nivel local con mayor detalle. Asimismo, conocemos las variables que tienen un mayor peso explicativo sobre la variable dependiente. GWR presenta menos errores de estimación, por lo que se puede determinar el

grado de dependencia espacial del modelo y generar aglomeraciones de localidades, básico para nuevos modelos espaciales de simulación urbana (Gutiérrez-Puebla *et al.*, 2012; Guanglong *et al.*, 2017).

La técnica de GWR determina el factor con mayor importancia a través del ajuste de la ecuación de regresión en cada entidad del espacio. Se construyen ecuaciones individuales con las variables dependiente e independientes para un número determinado de vecinos en la localidad. Se elige entre tres tipos de modelo: *a*) continuo, *b*) binario y *c*) de recuento. La elección del modelo dependerá de cómo se mide la variable dependiente y de su rango de valores.

Se opta por el modelo continuo cuando hay un rango amplio de valores de la variable dependiente, cuyos valores tengan una distribución normal, lo que implica que la mayoría de los valores se concentran en el valor medio y pocos valores se alejan del valor medio. Cuando los valores de la variable dependiente no se distribuyen de manera normal, es recomendable elegir un modelo binario, que la codifique de la siguiente forma: 1 para los valores superiores a la media y 0 para los valores inferiores a la media, o bien se pueden clasificar por la presencia o ausencia de una variable o por el éxito o el fracaso, entre otras opciones que permiten codificar las variables en 1 o 0.

Finalmente, se recurre al modelo de recuento para variables dependientes discretas y que representan el número de ocurrencias de un evento. Este modelo implica que la media y la varianza de la variable dependiente son iguales y no hay valores negativos o con decimales para la variable dependiente (Stewart Fotheringham y Park, 2018).

El objetivo principal de la GWR es tener un medio para modelar datos a través de métodos de regresión estándar, pero donde se incluyan descripciones de las variaciones espaciales en la relación que se busca determinar y una de sus utilidades principales para buscar desviaciones localizadas entre las tendencias globales (Harris *et al.*, 2010).

El método GWR está basado en una regresión lineal mediante la cual se determina la relación entre una variable independiente (causa) y una variable dependiente (efecto), pero se añade el factor espacial (Harris *et al.*, 2010).

A través del GWR se establece una o más variables independientes que se cree influyen en el comportamiento de la variable dependiente; a partir del modelo que se proponga se especificará el tipo de relación (positiva o negativa) (Stewart Fotheringham y Park, 2018).

El modelo GWR genera ecuaciones de regresión separadas para cada una de las observaciones. Al respecto, cada una de las ecuaciones se calibra a partir de un peso o ponderación diferente de las observaciones contenidas en cada conjunto de datos (Mennis, 2006).

Un aspecto muy importante de la GWR es el cálculo de la matriz espacial de pesos, la cual asume la existencia de correlación espacial y hace uso de una función Kernel, donde da mayor peso a las localizaciones cercanas en el espacio antes que a las más alejadas. Con esto se calcula el ancho de banda y se establece el número óptimo de vecinos más próximos a partir de la distancia de proximidad (adaptativa o fija). En el ancho de banda fijo cuenta una distancia fija a partir de cada punto, mientras que el ancho de banda adaptativa adhiere vecinos más próximos (Stewart Fotheringham *et al.*, 2002).

Es posible emplear dos tipos de Kernel: *a*) el fijo con un mismo ancho de banda para cada una de las observaciones del modelo y *b*) adaptativo con anchos de banda diferentes para cada observación dependiendo de la densidad de los puntos. El más empleado es el segundo para así tener anchos de banda más amplios en regiones con muchos datos y más estrechos en regiones donde la densidad de puntos es menor; esto evita el sesgo de los Kernels fijos al asignar un ancho de banda fijo que no considera la densidad de los puntos (Duque *et al.*, 2011).

Para calcular la influencia de la vecindad se aplica la función gaussiana con la que se reducen las ponderaciones de los pesos conforme aumentan las distancias (Duque *et al.*, 2011; Hernández-Hernández *et al.*, 2018). La máxima ponderación es 1, que disminuye conforme aumenta la distancia entre el punto observado y el calibrado (Gollini *et al.*, 2013; Lu *et al.*, 2017).

Se asume que las observaciones que están cerca unas de otras tienen mayor influencia entre sus parámetros estimados que aquellas más lejanas. El peso asignado a cada observación se basa en la función de disminución de distancia centrado en la observación; esta función se modifica mediante el ajuste de ancho de banda al punto donde el peso se acerca más rápido al 0, y el ancho de banda el analista lo elige de forma manual o se optimiza mediante un algoritmo que busque minimizar el criterio de validación cruzada (Mennis, 2006).

1. 2. Autómatas celulares

Los autómatas celulares son sistemas fascinantes, puesto que tienen estructuras y dinámicas sencillas, pero capaces de simular procesos muy complejos (Zhang *et al.*, 2018b). Se definen por cuatro elementos: d el espacio n -dimensional, S el conjunto de estados, H el espacio de vecindad y δ las reglas de transición (Wolfram, 2018).

El *espacio n -dimensional* se define como el objeto delimitado en el espacio con longitud fija. Es decir, el rango de valores es localizado por cada uno de los puntos de las longitudes, por ejemplo ancho, largo y la altura. Hay más dimensiones, por lo que también se considera un espacio con cualquier letra para indicar múltiples dimensiones, usualmente la letra n (Sági, 2019).

Se analizan mapas de dos dimensiones: largo-ancho o longitud-latitud, divididos en una rejilla de células que no se superponen, mencionado como $n = 2$. La célula (rejilla) toma un valor de pixel de la imagen, que en nuestro caso tiene una resolución del terreno de $15 \times 15 \text{ m}^2$. En el proceso de expansión urbana, los estados considerados son los espacios construidos y no construidos. Una propiedad de los AC es que manejan solo dos valores: 0 y 1. A los espacios o pixeles construidos se le asigna un valor de 1 y a los pixeles no-construidos se les asigna un valor de 0 (Cao *et al.*, 2020). El mapa resultante de 1 y 0 (llamado *mapa binario*) representa la ciudad en estudio conformada por suelo construido y no-construido.

El espacio de vecindad es el número de vecinos respecto a una célula central. Los vecinos son células ubicadas a la izquierda y derecha de cada pixel. Los vecinos que colindan con cada pixel forman una vecindad. En nuestro caso las vecindades siempre son de tres pixeles: *a*) uno central, *b*) uno que colinda a la izquierda y *c*) otro que colinda a la derecha (Grün, 2020).

La transición se refiere al paso de un estado a otro, en nuestro caso de un estado no-construido (valor 0) a un estado construido (valor 1). Las reglas de transición las determina el analista y deben describir la evolución de los procesos bajo estudio; en nuestro caso, la expansión urbana. Es decir, son instrucciones que establecen qué condiciones tienen cumplirse para que un pixel cambie de estado, usualmente de no-construido a construido, pero podría ser al revés (Cao *et al.*, 2016; Newland *et al.*, 2018). Estas condiciones guían el comportamiento de cada pixel: el comportamiento significa si cambia de estado o no (se construye o permanece no-construido). En nuestro caso las reglas de transición para cada pixel se asocian a su estado (valores 0 o 1) y al estado de sus dos pixeles vecinos. En seguida, ejemplo de regla de transición: los pixeles no-construidos (valor 0) que tengan *vecinos* construidos (valores 1) tenderán a construirse (a cambiar de estado: de 0 a 1) más rápido que si sus *vecinos* están no-construidos (valores 0). Cada espacio de vecindad será transformado de acuerdo con las instrucciones, sencillas o complicadas, simples o muy elaboradas, todo depende del objetivo del AC (Mohamed y Worku, 2020).

En los modelados de expansión urbana, las reglas de transición se asocian con el cambio de uso del suelo y de factores que impulsan o frenan el crecimiento de la ciudad. Todo esto hace posible a los AC generar escenarios alternativos de la expansión urbana (Feng y Tong, 2020).

Este trabajo aplica una técnica para identificar la regla de transición que mejor replica la realidad observada: filtro inverso. Esta técnica incorpora indicadores de bondad de ajuste tratando de encontrar la similitud entre pixeles mostrando la regla de transición, o también llamada *regla de vecindad*, que mejor ajuste entre la expansión observada de la ciudad y la generada por cada modelo (Jiménez-López, 2022).

El filtro es desarrollado como una herramienta e incorporada al GIS a partir del paquete PyQGIS y el lenguaje de programación Python; para ver más detalles del filtro inverso consúltese Jiménez-López (2022). Con esta herramienta se disminuye el tiempo de procesamiento computacional requerido para encontrar la mejor regla de transición en el AC. Este artículo contribuye a la planificación urbana de la ciudad de estudio, ya que normaliza métricas que impactan el crecimiento urbano, además de permitir la creación de futuras aplicaciones sobre ambientes SIG.

2. RESULTADOS

El centro de la mancha urbana de Toluca es la zona más densa y en términos de concentración de población es la zona clave para el funcionamiento de Toluca, como sucede en las grandes ciudades. Alrededor de la zona centro, se localizan espacios ocupados y espacios vacíos que se unen a lo largo de la mancha urbana y es una oportunidad de nuevas construcciones. Una característica muy común de las ciudades es que en la periferia existe ocupación del territorio dispersa, y son las zonas con mayor expansión urbana (Jiménez López, 2019).

El modelo propuesto en este artículo considera restricciones a la expansión urbana. Se encuentran numerosas células que no pueden ser espacio de expansión urbana: espacios ya ocupados, como espacios públicos (vialidades, carreteras, plazas y parques), infraestructura de movilidad de la ciudad, como el aeropuerto y tren suburbano; zonas protegidas, como parques nacionales Parque Estatal Sierra Morelos y el Nevado de Toluca. Esto garantiza que la ciudad solo crecerá en aquellas células donde exista suelo vacante sin restricciones.

En la parte de calibrar el modelo, se corre el modelo donde se une los AC, la regresión geográficamente ponderada y el filtro inverso para que con los datos de 2010 se haga una simulación de 2020 (mancha urbana proyectada) y se compara con el mapa de 2020 real. Todo esto se realiza con las 256 reglas de vecindad que se propone al tener dos estados (0 y 1), tres bits que realiza un conteo con sus ocho combinaciones, expresadas en un factor 2^8 , como el que se usa en este trabajo (véase Garrocho *et al.*, 2020).

De entre las variables seleccionadas como las más importantes, se encuentran la distancia a pendientes elevadas, distancia a vías de comunicación, distancia a áreas naturales protegidas, distancia a subcentros de empleo y distancia a las zonas donde más se concentra la población (densidad de población). En este sentido, se observa una gran correlación entre las variables seleccionadas (dos o más variables). La distancia a vías de comunicación, la distancia a subcentros de empleo y distancias a concentración de la población presentan un valor de correlación de 0.89. El resultado obtenido se debe a que se hizo en múltiples corridas tratando de relacionar diferentes factores y en una única relación. El resultado de una vuelta en el modelo (llamada *corrida*) da como resultado un potencial de transición en la zona metropolitana de Toluca (figura 2).




FIGURA 2

Potencial de transición de la ciudad de Toluca con las variables distancias a vías de comunicación y concentración de la población

Fuente: elaboración propia.

Después de encontrar las zonas que más aportan al crecimiento de la mancha urbana, se hace binario el mapa de ciudad y se introduce a la técnica de AC. Se resalta la aportación de una técnica que permite identificar la regla de transición que mejor replica la realidad observada. Este modelo de filtrado incorpora indicadores globales y locales que muestra la coincidencia de píxeles y también la mejor regla de transición que da mayor ajuste entre la expansión real de la ciudad y la generada por los AC-GWR.

Existen zonas en la ciudad donde está presente una tendencia al crecimiento y restricciones de crecimiento que se mantienen constantes en 20 años (figura 3). Se agregan a los AC en zonas donde el potencial de transición es elevado y alienta el crecimiento, además de zonas de restricción que espacializan la expansión. Las zonas de crecimiento son Metepec, Otzolotepec y Xonacatlán, con un crecimiento moderado. Por su parte, Toluca, Zinacantepec y Almoloya de Juárez presentan un crecimiento elevado.

Las zonas con restricciones en el terreno no son perceptibles en medio impreso, esto es, zonas donde no se puede construir. La primera zona restringida está cerca del centro de Toluca, que es el Cerro de la Teresona (figura 3). La pendiente de esta zona es mayor a 30° , circunstancia que hace muy complicado construir, además de que es un parque en la zona metropolitana. La segunda zona restringida es el volcán Nevado de Toluca, que está en la parte inferior izquierda de la figura 3, *a)* y *b)*, catalogado como un parque nacional, donde no se permite la urbanización. La tercera zona restringida esta localizada en el área de Lerma, ya que tiene terrenos destinados a la expansión del Aeropuerto Internacional de Toluca (figura 3 *a)* y *b)*, parte centro derecha de las imágenes.




FIGURA 3
Mapas de la ciudad de Toluca *a)* 2010 y *b)* 2020
Fuente: elaboración propia.

Con el filtro inverso se estiman los indicadores de bondad de ajuste para determinar los mejores valores de los indicadores que miden la similitud de las imágenes. Con este filtrado se encuentra la mejor regla de vecindad, que trata de imitar en mejor forma el crecimiento real. Se observa qué tan efectiva es la técnica en la expansión de la mancha urbana en Toluca en el periodo propuesto. Al respecto, la mejor regla para el año 2020 es la 113.

Una vez hecho un entrenamiento del modelo, realizamos una proyección de la mancha urbana con el mapa real de Toluca en 2010 que genera el mapa en 2020, y así buscar la mayor similitud posible con el mapa real de 2020. La figura 4 muestra la mayor semejanza del crecimiento de la mancha urbana en 2020 con la mejor regla encontrada por el filtro inverso. Para la difusión o expansión se ocupan los valores calculados en una tendencia de crecimiento en los píxeles en la imagen; se toman solo los valores que cambian de 0 a 1 (685 700 píxeles), y los que no cambiaron o permanecieron en 1 (686 808 píxeles): un total de 1 372 508 píxeles que cambiarán en el mapa de 2010.

Con la proyección de Toluca para 2020 con la mejor regla encontrada por el filtro inverso, observamos qué tan eficiente es la distribución de píxeles. Los mejores valores son los siguientes: el valor de Kappa = 0.85, Jaccard = 0.88, entropía de Shannon = 0.93 y dimensión fractal = 1.85.




FIGURA 4
Simulación del crecimiento de Toluca para 2020
Fuente: elaboración propia.

Al conjugar tres técnicas de análisis en el modelo de crecimiento de la mancha urbana, se establece que es muy útil y da muy buenos resultados. La proyección de Toluca para 2030 con la mejor regla encontrada es la 113 (figura 5). En la figura 5 se observa un equilibrio en los valores que cambiaron de 1 a 0 y al inverso; así, se puede decir que en 20 años la velocidad de crecimiento de Toluca sigue en una línea ascendente logarítmica.

En la simulación para 2030 cubre 54 262 hectáreas, con un aumento de 24 275 hectáreas, lo que significa que en 20 años se plantea que la ciudad crezca casi 81% comparado con 2010. Es primordial saber dónde crecerá la ciudad, lo cual se resuelve al encontrar el potencial de transición. Se destacan en este modelo los factores que más aportan al crecimiento de la mancha urbana y también el empleo de la técnica de GWR, que es poco utilizada en este tipo de trabajos.

En la figura 5 se muestran zonas delimitadas por cuadrados de colores que destacan cinco zonas que están en la periferia y donde se detona la expansión. En la periferia al norte de la ciudad observamos Almoloya de Juárez, que es un lugar con muchas tierras agrícolas (cuadro rojo). Zinacantepec, al oeste, cuenta con un gran número de espacios de tierras para construir (cuadro rojo). Lerma, en su caso, que tiene una gran extensión de tierra para construir, cuenta con nuevos asentamientos al alrededor del aeropuerto (cuadro en color amarillo). Metepec, Mexicaltzingo y Calimaya, encontrados al sureste de la mancha urbana (cuadros en verde), muestran un aumento de la mancha urbana debido a que eran considerados como zona agrícolas; en la actualidad ha cambiado este rubro por construcción de muchos asentamientos de nuevos fraccionamientos (Jiménez-López, 2022).

En la figura 6 se muestra una proyección de la mancha urbana para 2030. Esta simulación responde bien al patrón que genera el modelo propuesto en este trabajo. Se utilizan los insumos entrenados para hacer la proyección de 2010 a 2020, con la mejor regla encontrada por el filtro inverso, que se vale de las cuatro métricas de comparación de imágenes propuestas en Jiménez-López (2022). Se puede decir que el área construida en 20 años ha aumentado

de forma logarítmica, ya que el crecimiento de la mancha urbana implica mayor demanda de servicios públicos y alimentos para la población (Garrocho *et al.*, 2020). Por lo anterior, es que se observa un crecimiento logarítmico a un límite que la ciudad pueda soportar.




FIGURA 5
Proyección de Toluca para 2030
Fuente: elaboración propia.




FIGURA 6
Ciudad de Toluca: mapa proyecto a 2030, uso del modelo de AC-GWR
Fuente: elaboración propia.

El modelo propuesto en este trabajo respeta las zonas donde no se puede construir y sus dimensiones son más grandes en comparación con otros equipamientos urbanos: *a)* la primera en el Cerro de la Teresona, en el centro de Toluca, *b)* en la segunda el parque nacional Nevado de Toluca y *c)* la tercera la del aeropuerto en el municipio de Lerma.

La comparación numérica mostró cómo el modelo elaborado de GWR-AC con el Filtro Inverso responde al patrón básico que ocurre en la realidad, con crecimiento más compacto. De esta manera, es posible decir que el crecimiento en la proyección responde a la adición a construcciones ya existentes y que nuevas urbanizaciones aisladas desaparecen por falta de vecindad, bajo potencial de transición o por restricciones de espacio para construir.

CONCLUSIONES

En este artículo se propone y se aplica una técnica innovadora para explorar el crecimiento de la mancha urbana en Toluca: GWR-AC con filtro inverso. Esta técnica de crecimiento- proyección es muy eficiente y reduce el tiempo de procesamiento que demandan los cálculos. El modelo nos ofrece información valiosa y una mejor visión para el análisis en lugar de realizarlo simplemente con el enfoque tradicional de potencial de transición en el crecimiento de la ciudad. Todo el análisis se centra en el crecimiento de la mancha urbana con diferentes factores que aportan o no al crecimiento.

En el modelo de GWR-AC con filtro inverso destaca la unión de factores espacio-temporales, técnica geográfica cuyo principal objetivo es proyectar en mapas el crecimiento de la ciudad. La búsqueda de las variables que alientan el crecimiento se denomina en este trabajo *factor*. La tendencia en las proyecciones de los píxeles ocupados dirige a un análisis espacio temporal, que es lo que se aprovecha para solo agregar el espacio con la mejor regla de vecindad encontrada por AC y el filtro inverso. Con este modelo se genera una proyección de 20 años a partir de los datos y mapas de la ciudad que estén disponibles.

La suma del el sistema de información geográfica con GWR-AC nos lleva de la mano para generar una herramienta de *software* programada en Python. En este aspecto, uno de los objetivos de este tipo de investigación es aplicar y generar una herramienta de interés que se emplee en diferentes áreas del conocimiento y donde el *software* utilizado en la programación es de acceso libre y de bajo costo.

Al comparar mapas y obtener índices se demuestra qué tan eficiente es el modelo. Existe una lucha constante con una variable que es difícil de controlar, la obtención de los mapas para el análisis desde su fuente; todo depende de que tenga las mismas condiciones de captura en la toma, pero esto no se logra fácilmente debido a los cambios climáticos que empeoran las condiciones para que el satélite tome la imagen. Lo anterior puede ser una vertiente de gran interés para el futuro.

Después de tener los resultados generados por el modelo viene una comparación de mapas, mediante técnicas no utilizadas en la investigación cartográfica: la dimensión fractal y la entropía de Shannon, las cuales se adaptaron para capturar la esencia de crecimiento (dimensión fractal) y la correcta dispersión aleatoria utilizada en el modelo. Así pues, agregar un factor aleatorio al modelo es una correcta forma de simular la realidad, ya que la ciudad no crece de una forma determinística o periódica si no que aparecen construcciones en una forma no determinista. Todo lo anterior es una contribución fundamental en este artículo.

Para finalizar, cuando se conjugan sistemas de información geográfica con herramientas o técnicas matemáticas es posible tener un modelo de análisis, supervisión y control en fenómenos que involucran a la ciudad. Como se dijo, este modelo depende de los datos y mapas que tengan las mismas condiciones espaciales, pero en diferente tiempo. Si reunimos todas las condiciones necesarias para el análisis, se logra extraer información muy útil y de gran valor para servidores públicos encargados de las prospectivas de la ciudad o para estudiosos que den alternativas del crecimiento de la ciudad.

REFERENCIAS

- Aburas, M. M., Ho, Y. M., Ramli, M. F., & Ash'aari, Z. H. (2016). The simulation and prediction of spatio-temporal urban growth trends using cellular automata models: A review. *International Journal of Applied Earth Observation and Geoinformation*, 52, 380-389.
- Aburas, M. M., Ho, Y. M., Ramli, M. F., & Ash'aari, Z. H. (2017). Improving the capability of an integrated CA-Markov model to simulate spatio-temporal urban growth trends using an Analytical Hierarchy Process and Frequency Ratio. *International Journal of Applied Earth Observation and Geoinformation*, 59, 65-78.
- Almeida, C. D., Gleriani, J. M., Castejon, E. F., & 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.
- ArcGis (03 de agosto de 2022). *Introducción a las imágenes multiespectrales multidimensionales. Usar datos ráster e imágenes en ArcGIS Pro*. <https://learn.arcgis.com/es/paths/using-raster-data-and-imagery-in-arcgis-pro/>
- Batty, M. (2012). Building a science of cities. *Cities*, 29(1), S9-S16.
- Berberoglu, S., Akin, A., & Clarke, K. C. (2016). Cellular automata modeling approaches to forecast urban growth for adana, Turkey: A comparative approach. *Landscape and Urban Planning*, 153, 11-27.
- Brunsdon, C., Fotheringham, A. S., & Charlton, M. E. (1996). Geographically weighted regression: a method for exploring spatial nonstationarity. *Geographical Analysis*, 28(4), 281-298.
- Cao, M., Bennett, S. J., Shen, Q., & Xu, R. (2016). A bat-inspired approach to define transition rules for a cellular automaton model used to simulate urban expansion. *International Journal of Geographical Information Science*, 30(10), 1961-1979.
- Cao, Y., Zhang, X., Fu, Y., Lu, Z., & Shen, X. (2020). Urban spatial growth modeling using logistic regression and cellular automata: A case study of Hangzhou. *Ecological Indicators*, 113, 106200.
- Clarke, K. C., Hoppen, S., & Gaydos, L. (1997). A self-modifying cellular automaton model of historical urbanization in the San Francisco Bay area. *Environment and planning B: Planning and Design*, 24(2), 247-261.
- Dietzel, C., & Clarke, K. C. (2007). Toward optimal calibration of the SLEUTH land use change model. *Transactions in GIS*, 11(1), 29-45.
- Du, S., Wang, Q., & Guo, L. (2014). Spatially varying relationships between land-cover change and driving factors at multiple sampling scales. *Journal of Environmental Management*, 137, 101-110.
- Duque, J. C., Velásquez, H., & Agudelo, J. (2011). Infraestructura pública y precios de vivienda: una aplicación de regresión geográficamente ponderada en el contexto de precios hedónicos. *Ecos de Economía*, 15(33), 95-122.
- Feng, Y., & Tong, X. (2018). Dynamic land use change simulation using cellular automata with spatially nonstationary transition rules. *GIScience & Remote Sensing*, 55(5), 678-698.
- Feng, Y., & Tong, X. (2020). A new cellular automata framework of urban growth modeling by incorporating statistical and heuristic methods. *International Journal of Geographical Information Science*, 34(1), 74-97.
- Feng, Y., Liu, Y., & Tong, X. (2018). Comparison of metaheuristic cellular automata models: A case study of dynamic land use simulation in the Yangtze River Delta. *Computers, Environment and Urban Systems*, 70, 138-150.

- Gao, C., Feng, Y., Tong, X., Lei, Z., Chen, S., & Zhai, S. (2020). Modeling urban growth using spatially heterogeneous cellular automata models: Comparison of spatial lag, spatial error and GWR. *Computers, Environment and Urban Systems*, 81, 101459.
- Garrocho, C., Jiménez, E., & Chávez-Soto, T. (2020). Expansión de la ciudad: un instrumento de simulación de escenarios para los sectores público y privado. *La situación demográfica de México*, 2(2), 195-219.
- Gollini, I., Lu, B., Charlton, M., Brunsdon, C., & Harris, P. (2013). GWmodel: an R package for exploring spatial heterogeneity using geographically weighted models. *Journal of Statistical Software*, 63(17), 1-50. <https://doi.org/10.18637/jss.v063.i17>
- Gounaridis, D., Chorianopoulos, I., Symeonakis, E., & Koukoulas, S. (2019). A Random Forest-Cellular Automata modelling approach to explore future land use/cover change in Attica (Greece), under different socio-economic realities and scales. *Science of the Total Environment*, 646, 320-335.
- Grün, D. (2020). Revealing dynamics of gene expression variability in cell state space. *Nature Methods*, 17(1), 45-49.
- Guanglong, D., Erqi, X., & Hongqi, Z. (2017). Urban expansion and spatiotemporal relationships with driving factors revealed by geographically weighted logistic regression. *Journal of Resources and Ecology*, 8(3), 277-286.
- Gutiérrez-Puebla, J., García-Palomares, J. C., & Daniel-Cardozo, O. (2012, September). Regresión Geográficamente Ponderada (GWR) y estimación de la demanda de las estaciones del Metro de Madrid. *XV Congreso Nacional de Tecnologías de la Información Geográfica* (pp. 1-13).
- Harris, R., Singleton, A., Grose, D., Brunsdon, C., & Longley, P. (2010). Grid-enabling geographically weighted regression: a case study of participation in higher education in England. *Transactions in GIS*, 14(1), 43-61.
- Hernández-Hernández, V., Pansza, E. M., & Daniel, D. Q. (2018). Geografía del robo a casa habitación en Ciudad Juárez, Chihuahua (2007-2014). *Investigaciones Geográficas*, 96, 1-15. <https://doi.org/10.14350/rig.59545>
- INEGI (Instituto Nacional de Estadística y Geografía). (2021). En el Estado México somos 16 992 418 habitantes: Censo de Población y Vivienda 2020. *Comunicado de prensa Núm. 55/21*, 1-3. Toluca.
- Jafari, M., Majedi, H., Monavari, S. M., Alesheikh, A. A., & Kheirkhah Zarkesh, M. (2016). Dynamic simulation of urban expansion based on cellular automata and logistic regression model: Case study of the Hyrcanian Region of Iran. *Sustainability*, 8(8), 810.
- Jardón, E., Jiménez, E., & Romero, M. (2018, December). *Spatial Markov chains implemented in GIS*. In *2018 International Conference on Computational Science and Computational Intelligence (CSCI)* (pp. 361-367). IEEE.
- Jiménez López, 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.
- Jiménez-López, E. (2022, June). Inverse Filter in the Growth of Urban Sprawl with Cellular Automata Model. In *Complex Systems and Their Applications: Second International Conference (EDIESCA 2021)* (pp. 231-247). Cham: Springer International Publishing.
- Kamusoko, C., Aniya, M., Adi, B., & Manjoro, M. (2009). Rural sustainability under threat in Zimbabwe-simulation of future land use/cover changes in the Bindura district based on the Markov-cellular automata model. *Applied Geography*, 29(3), 435-447.
- Leao, S., Bishop, I., & Evans, D. (2004). Simulating urban growth in a developing nation's region using a cellular automata-based model. *Journal of Urban Planning and Development*, 130(3), 145-158.

- Li, X., & 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.
- Li, G., Sun, S., & Fang, C. (2018). The varying driving forces of urban expansion in China: Insights from a spatial-temporal analysis. *Landscape and Urban Planning*, 174, 63-77.
- Liang, X., Liu, X., Li, D., Zhao, H., & Chen, G. (2018). Urban growth simulation by incorporating planning policies into a CA-based future land-use simulation model. *International Journal of Geographical Information Science*, 32(11), 2294-2316.
- Liu, X., Li, X., Shi, X., Zhang, X., & Chen, Y. (2010). Simulating land-use dynamics under planning policies by integrating artificial immune systems with cellular automata. *International Journal of Geographical Information Science*, 24(5), 783-802.
- Liu, D., Clarke, K. C., & Chen, N. (2020). Integrating spatial nonstationarity into SLEUTH for urban growth modeling: A case study in the Wuhan metropolitan area. *Computers, Environment and Urban Systems*, 84, 101545.
- Lu, B., Brunsdon, C., Charlton, M., & Harris, P. (2017). Geographically weighted regression with parameter-specific distance metrics. *International Journal of Geographical Information Science*, 31(5), 982-998.
- Mahiny, A. S., & Clarke, K. C. (2012). Guiding SLEUTH land-use/land-cover change modeling using multicriteria evaluation: towards dynamic sustainable land-use planning. *Environment and Planning B: Planning and Design*, 39(5), 925-944.
- Maimaitijiang, M., Ghulam, A., Sandoval, J. O., & Maimaitiyiming, M. (2015). Drivers of land cover and land use changes in St. Louis metropolitan area over the past 40 years characterized by remote sensing and census population data. *International Journal of Applied Earth Observation and Geoinformation*, 35, 161-174.
- Martellozzo, F., Amato, F., Murgante, B., & Clarke, K. C. (2018). Modelling the impact of urban growth on agriculture and natural land in Italy to 2030. *Applied Geography*, 91, 156-167.
- Mayfield, H. J., Lowry, J. H., Watson, C. H., Kama, M., Nilles, E. J., & Lau, C. L. (2018). Use of geographically weighted logistic regression to quantify spatial variation in the environmental and sociodemographic drivers of leptospirosis in Fiji: A modelling study. *The Lancet Planetary Health*, 2(5), e223-e232.
- Mennis, J. (2006). Mapping the results of geographically weighted regression. *The Cartographic Journal*, 43(2), 171-179.
- Mirbagheri, B., & Alimohammadi, A. (2017). Improving urban cellular automata performance by integrating global and geographically weighted logistic regression models. *Transactions in GIS*, 21(6), 1280-1297.
- Mohamed, A., & Worku, H. (2020). Simulating urban land use and cover dynamics using cellular automata and Markov chain approach in Addis Ababa and the surrounding. *Urban Climate*, 31, 100545.
- Molinero-Parejo, R., Aguilera-Benavente, F., & Gómez-Delgado, M. (2021). Regresión Logística Geográficamente Ponderada para identificar los factores explicativos de la distribución de usos de suelo en escenarios futuros de crecimiento urbano. *Boletín de la Asociación de Geógrafos Españoles*, 88.
- Mustafa, A., Heppenstall, A., Omrani, H., Saadi, I., Cools, M., & Teller, J. (2018). Modelling built-up expansion and densification with multinomial logistic regression, cellular automata and genetic algorithm. *Computers, Environment and Urban Systems*, 67, 147-156.
- Newland, C. P., Maier, H. R., Zecchin, A. C., Newman, J. P., & Van Delden, H. (2018). Multi-objective optimisation framework for calibration of Cellular Automata land-use models. *Environmental Modelling & Software*, 100, 175-200.

- Ntinas, V. G., Moutafis, B. E., Trunfio, G. A., & Sirakoulis, G. C. (2017). Parallel fuzzy cellular automata for data-driven simulation of wildfire spreading. *Journal of Computational Science*, 21, 469-485.
- Ozdemir, A. (2011). Using a binary logistic regression method and GIS for evaluating and mapping the groundwater spring potential in the Sultan Mountains (Aksehir, Turkey). *Journal of Hydrology*, 405 (1-2), 123-136.
- Park, S., Lee, J. H., & Clarke, K. C. (2018). Capturing the heterogeneity of urban growth in South Korea using a latent class regression model. *Transactions in GIS*, 22(3), 789-805.
- Pellegrini, P. A., & Fotheringham, A. S. (2002). Modelling spatial choice: a review and synthesis in a migration context. *Progress in Human Geography*, 26(4), 487-510.
- Rienow, A., & Goetzke, R. (2015). Supporting SLEUTH-Enhancing a cellular automaton with support vector machines for urban growth modeling. *Computers, Environment and Urban Systems*, 49, 66-81.
- Sági, G. (2019). Almost injective mappings of totally bounded metric spaces into finite dimensional euclidean spaces. *Advances in Pure Mathematics*, 9(06), 555.
- Seto, K. C., Güneralp, B., & Hutyra, L. R. (2012). Global forecasts of urban expansion to 2030 and direct impacts on biodiversity and carbon pools. *Proceedings of the National Academy of Sciences*, 109(40), 16083-16088.
- Shu, B., Bakker, M. M., Zhang, H., Li, Y., Qin, W., & Carsjens, G. J. (2017). Modeling urban expansion by using variable weights logistic cellular automata: a case study of Nanjing, China. *International Journal of Geographical Information Science*, 31(7), 1314-1333.
- Stewart Fotheringham, A., Brunson, C., & Charlton, M. (2002). *Geographically weighted regression: the analysis of spatially varying relationships*. WILEY.
- Stewart Fotheringham, A., & Park, B. (2018). Localized spatiotemporal effects in the determinants of property prices: A case study of Seoul. *Applied Spatial Analysis and Policy*, 11, 581-598. <https://doi.org/10.1007/s12061-017-9232-8>
- Wang, Y., Kockelman, K. M., & Wang, X. (2011). Anticipation of land use change through use of geographically weighted regression models for discrete response. *Transportation Research Record No. 224*.
- Wang, H., & Stephenson, S. R. (2018). Quantifying the impacts of climate change and land use/cover change on runoff in the lower Connecticut River Basin. *Hydrological Processes*, 32(9), 1301-1312.
- Wolfram, S. (2018). *Cellular automata and complexity: collected papers*. CRC Press.
- Wu, D., Liu, J., Wang, S., & Wang, R. (2010). Simulating urban expansion by coupling a stochastic cellular automata model and socioeconomic indicators. *Stochastic Environmental Research and Risk Assessment*, 24(2), 235-245.
- Yang, Q., Li, X., & Shi, X. (2008). Cellular automata for simulating land use changes based on support vector machines. *Computers & Geosciences*, 34(6), 592-602.
- Zhang, W., Li, W., Zhang, C., Hanink, D., Liu, Y., & Zhai, R. (2018a). Analyzing horizontal and vertical urban expansions in three East Asian megacities with the SS-co MCRF model. *Landscape and Urban Planning*, 177, 114-127.
- Zhang, Z., Liu, F., Zhao, X., Wang, X., Shi, L., Xu, J., ... & Liu, B. (2018b). Urban expansion in China based on remote sensing technology: a review. *Chinese Geographical Science*, 28(5), 727-743.



Disponible en: <https://cienciaergosum.uaemex.mx/article/view/21517>

Cómo citar el artículo:

Echeverri Londoño, C. A. & Maya Vasco, G. J. (2025). Probabilidad de crecimiento de la mancha urbana de Toluca con autómatas Celulares. *CIENCIA ergo-sum*, 32. <https://doi.org/10.30878/ces.v32n0a16>

DOI: <https://doi.org/10.30878/ces.v32n0a16>



Licencia Creative Commons Atribución-NoComercial-SinDerivar 4.0 Internacional.

Declaración de autoría (CRediT):

Eduardo Jiménez López: conceptualización, curación de datos, investigación, metodología, administración del proyecto, software, supervisión, validación, visualización y redacción-borrador original.

Edel Gilberto Cadena Vargas: conceptualización, curación de datos, investigación, metodología, administración del proyecto, software, supervisión, validación, redacción-borrador original, redacción-revisión y edición