



Geografía y Sistemas de Información Geográfica (GEOSIG).
Revista digital del Grupo de Estudios sobre Geografía y Análisis Espacial con Sistemas de Información Geográfica (GESIG). Programa de Docencia e Investigación en Sistemas de Información Geográfica (PRODISIG). Universidad Nacional de Luján, Argentina.

<http://www.revistageosig.wixsite.com/geosig> (ISSN 1852-8031)

Luján, Año 10, Número 12, 2018, Sección II: Metodología. pp. 1-26

MODELANDO LA EXPANSIÓN URBANA CON AUTÓMATAS CELULARES: APLICACIÓN DE LA ESTACIÓN DE INTELIGENCIA TERRITORIAL (CHRISTALLER)[®]

Eduardo Jiménez López - Tania Chávez Soto - Carlos Garrocho

El Colegio Mexiquense A.C.

Ex. Hacienda Santa Cruz de los Patos s/n

C.P. 51350 – Zinacantepec – Estado de México, México.

E-mail: ejimenez@cmq.edu.mx; tchavez@cmq.edu.mx; cfgarrocho@gmail.com.

RESUMEN

Este trabajo vincula Sistemas de Información Geográfica (SIG) con software especializado de código abierto desarrollado en El Colegio Mexiquense (la *Estación de Inteligencia Territorial: CHRISTALLER[®]*), para simular la expansión de ciudades mexicanas con Autómatas Celulares (AC) en un entorno experimental en el periodo 2003-2017. Los objetivos del texto son: *i.* Explicar en detalle los modelos de AC, para orientar a los futuros usuarios de CHRISTALLER[®]; *ii.* Mostrar la complejidad de los procesos que puede llevar a cabo CHRISTALLER[®]; y, *iii.* Ilustrar las capacidades de CHRISTALLER[®] con un experimento que devela si los AC deterministas son capaces de simular la expansión de la mancha urbana de tres grandes ciudades mexicanas, con el fin de realizar proyecciones. Mediante un Modelo de AC de CHRISTALLER[®] se identificó la Regla de Transición más precisa de los AC deterministas para simular la expansión urbana de las ciudades bajo experimentación, las métricas de bondad de ajuste entre las imágenes satelitales y los resultados de las simulaciones del Modelo del AC resultaron muy alentadoras y demostró una gran rapidez de procesamiento de información numérica y visual.

Palabras clave: Expansión urbana, Autómatas Celulares, Dimensión Fractal, Índice Kappa de Cohen, Índice de Jaccard.

ABSTRACT

This work links Geographic Information Systems (GIS) with open source software developed at El Colegio Mexiquense (the *Territorial Intelligence Station: CHRISTALLER[®]*), to simulate the expansion of Mexican cities with Cellular Automata Models (CAM) in the period 2003-2017. The objectives of the text are *i.* Explain the

CAM in detail, to guide future CHRISTALLER[®] users; *ii.* Show the complexity and speed of the processes that CHRISTALLER[®] can carry out; and, *iii.* Illustrate the capabilities of CHRISTALLER[®] with an experiment that explores if deterministic CAM are able to simulate the expansion of the urban sprawl of three big Mexican cities, in order to make projections. CHRISTALLER[®] identifies (easily and quickly) the most precise Transition Rule of the deterministic CAM to simulate the urban expansion of the cities under experimentation and the goodness of fit metrics between the satellite images and the results of the models simulations. CHRISTALLER[®] Cellular Automat Models produced very encouraging results and showed great speed in processing numerical and visual information.

Keywords: Urban Expansion, Cellular Automata Models, Fractal Dimension, Cohen's Kappa Index, Jaccard Index.

INTRODUCCIÓN

Ese trabajo es de carácter metodológico y experimental. Se explican en detalle los modelos de Autómatas Celulares (AC) y se explora si son capaces de simular con un grado aceptable de precisión el crecimiento de tres grandes ciudades mexicanas: Querétaro, San Luis Potosí y Toluca, a lo largo de más de una década. Las tres ciudades registran una población entre 2.2 y 3.0 millones de habitantes. Los experimentos gravitan en torno a la *Estación de Inteligencia Territorial: CHRISTALLER[®]*, desarrollada en El Colegio Mexiquense (ver los detalles en Garrocho y Chávez, 2018).

Los AC constituyen un método discreto (i.e. cuantifican valores enteros a intervalos regulares), para modelar la evolución de fenómenos dinámicos, como la expansión de las ciudades en *tiempo y espacio*. Para los AC deterministas de tres bits, que son los que se utilizan en este trabajo, existen 256 Reglas de Transición, o *instrucciones de evolución* de sistemas complejos (Wolfram, 1984). Si se identifican Reglas aceptablemente precisas para modelar la expansión de las ciudades, entonces es posible explorar de manera *condicionada* el crecimiento futuro de la mancha urbana. CHRISTALLER[®] facilita todos los procesos de instrumentación de modelos de AC de una manera amigable.

Entender la expansión de las ciudades implica comprender múltiples singularidades de cada ciudad, lo que resulta muy complicado en la práctica, porque las ciudades son sistemas de alta complejidad. Sin embargo, se puede encontrar un punto de apoyo para el análisis y la planeación de las ciudades si se hacen *simulaciones* con AC (Aguilera, 2002; Gorostiaga, 2010). En este sentido, el módulo de Autómatas Celulares de CHRISTALLER[®] es un laboratorio de simulación urbana. Revisemos algunas de las características claves de los AC para replicar la expansión de las ciudades.

Los AC presentan múltiples componentes o unidades en interacción, lo que los asemeja a las ciudades como sistemas complejos. Sin embargo, registran otras características básicas de un sistema complejo: son dinámicos, registran fuertes conexiones de vecindad espacial y presentan autosimilitud (Wolfram, 1984). La autosimilitud es la presencia de estructuras *espaciotemporales* que siguen patrones que surgen de lo que aparentemente es un caos. Diversos fenómenos urbanos registran autosimilitud. Por ejemplo: el crecimiento y la morfología urbana (Batty y Xie 1996; Couclelis, 1997; Aguilera Benavente, 2006; Rueda y Dewar, 2007; León y Villalobos, 2014; Polidori *et al*, 2015), la dinámica del mercado de bienes raíces (Cavada, 2007), el comportamiento

de la economía regional (Valdivia, 2013), la evolución de la ecología urbana (Padilla *et al*, 2015), los cambios en los usos del suelo (Baxendale y Buzai, 2011; Pérez-Miranda *et al*, 2011; Padilla *et al*, 2015), la distribución espacial de las actividades (Buzai, 2007), entre muchas otras.

Al estudiar las ciudades en tiempo y espacio, y a diferentes escalas *espaciotemporales*, se revela que las formas urbanas a una determinada escala son similares a las formas que surgen en otras escalas. Esta autosemejanza o autosimilaridad, significa que si observamos relaciones formales a través de una serie de escalas espaciales (i.e. ciudad, barrio, manzana) o temporales (i.e. años, quinquenios, décadas), se descubren simetrías (y regularidades), porque estamos observando “*partes de partes*”. No es una simetría de espejo, de derecha e izquierda o de arriba-abajo, sino entre escalas grandes y pequeñas, que denominamos autosimilitud, donde cada parte tiene una estructura espacial similar o igual *al todo* en determinados lapsos de tiempo. Estas estructuras sólo varían en cierta proporción escalar (Couclelis, 1985; White y Engelen, 1993; Batty y Longley, 1994; Benenson y Torrens, 2004; Linarez, 2016).

Los AC pueden ser una herramienta útil para simular y proyectar (i.e. *explorar*) la expansión de las ciudades en tiempo y espacio. Una forma de conocer su utilidad para ciudades particulares, es valorar la precisión de las simulaciones de los AC. Esto se logra utilizando diversas medidas de *bondad de ajuste*. Es decir, utilizando indicadores que midan qué tan parecidos son los resultados del modelo respecto a lo ocurrido en la realidad. En este trabajo se utilizan tres métricas de bondad de ajuste: la Dimensión Fractal, el Índice de Kappa de Cohen y el Índice de Jaccard. Si el modelo replica aceptablemente la realidad, entonces puede utilizarse como un instrumento que genere *alguna información relevante* sobre el futuro de la expansión de la ciudad (Batty y Longley, 1994; Mandelbrot, 1983; Unibazo y Suazo, 2009).

ANTECEDENTES DE LOS AC

Los AC datan de los inicios de la computación digital. Alan Turing y John Von Neumann dedujeron que se podría encontrar un conjunto de reglas o *instrucciones* que al operarse mediante un software podrían simular la evolución de sistemas complejos (Macrae, 1992; Couclelis, 1997; Batty, 2007). En un AC el espacio está representado por una cuadrícula, como la de un tablero de ajedrez, y a cada casquete o cuadro del tablero se le llama *célula*. El tiempo se concibe de manera discreta y, por tanto, transcurre en lapsos uniformes. Por su parte, la vecindad espacial usualmente se refiere a células inmediatamente adyacentes (i.e. adyacencia de primer orden). El *estado* de cada célula se determina por los estados de las células vecinas y por las *Reglas de Transición* o instrucciones que se utilicen para determinar el cambio de los estados de cada célula en cada periodo y en cada lugar (Couclelis, 1997; Wu y Webster, 1998; White y Engelen 2000).

En esta fase de su desarrollo el modelo del AC desarrollado en CHRISTALLER[®], utiliza Reglas de Transición deterministas en sus AC de tres bits. ¿Por qué se les llaman deterministas? Veamos. Wolfram (1984), mostró que cada una de las Reglas de Transición de tres bits genera *determinados* patrones complejos, aparentemente aleatorios. Una familia de reglas para simular la evolución del AC se obtiene a través de funciones cuyo valor en un sitio determinado se deriva de los valores del propio sitio y de los valores de sus vecinos más cercanos, en cada lapso de tiempo. Por tanto, cada regla (o instrucción) conduce al modelo por diferentes trayectorias de evolución en el espacio a lo largo del tiempo (Coombes, 2009). El AC desarrollado en

CHRISTALLER[®] hace un barrido exhaustivo de las Reglas de Transición de los AC e identifica la más precisa para simular la expansión urbana, apoyándose en indicadores de bondad de ajuste.

Los modelos basados en AC abren una ventana teórica asociada a la naturaleza de las ciudades como estructuras autosimilares. La literatura especializada muestra que los AC se adaptan bien al modelado urbano, con la ventaja de ser intrínsecamente espaciales y dinámicos. Para modelar ciudades con un mayor grado de realismo, se requieren AC más complejos, vecindades más amplias (más allá del primer orden o adyacencia directa) y Reglas de Transición más complejas (White y Engelen, 1997; White, 1998; Torrens, 2000; Barredo *et al* 2003; Berling-Wolff y Wu, 2004). Este es el futuro hacia el que avanzan las herramientas desarrolladas en CHRISTALLER[®].

AC: explicación “paso a paso”

Cuando se quiere modelar un proceso en el territorio con AC es conveniente concebir el espacio como una cuadrícula regular delimitada en dos dimensiones (Batty, 1997; 2007). Como adelantamos, los AC se componen de cuatro propiedades relacionadas con sus elementos básicos y es momento de explicarlos en mayor detalle: *i. Adyacencia*: se refiere a que las células ubicadas en cualquier espacio dimensional, deben registrar relaciones de proximidad-lejanía entre sí; *ii. Estados*: significa que cada célula puede asumir sólo un estado de un conjunto posible de estados, en un cierto punto en el tiempo (e.g. la célula puede asumir el estado de ser suelo construido o suelo vacante); *iii. Influencia Espacial*: implica que el estado de las células depende de los estados y configuraciones de otras células, especialmente de las más cercanas; y, *iv. Reglas de Transición*: son las reglas o instrucciones que impulsan los cambios de estado en cada célula en tiempo y espacio (Batty, 1997, 2007; Aguilera Benavente, 2006). Por tanto, un AC puede concebirse como un arreglo uniforme, cuadrículado, generalmente infinito, formado por objetos idénticos llamados *células*. Este arreglo puede ser *n-dimensional*, pero para efectos de simulación de sistemas se implementa en una, dos o tres dimensiones (Wolfram, 1983, 1994). Formalmente, un AC se representa a través de una función como la mostrada en la ecuación (1).

$$AC = (L, S, V, \delta) \quad (1)$$

Donde L es la cuadrícula regular, S es el conjunto finito de todos los posibles estados que pueden tomar las células, V es el conjunto finito de células que definen las relaciones espaciales entre ella (e.g. adyacencia o vecindad de un determinado orden) y δ es una función de transición aplicada a las células en cada lapso de tiempo (i.e. la Regla de Transición).


Las relaciones espaciales de vecindad para las células se pueden expresar de la siguiente manera: $c \in L$ es $V(c) = \{k_1, k_2, \dots, k_n | k_j \in L, j = 0, 1, \dots, n\}$. Es decir, la relación espacial de vecindad para una célula c es el conjunto de células para las cuales la célula c es el punto de referencia de su área de influencia.

En el caso de un AC de *una dimensión* (i.e. espacio lineal) la vecindad para la célula de estudio está compuesta por las células adyacentes que están en su lado derecho e izquierdo, por lo que se dice que esta vecindad es de radio r , como en la ecuación (2).

$$V(c) = (c_{i-r}, \dots, c_{i-1}, c_i, c_{i+1}, \dots, c_{i+r}) \quad (2)$$

Para un AC de *dos dimensiones* las relaciones clásicas de vecindad son las planteadas por von Neumann, que consisten en una célula central y sus cuatro vecinos con los que comparte frontera (i.e. norte, sur, este y oeste) (Figura 1a). Sin embargo, hay otras relaciones de vecindad, como las de Moore que incluyen las ocho células que rodean a la célula central: las que comparten frontera y un vértice (Figura 1b) (White *et al*, 2007).

Figura 1. Ejemplos de vecindades de un Autómata Celular.



Fuente: Elaboración propia con base en (White, 2007).

La definición de la cuadrícula permite concebir AC infinitos, pero en la práctica esto resulta imposible, por lo que los AC se representan como sistemas en un espacio finito que permite limitar espacialmente su operación. Esta es la llamada *condición de frontera* (Chopard, 2009).

Ahora bien, el elemento clave que define al AC son las Reglas de Transición. Deben ser uniformes y se aplican a cada célula y a cada estado. El cambio de estado más básico debe ser *local*, lo que implica que no hay cambios a distancia (Wolfram, 1983; 1994). Por tanto, vale la pena explorar las Reglas de Transición con cierto detalle.

Reglas de Transición Deterministas

La parte medular de los AC son las *Reglas de Transición* o instrucciones que representan la evolución del proceso que se quiere modelar. Las reglas pueden ser deterministas o estocásticas (i.e. probabilísticas), sencillas o altamente elaboradas. Normalmente, las reglas son fijas, pero algunos trabajos incluyen reglas que evolucionan para modelar un cierto proceso y es cuando los AC se transforman en *Agentes*. Se debe subrayar que las reglas deterministas se basan en la manera como se defina la adyacencia entre las células. Como vimos, en un espacio *bidimensional* la adyacencia más común es la de cuatro células, si se utiliza el criterio de von Neumann, o de ocho células si se utiliza el criterio de Moore. En consecuencia, en un espacio *unidimensional* (i.e. lineal) las células adyacentes sólo pueden ser tres: las que necesariamente comparten frontera, que pueden formar sólo ocho tipos de adyacencia. La Figura 2 muestra los tipos de adyacencia posibles y su codificación en numeración binaria: cero y uno significan dos tipos de estado de la célula. Por ejemplo, en nuestro caso: cero indica si la célula es un espacio vacante y uno si es espacio construido.

Figura 2. Espacio Unidimensional (Lineal): Tipos de adyacencia posibles entre células y su codificación binaria de tres dígitos.

Adyacencias posibles			Codificación binaria
0	0	0	0, 0, 0
0	0	1	0, 0, 1
0	1	0	0, 1, 0
0	1	1	0, 1, 1
1	0	0	1, 0, 0
1	0	1	1, 0, 1
1	1	0	1, 1, 0
1	1	1	1, 1, 1

Fuente: Elaboración propia.

Entonces: si K es el número de *estados* posibles de las células (en este caso tenemos dos estados: 0 y 1) y n es el número de tipos de *adyacencias* posibles (ya vimos que en el espacio lineal son ocho los tipos de adyacencias: (Figura 2), el número de Reglas de Transición (o de instrucciones posibles) para la evolución de un AC determinista de tres bits en un espacio lineal es: $K^n = 2^8 = 256$. Esto es: tenemos 256 Reglas de Transición posibles para simular la evolución de un modelo de AC de tres bits en el espacio lineal (Padilla *et al*, 2015). Veamos un ejemplo de las reglas deterministas que utilizamos en este trabajo y cómo se generan (Figura 3).

Observemos la Figura 3a. En la *primera* columna se muestran los ocho tipos posibles de adyacencia entre células en un espacio lineal de tres bits (es la misma codificación binaria que se presentó en la Figura 2). Esta codificación binaria puede traducirse a una serie exponencial de base dos (*segunda* columna) para obtener su valor absoluto o decimal (*tercera* columna, por ejemplo: $2^0 = 1$), que permita realizar operaciones numéricas (e.g. la suma de la *quinta* columna: $2 + 8 + 16 + 64 = 90$), considerando todas las *permutas posibles* de la codificaciones binarias de un dígito (*cuarta* columna, en la que presentamos sólo una permuta de todas las posibles). Como sabemos, son 256 permutas posibles (K^n). A cada codificación binaria de un dígito le corresponderá un valor decimal o absoluto de la tercera columna *en cada permuta posible*. Cada permuta de codificaciones binarias de un dígito genera un *total*: la suma de la *quinta* columna, que en nuestro ejemplo de la Figura 3a es 90. Por facilidad, a esa permuta específica que genera una suma de 90 se le llama Regla de Transición Número 90: no existe otra permuta que genere una suma de 90. Entonces, cada permuta genera una suma única que la identifica como Regla de Transición. Por tanto, las permutas posibles de codificaciones binarias de un dígito van a generar sumas que van desde cero (si todas las codificamos con ceros) hasta 255 (si todas las codificamos con unos). Evidentemente, el número de permutas de 0 a 255 es 256.


Figura 3. Simulación de una regla determinista.

a.

Número Binario	Exponencial Base 2	Número Decimal	Codificación	Decimal
000	2^0	1	0	
001	2^1	2	1	2
010	2^2	4	0	
011	2^3	8	1	8
100	2^4	16	1	16
101	2^5	32	0	

110	2^6	64	1	64
111	2^7	128	0	
Total				90

b.



Fuente: Elaboración propia en Matlab.

Al inspeccionar la Figura 3b, observamos que si se aplica la Regla 90 hay patrones de células que se repiten en espacios y lapsos de tiempo determinados: estructuras espaciotemporales que se reproducen en forma triángulos. Cada triángulo es la construcción de un *fractal*: en este caso, el llamado Triángulo de Sierpinski. La evolución del CA muestra como incluso una regla determinista sencilla puede generar patrones espaciotemporales complejos.

Ejemplo de Autómata Celular Determinista

Para apoyar la comprensión de cómo un AC genera una estructura espacial a lo largo del tiempo, consideremos un ejemplo sencillo. Preparamos una hoja de papel cuadrículado. Cada cuadro de la cuadrícula sería una célula. Establecemos la *condición inicial*. En este ejemplo, la condición inicial es que la estructura arranca en la célula central del primer renglón. Por tanto, activamos o marcamos la célula correspondiente. Por marcar la célula queremos decir en este ejemplo que la coloreamos de negro, pero en un ejercicio real utilizaríamos notación binaria (0, 1). La Regla de Transición que estamos utilizando en este ejemplo es la 146 e implica que en el renglón siguiente se marcan sólo las células que estén inmediatamente abajo a la derecha y a la izquierda de la célula que se activó originalmente (la de la condición inicial). Los AC implican la propiedad de *exclusión*, que significa que una célula no puede activarse en dos ocasiones (i.e. no hacer una marca arriba de otra). Con esta condición inicial, la Regla de Transición seleccionada y la propiedad de exclusión, se genera una estructura espacial que evoluciona en el tiempo.

Para tener un lenguaje más claro y general, se puede decir, que la *condición inicial* ocurre en el tiempo $\tau = 0$ y que la estructura evoluciona en lapsos de tiempo que operativamente son los renglones de la cuadrícula, por tanto el siguiente renglón es $\tau = 1$, el que sigue sería $\tau = 2$ y así sucesivamente. Al paso del tiempo, el AC genera una cierta estructura espaciotemporal sobre la hoja cuadrículada (Figura 4).

Vale la pena analizar la estructura que produce este AC. Si marcamos los renglones $\tau = 3$ y $\tau = 7$ con un color más claro, se devela una similitud entre renglones, que son lapsos de tiempo. Con la *Regla de Transición* 146 emerge una estructura de frecuencia con similitud de los renglones $\tau = 3, \tau = 7, \tau = 11, \tau = 15, \tau = 19...$ Estos renglones

son sólo algunos de los tantos que se repiten en la estructura espaciotemporal al aplicar la Regla de Transición 146 en un espacio unidimensional (pasa lo mismo en la Figura 3b, sólo que el AC evoluciona de acuerdo a otra Regla de Transición: la número 90).

DESARROLLO METODOLÓGICO

En este trabajo usamos software y herramientas de simulación para instrumentar modelos de AC que repliquen la expansión de la mancha urbana entre 2003 y 2017, de tres grandes ciudades mexicanas: Querétaro, San Luis Potosí y Toluca, que registran poblaciones entre 2.2 y 3.0 millones de habitantes. No sólo seleccionamos tres ciudades complejas de gran tamaño, sino que elegimos ciudades que registran tres velocidades contrastantes (i.e. alta, media y baja) en la expansión de su mancha urbana. Para esto generamos un desarrollo híbrido entre los AC y los Sistemas de Información Geográficos (SIG), que se sitúa en el campo de la Geosimulación (Benenson *et al.*, 2004). Este desarrollo es sólo uno de los varios módulos que se han implementado en la *Estación de Inteligencia Territorial: (CHRISTALLER)*[®], desarrollada en El Colegio Mexiquense (Garrocho y Chávez, 2018).

Figura 4. Ejemplo de Autómata Celular.



Fuente: Elaboración propia en Excel.

La literatura reporta ejemplos que muestran logros cuando se articulan AC con SIG para simular fenómenos urbanos (Tobler 1979, White y Engelen 1993, Clarke y Gaydos 1998, Wu 1998, Batty et al. 1999, Liu et al. 2008) y apoyar la planeación y gestión de las ciudades (Stevens et al., 2007, Arsanjani et al. 2013). Una de las ventajas de los modelos de AC es que las trayectorias de los patrones urbanos futuros se pueden observar durante el desarrollo de la simulación del modelo (Li y Yeh 2000; Buzai, 2007). Siempre en el marco de ciertas Reglas de Transición (Al-Kheder et al., 2008, de Almeida et al., 2003), apoyándose en indicadores de bondad de ajuste (Wu 2002, Dietzel y Clarke 2006) y con el apoyo de las capacidades de los SIG (Batty et al., 1999; Buzai, 2007; Arsanjani et al., 2013), que es el “procesador de palabras” de los geógrafos del Siglo XXI (Garrocho y Buzai, 2015).

En este trabajo, el SIG simplifica la realidad y la muestra en mapas, hasta lograr una masa de datos representativa y manejable. Una forma de representación de esta información es en formato raster (Aliaga, 2006). Es decir, el espacio geográfico se representa en una malla regular, que es la base de los AC. La malla tiene $(n \times m)$ células, lo que determina su resolución espacial. En el entorno computacional, cada célula es un

pixel que puede asumir un determinado estado. Al aplicar un proceso iterativo derivado de Reglas o instrucciones de Transición, se determinan los resultados espaciotemporales de la simulación (Feng, 2017). La idea es construir mecanismos de validación de teorías y de aplicación de modelos de planeación y simulación urbana (y regional). Estos modelos serán más populares mientras más amigable sea su manejo y mayor su capacidad de simular procesos de cambio urbano en marcos dinámicos no-lineales (Batty, 1997; de Almeida et al, 2003). Esta es la idea que está tras bambalinas de CHRISTALLER[®] sobre AC.

Los SIG por sí solos no han sido la opción más adecuada para modelar sistemas *espaciotemporales*. En particular, la representación del tiempo en los SIG aún constituye un problema no-resuelto. Sin embargo, al acoplar de manera transparente desarrollos computacionales especializados (como los AC de CHRISTALLER[®]) con un SIG, se genera una plataforma muy potente para el análisis y simulación de fenómenos urbanos en tiempo y espacio (Brown *et al.*, 2005; Crooks *et al.*, 2008; Deep y Saklani, 2014).

Método


La lógica del modelo de AC que se utiliza en la parte experimental de este trabajo se basa en Reglas de Transición deterministas, donde la adyacencia se define a partir de criterios de contigüidad (Wolfram, 1984). El modelo se basa en la adaptación del número de procesos que define cuántas veces va a ser recorrido el espacio donde están contenidos los ceros y unos de la imagen raster (i.e. mapas) que se analizan.

La Regla de Transición (δ) es un número en base 10 que va del número “0” al “255”, es decir, $\delta \in [0, 255]$. Este número en base 10 se traduce en su equivalente de base 2 (binario) que puede ser utilizado por el modelo. Para los experimentos de este trabajo, las condiciones iniciales provienen de mapas raster a los que se les realizó un proceso de filtrado para binarizarlas. Con los mapas ya binarizados CHRISTALLER[®] instrumenta el modelo de AC.

En este trabajo, la simulación y proyección de la mancha urbana de las tres ciudades seleccionadas parte de una Regla de Transición determinista que se describe de la siguiente manera:

- i. Se obtienen los mapas de las ciudades en formato raster del satélite LandSat para 2003 y 2017. Se hace un filtrado del mapa raster para reclasificar los píxeles en 1 (suelo ocupado) y 0 (suelo vacante) y así tener un mapa binario (Figura 4).
- ii. Un ejemplo de las condiciones iniciales de las imágenes en formato binario se muestra en la Figura 5. Tomamos el dato con coordenadas (1,1), que se refiere a la célula de la primera columna (contadas de izquierda a derecha) y el primer renglón (contados de arriba abajo) e identificamos los vecinos: X, X-1, X+1 (Figura 6). En un AC unidimensional, el espacio consiste en un solo renglón de células a las que se aplica un principio de adyacencia básico de dos vecinos por célula y a los que también administramos condiciones de frontera (Figura 6). El principio de adyacencia y la Regla de Transición producen el estado de la estructura espaciotemporal en cada lapso de tiempo (τ), que en nuestro ejemplo es el renglón siguiente en la cuadrícula. Esto se va generando en este ejemplo, como el movimiento de avance de un peón de ajedrez (Figura 7).


Figura 5. Condición inicial de un mapa filtrado para el análisis de AC.



Fuente: Elaboración propia.

- iii. En nuestros experimentos no generamos el estado en el siguiente renglón, sino que actualizamos el estado ($\tau = 1$), como se muestra en la Figura 8. Con esto garantizamos que la rejilla donde ubicamos el mapa binario bajo experimentación no crezca.
- iv. Las Reglas de Transición que utilizamos son las aplicables a tres bits. Por lo tanto, tenemos 256 reglas que podemos utilizar. La *clave* es encontrar la Regla de Transición que mejor simule el proceso de expansión urbana para cada ciudad que participa en el experimento, de entre el conjunto de 256 Reglas de Transición posibles. Para lograrlo, se requieren por lo menos dos cosas: *i*. Probar todas las Reglas de Transición (las 256); y *ii*. Contar con indicadores de bondad de ajuste que valoren la similitud de los resultados del modelo de AC con la realidad observada, para medir la precisión de cada Regla de Transición. En este trabajo hicimos ambas cosas.
- v. Los índices de bondad de ajuste que utilizamos fueron: *i*. La *Dimensión Fractal*, que permite estimar el crecimiento de la mancha urbana, incluso cuando se llenan espacios vacantes. Esta es una aportación metodológica de este trabajo; *ii*. El *Índice de Kappa de Cohen*, que permite medir la similitud general entre dos mapas; y, *iii*. El *Índice de Jaccard* que mide la igualdad de la localización de las células considerando sus estados, en dos mapas.
- vi. A partir de los mapas de 2003 de las ciudades bajo experimentación, se ejecutó el modelo de AC con dos iteraciones y se obtuvieron simulaciones de la expansión de las manchas urbanas para 2017 con cada una de las 256 Reglas de Transición. Los indicadores de bondad de ajuste valoraron cuál de las Reglas generaba el mejor ajuste de la simulación del AC con la realidad de cada ciudad en 2017.

Figura 6. Condiciones de frontera en el AC.




Fuente: Elaboración con base en Hoyo, 2006.

Dimensión Fractal como medida de expansión urbana en un mapa

Desde que se empezó a utilizar el concepto de *fractal* se han encontrado diversas estructuras fractales en sistemas naturales, sociales y en estructuras socioespaciales (Goodchild y Mark, 1987). Aún más, se pueden distinguir fractales perfectamente autosimilares (que se generan mediante procesos de iteración en forma regularmente determinada) y fractales de similitud estocástica (cuya autosimilitud es aleatoria y no-determinística) (Buzai, 2007).


El grado de irregularidad y fragmentación de las estructuras es posible medirlo con la *dimensión fractal* (D), que por lo regular es un número no-entero que se sitúa en un espacio Euclidiano y se representa entre $D = 0$ (punto), $D = 1$ (línea), $D = 2$ (plano bidimensional) y $D = 3$ (volumen tridimensional).

Figura 7. Transición en el AC. Tomamos los datos con coordenadas (1,2) - (1,3) - (1,4) y generamos el dato (2,3).



Fuente: Elaboración propia.

Figura 8. Nueva Transición en el AC. Tomamos los datos con coordenadas (1,2) - (1,3) - (1,4) y actualizamos el dato (1,3).



Fuente: Elaboración propia.

Con los valores de dimensión podemos considerar que la Dimensión Fractal también es una dimensión de *crecimiento*, ya que $D = 1$ es una línea y $D = 2$ es un plano totalmente lleno de puntos o un plano sólido. Por lo tanto, la dimensión fractal en este trabajo está contenida entre 1.0 y 2.0. En nuestro caso, si la métrica se acerca a 1.0 podemos decir que decreció la proyección de la mancha urbana generada por el modelo de AC, porque la forma tiende a ser lineal. Pero si la medida se acerca a 2.0 se puede concluir que creció la proyección del modelo de AC, ya que la forma se acerca a un plano totalmente lleno.

La dimensión Euclidiana de un objeto relaciona la unidad de medida utilizada con el valor geométrico medido: $N(L) = (1/L)^D$, donde $(1/L)$ corresponde a la escala, que son las divisiones que se hacen en el plano (i.e. las células de la malla que usamos en nuestros experimentos). El cálculo de D se basa en la correspondiente medición del número de células ocupadas que cubren determinado conjunto (línea, superficie o volumen) $N(L)$ que está en función de la escala. El cálculo de la dimensión fractal D , sólo es válido en el rango en el que la relación entre $N(L)$ y $1/L$ es potencial y está bien definida mediante la ecuación (3).

$$D = \frac{\text{Log}(N(L))}{\text{Log}\left(\frac{1}{L}\right)} \quad (3)$$

A esta relación potencial se le denomina “Método de Conteo de Cajas o Píxeles” (*box counting*), que, en nuestro caso, mide la diferencia del crecimiento o contracción de la mancha urbana entre el mapa satelital y el mapa que resulta del modelo de AC, considerando en el crecimiento si se llenan espacios vacantes. Mientras menor sea la diferencia entre lo que indica el modelo y lo que se observa en el mapa satelital, mejor el ajuste del modelo.

Índice de Kappa de Cohen como medida de comparación de mapas

El *Índice Kappa de Cohen* (k) es una medida estadística que ajusta el efecto del azar en la comparación de mapas. En nuestro caso: entre mapas de categorías binarias. El k puede tomar valores entre -1.0 y +1.0 y se interpreta de manera parecida al índice de correlación de Pearson: mientras más cercano a +1.0, mayor es el grado de

concordancia entre los mapas; mientras más cercano a -1.0 mayor es el grado de discordancia; y un valor alrededor de 0.0 indica ausencia de similitud entre los mapas. Lo importante es que los resultados del Índice de Kappa de Cohen controlan el efecto del azar y es posible saber si sus resultados son estadísticamente significativos (de Ullibbarri, 1999; Abraira, 2001; Viera, 20005). En nuestros experimentos los k son significativos al 0.95. El cálculo del índice Kappa de Cohen se realiza con la ecuación (4).

$$K = \frac{P_0 - P_e}{1 - P_e} \quad (4)$$

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. Entonces, el numerador del Índice de Kappa de Cohen expresa la proporción de igualdad observada menos la esperada, en tanto que el denominador es la diferencia entre la igualdad total y la proporción esperada. Si este valor es igual a 1.0, estaríamos frente a una situación en que la igualdad entre los mapas es perfecta (100% de igualdad), cuando el valor es 0.0 los mapas tienen un parecido de cero (no se parecen en nada), y si el valor es -1.0 un mapa sería el inverso del otro (como el negativo de una fotografía) (Viera, 2005).

En la Figura 9, se muestra una matriz de comparación entre dos mapas. En el ejemplo los mapas que utilizamos son de una misma región en diferente lapso de tiempo y contamos la transición de los valores. La transición de los unos del mapa 1 al mapa 2 es 42. La transición de unos a ceros es 13. Por su parte, la transición de ceros a unos es 8 y finalmente la transición de ceros es 37. Con los valores de la matriz podemos obtener las variables P_0 y P_e .

Figura 9. Ejemplo del Índice Kappa de Cohen.

		Mapa 2		Total
		1	0	
Mapa 1	1	42	13	55
	0	8	37	45
Total		50	50	100

$P_0 \Rightarrow$ observado: $(42+37)/100=0.79$
 $P_e \Rightarrow$ esperado: $(50/100)(55/100)+(50/100)(45/100)=0.5$

$$\text{kappa} = \frac{P_0 - P_e}{1 - P_e} = \frac{0.79 - 0.5}{1 - 0.5} = 0.58$$

Fuente: Elaboración propia.

P_0 es la probabilidad observada en los mapas, se calcula con los valores que se encuentran en la diagonal de la matriz (i.e. los valores que permanecen en los mapas a pesar de que el tiempo ya transcurrió), sobre el total de la suma de los valores que se encuentran en la columna y renglón. A esto es a lo que se le llama Total.

P_e es la probabilidad esperada en los mapas. Se calcula de la siguiente forma: el valor del Total de unos en la columna del mapa 2 (i.e. 50) entre el Total (i.e. 100) y se

multiplica por el Total del renglón del mapa 1 (i.e. 55) entre el Total, seguido de la suma de los valores obtenidos del Total de los ceros en la columna del mapa 2 (i.e. 50) entre el Total, multiplicado por el renglón en el mapa 1 (i.e. 45) entre el Total. Así se obtiene una de las variables. Luego se utiliza la ecuación (4) para el cálculo del índice.

¿Cómo interpretamos los valores del Índice de Kappa de Cohen? Viera (2005) propone, como guía, los umbrales que se presentan en el Cuadro 1. La interpretación de los k es una cuestión subjetiva y no existe acuerdo general (esto no es raro: lo mismo ocurre con el índice de correlación de Pearson). Sin embargo, esta guía se acepta cuando el número de píxeles que componen las imágenes es elevado, como es nuestro caso que consideramos casi 7.0 millones de píxeles por ciudad. Por lo tanto, aquí utilizaremos los umbrales interpretativos de k que se muestran en el Cuadro 1.

Cuadro 1. Interpretación del Índice de Kappa de Cohen.

Índice Kappa	Estimación del Grado de Igualdad
< 0	No igualdad
0.0 - 0.2	Insignificante
0.2 - 0.4	Bajo
0.4 - 0.6	Moderado
0.6 - 0.8	Bueno
0.8 - 1.0	Muy bueno

Fuente: Elaboración propia, con base en (Viera, 2005).

Índice de Jaccard como medida de Comparación-Posición de mapas


El Índice de Similitud de Jaccard (I_j) expresa el grado en el que dos imágenes (e.g. mapas) son semejantes (Reyes y Torres-Flores, 2009). El intervalo de valores para el Índice de Jaccard va de 0.0, cuando la desigualdad entre los mapas es total, hasta 1.0, cuando dos mapas tienen la misma composición en la posición y estado de las células. El índice se obtiene con la ecuación (5).

$$I_j = \frac{T_{11}}{T_{21} + T_{12} + T_{11}} \quad (5)$$

Donde T_{21} es el número de objetos (i.e. células) presentes en el conjunto A, T_{12} es el número de objetos presentes en el conjunto B y T_{11} número de objetos presentes en ambos conjuntos A y B (Figura 10).

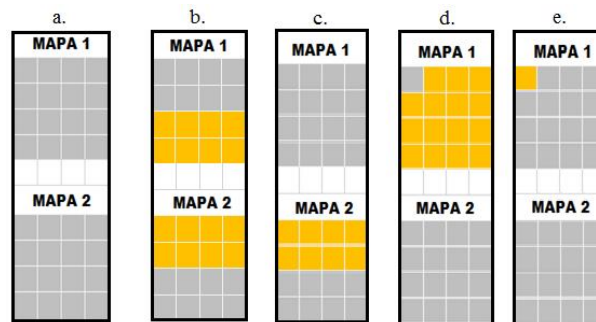
El Índice de Jaccard es sencillo de analizar desde la teoría de conjuntos (Figura 9). En el conjunto A, los objetos que se encuentren en su dominio se nombran T_{21} . En el conjunto B, los objetos que se encuentran en su dominio se les etiqueta T_{12} . Los objetos que se encuentren en la unión de los dos conjuntos (i.e. $A \cup B$) se les califica como T_{11} . Todo lo que este fuera de los conjuntos lo etiquetamos como T_{22} . Para explicar el cálculo del índice de Jaccard nos apoyamos en la Figura 11.

Figura 10. Interpretación del Índice de Jaccard.



Fuente: Elaboración propia.

Figura 11. Ejemplo Índice de Jaccard.



Fuente: Elaboración propia.

En la Figura 11, se muestran cinco ejemplos de comparación de conjuntos de células (e.g. píxeles) con dos colores (i.e. estados) en diferentes posiciones. En este ejemplo los llamamos mapas 1 y 2. La Figura 11a, muestra una situación de completa similitud (i.e. las mismas células de los dos mapas están en color gris). Utilizando la ecuación (5) el valor del índice de Jaccard es 1.0. En la Figura 11b, no existe similitud (i.e. ninguna célula en gris en el mapa 1 coincide con las células en gris en el mapa 2). En esta circunstancia el valor del Índice de Jaccard es 0.0. En la Figura 11c, la similitud es parcial (i.e. la mitad de las células grises en el mapa 1 coinciden con las células grises en el mapa 2). Para este caso el Índice de Jaccard es menor a uno (el cálculo con la ecuación (5) genera un valor de 0.33). La Figura 11d, muestra otro caso de similitud parcial: sólo una célula en gris en el mapa 1 coincide con las células en gris en el mapa 2, por lo tanto, el cálculo del Índice de Jaccard debe ser cercano a cero (efectivamente: el valor resultante es 0.03). Por último, la Figura 11e muestra otro tipo de similitud parcial: una célula en el mapa 1 no coincide con las células en gris en el mapa 2, por lo tanto, el índice de Jaccard debe ser cercano a uno (cierto: el valor calculado es 0.88).

Los casos mostrados en la Figura 11, concuerdan perfectamente con los valores esperados del Índice de Jaccard, según la ecuación (5). El Índice de Jaccard calcula dos aspectos clave para la comparación de mapas: la *igualdad* de los datos raster y su *posición* en el mapa. Todos los Índices de Jaccard utilizados en este trabajo tienen un nivel de significancia de 0.95, de acuerdo a las tablas de significancia de Real (1999).

Las tres métricas de bondad de ajuste presentadas en esta sección las calcula la *Estación de Inteligencia Territorial: CHRISTALLER®*.

RESULTADOS DEL MODELO DE EXPANSIÓN URBANA CON AC

Este ejercicio experimental se enfocó a las ciudades de Querétaro (Figura 12), Toluca (Figura 14) y San Luis Potosí (Figura 16), para el periodo 2003-2017. Las imágenes satelitales de LandSat 3 que utilizamos como referente de contraste para los resultados del modelo de AC corresponden a 2017 y se muestran en las Figura 13, 15 y 17. Su situación en 2003 se muestra en las Figuras 12, 14 y 16. Estas imágenes satelitales de 2003 de LandSat son los *mapas base* a con los cuales el Modelo del AC de CHRISTALLER® les trabajo como datos de entrada. Recordemos que estamos trabajando con tres bits y, por tanto, tenemos 256 Reglas de Transición. CHRISTALLER® hace un barrido completo de las 256 Reglas de Transición, estima los indicadores de bondad de ajuste e identifica la Regla de Transición que mejor replica la expansión de la mancha urbana de cada ciudad en el periodo de experimentación. Las Figuras 18, 19 y 20 muestran las simulaciones de la mancha urbana para 2017 en las tres ciudades de estudio, con la Regla de Transición más precisa. Para Querétaro la Regla de Transición que mostró el mejor ajuste entre la imagen satelital de 2017 y la proyección del modelo de AC fue la 192; para San Luis Potosí fue la 218 y para Toluca la Regla 222.

¿Qué tan precisa es la proyección del Modelo de AC?

En cuanto a la Dimensión Fractal, los resultados para las tres ciudades son muy alentadores (Cuadro 2). Las diferencias entre la imagen satelital de 2017 y la proyección del modelo de AC de CHRISTALLER® registran una variación de menos de una décima (en el caso de San Luis Potosí y Toluca) y de siete centésimas para el caso de Querétaro. Se pueden considerar muy buenos ajustes.

Figura 12. Querétaro: Mapa Satelital 2003.

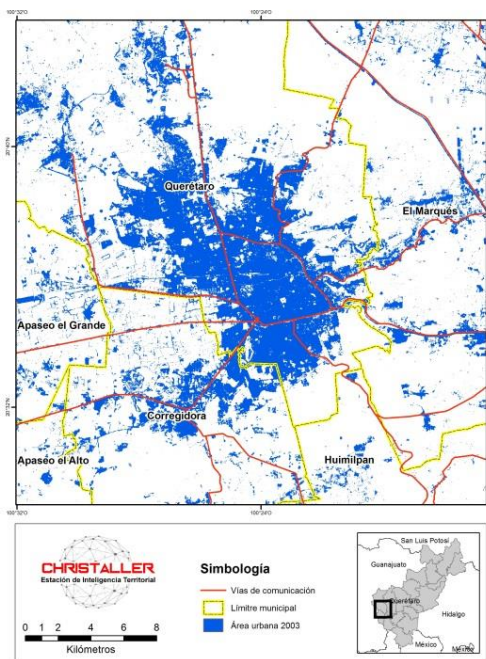
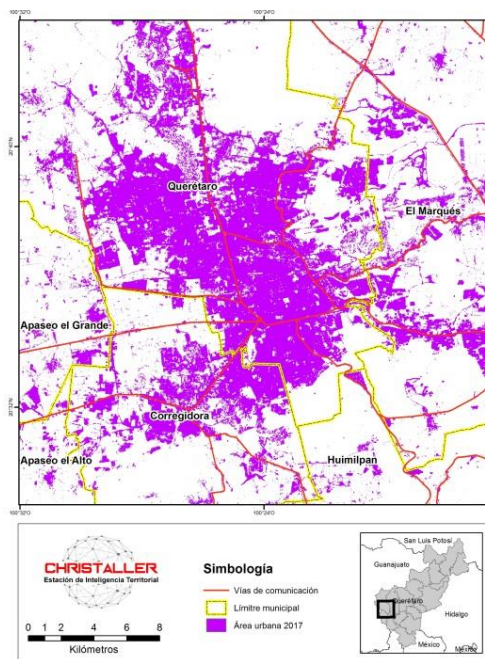


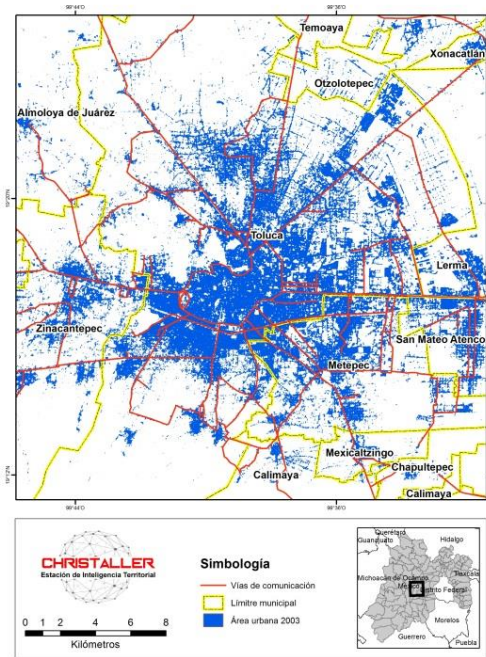
Figura 13. Querétaro: Mapa Satelital 2017.



Fuente: Elaboración propia con base en LandSat.

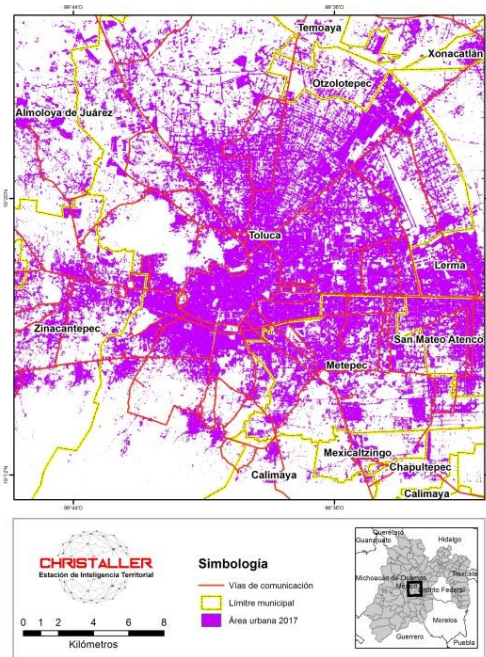
Fuente: Elaboración propia con base en LandSat.

Figura 14. Toluca: Mapa Satelital 2003.



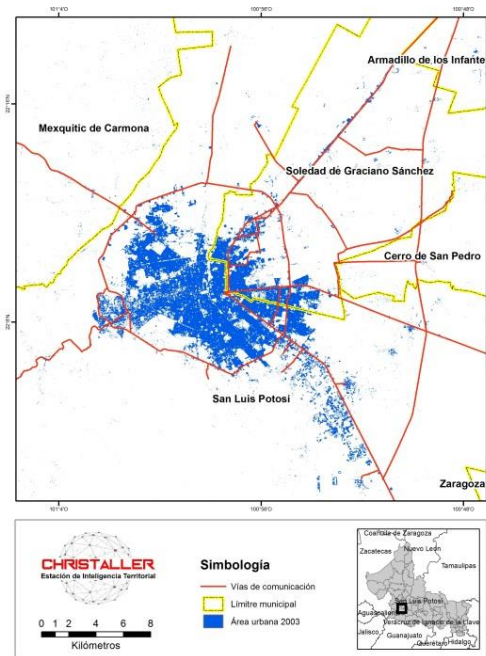
Fuente: Elaboración propia con base en LandSat.

Figura 15. Toluca: Mapa Satelital 2017.



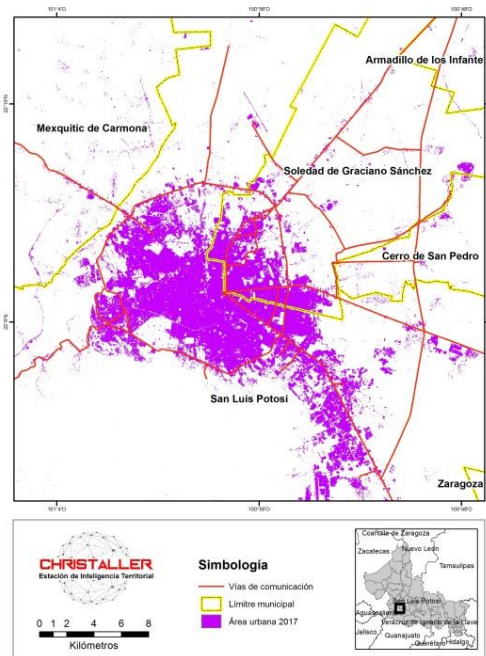
Fuente: Elaboración propia con base en LandSat.

Figura 16. San Luis Potosí: Mapa Satelital 2003.



Fuente: Elaboración propia con base en LandSat.

Figura 17. San Luis Potosí: Mapa Satelital 2017.



Fuente: Elaboración propia con base en LandSat.

Cuadro 2. Resultados de la Dimensión Fractal.

Ciudades	2003	2017	2017 proyección	2031 proyección
Querétaro	1.72	1.69	1.62	1.64
San Luis Potosí	1.42	1.53	1.46	1.56
Toluca	1.74	1.85	1.77	1.87

Fuente: Elaboración propia.

Por su parte, el Cuadro 3 muestra los Índices de Kappa de Cohen y el Índice de Jaccard para las tres ciudades. Como se mencionó, el valor máximo de los dos índices es 1.0. El *Índice de Kappa de Cohen* para Querétaro (0.53) y Toluca (0.56) indica que el modelo de AC generó una proyección moderadamente precisa del proceso de expansión de la mancha urbana entre 2003 a 2017, y para San Luis Potosí indica que el ajuste fue bueno (0.64). Esto es interesante, porque, aparentemente, a mayor *velocidad relativa* de expansión de la mancha urbana, menor capacidad del modelo de AC para replicar el proceso. La ciudad con la *velocidad relativa* de expansión más acelerada en el periodo de estudio fue Querétaro, luego Toluca y la de velocidad más lenta fue San Luis Potosí. Sin embargo, esta hipótesis de la relación inversa entre la velocidad de expansión de la mancha urbana y la bondad de ajuste del modelo no pasa de ser una conjetura que debe probarse considerando más ciudades mexicanas.

Cuadro 3. Bondad de ajuste entre la imagen satelital y los resultados del modelo de AC.

Ciudad	Índice Kappa	Índice de Jaccard
Querétaro	0.53	0.76
San Luis Potosí	0.64	0.91
Toluca	0.56	0.68

Fuente: Elaboración propia.

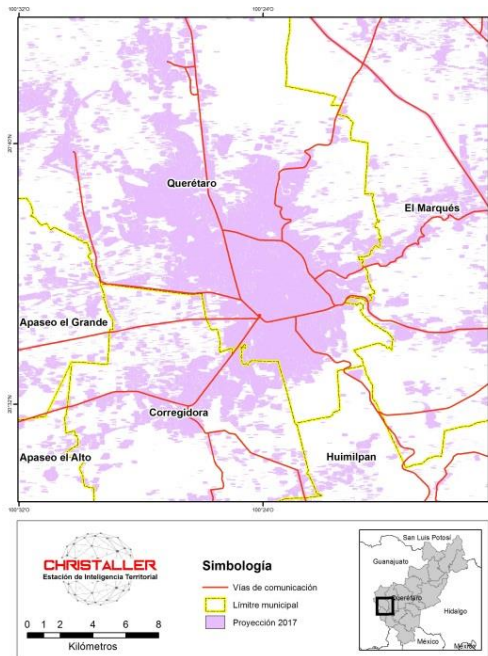
El Índice de Jaccard, que es más completo que el de Kappa de Cohen, muestra resultados aún más alentadores para el Modelo de AC. Querétaro registró un Jaccard de 0.76, Toluca 0.68, y San Luis Potosí un sorprendente 0.91 (muy cercano al valor ajuste perfecto: 1.0). Los tres valores indican una *alta capacidad* del modelo de AC para replicar el fenómeno de expansión urbana en las tres ciudades, en los catorce años de análisis. En este caso, también se devela que las ciudades con procesos relativos más acelerados de expansión de la mancha urbana (Querétaro y Toluca) son más complicadas de modelar, que la ciudad con el proceso de velocidad más lento (San Luis Potosí).

La calidad de los valores de los indicadores de bondad de ajuste permite proyectar con menos incertidumbre la expansión de la mancha urbana para las tres ciudades, para un periodo similar al de las simulaciones: un horizonte de catorce años, esto es, al año 2031 (Figuras 20, 21 y 22). Estas proyecciones son un dato importante para los planificadores urbanos, pero de *ninguna manera* son una predicción del futuro.

Desempeño de la Estación de Inteligencia Territorial: CHRISTALLER®

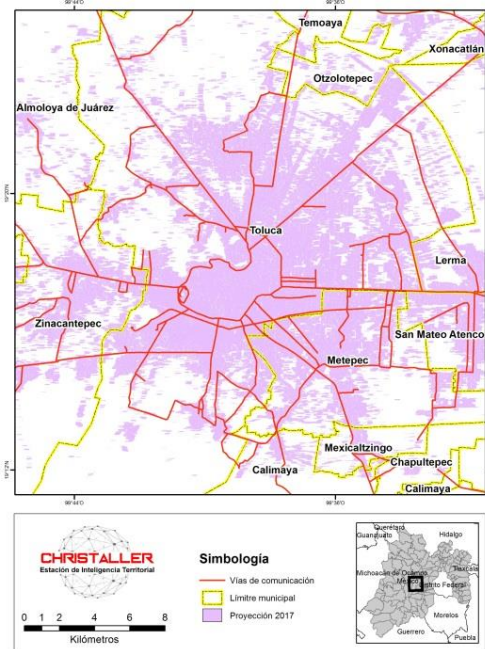
CHRISTALLER® fue capaz de manejar archivos numéricos masivos e imágenes de alta complejidad. Tan sólo las imágenes satelitales de las ciudades contenían alrededor de 7.0 millones de píxeles. Considerando la magnitud de la información, la complejidad de los cálculos, el barrido exhaustivo de las Reglas de Transición, la estimación iterativa de los índices de bondad de ajuste y la generación automatizada de los mapas de las simulaciones y las proyecciones, podemos considerar que el desempeño del Modelo del AC de CHRISTALLER® y las métricas correspondientes son aceptablemente rápidos. En promedio, CHRISTALLER® requirió cuatro horas para generar todos los resultados y las proyecciones de cada ciudad.

Figura 18. Querétaro: Mapa del Modelo de Autómata Celular, 2017.



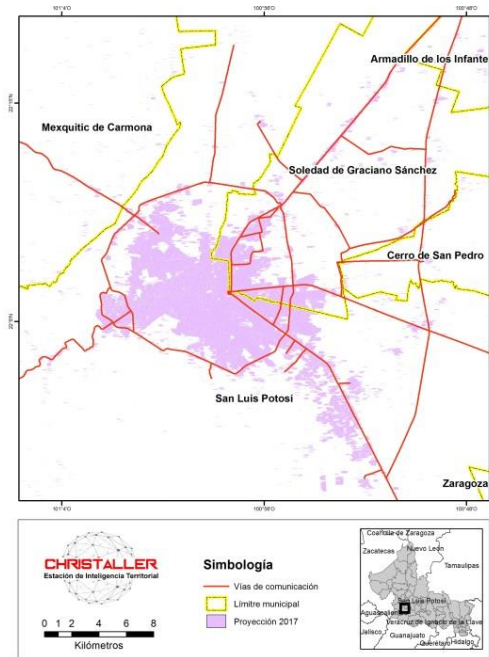
Fuente: Elaboración propia con CHRISTALLER®

Figura 19. Toluca: Mapa del Modelo de Autómata Celular, 2017.



Fuente: Elaboración propia con CHRISTALLER®

Figura 20. San Luis Potosí: Mapa del Modelo de Autómata Celular, 2017.



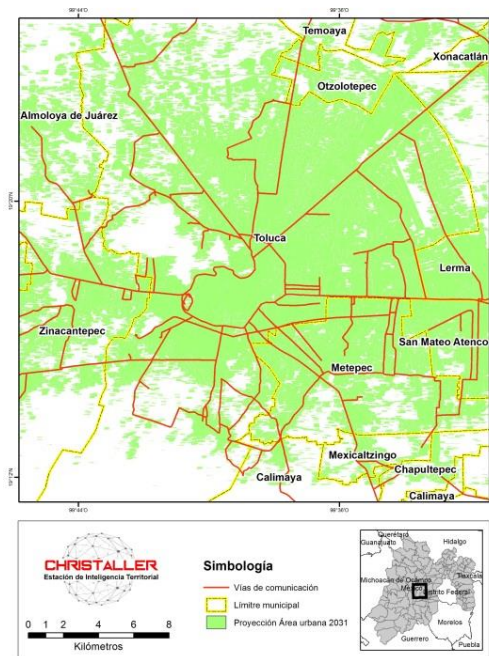
Fuente: Elaboración propia con CHRISTALLER®

Figura 21. Querétaro: Mapa del Modelo de Autómata Celular, 2031.



Fuente: Elaboración propia con CHRISTALLER®

Figura 22. Toluca: Mapa del Modelo de Autómata Celular, 2031.



Fuente: Elaboración propia con CHRISTALLER®

Figura 23. San Luis Potosí: Mapa del Modelo de Autómata Celular, 2031.



Fuente: Elaboración propia con CHRISTALLER®

CONCLUSIONES

Este texto presenta experimentos de simulación urbana llevados a cabo con el módulo de Autómatas Celulares de la *Estación de Inteligencia Territorial: CHRISTALLER®*, construida en El Colegio Mexiquense. Se simuló la expansión de tres grandes ciudades mexicanas (poblaciones entre 2.2 y 3.0 millones de habitantes) con modelos de AC deterministas para el periodo 2003-2017. Los resultados fueron muy alentadores: los indicadores de bondad de ajuste entre la imagen satelital de las ciudades de 2017 y los resultados del modelo fueron de moderadamente precisos a muy precisos. Esto permitió proyectar la expansión urbana de las tres ciudades a 2030, lo que constituye información valiosa para los interesados en la expansión de la ciudad (e.g. gobiernos, investigadores, desarrolladores, sociedad en general). Un tema crítico, común a las tres ciudades estudiadas, en el que la información de las proyecciones puede ser de gran utilidad es el de la disponibilidad de agua.

La estrategia que se siguió en la exposición del texto fue, primero, explicar en detalle los principales aspectos de los modelos de AC, para orientar a los futuros usuarios de CHRISTALLER®, ya que su diseño prevé su operación como un sistema abierto de uso gratuito. Esta primera sección mostró la complejidad de los procesos que puede llevar a cabo CHRISTALLER®, y la ventaja que implica contar con un sistema automatizado amigable que permita *hacer sencillo lo complejo*. Luego se detalló el método que se siguió para realizar los experimentos urbanos. En esta parte del trabajo vale destacar los indicadores de bondad de ajuste del modelo de AC que usa CHRISTALLER®: la Dimensión Fractal, el Índice de Kappa de Cohen y el Índice de Jaccard. Aunque los tres apuntan hacia aspectos diferentes de las simulaciones, el más completo es el Índice de Jaccard, seguido por la Dimensión Fractal. El uso de la Dimensión Fractal como indicador de bondad de ajuste es una aportación metodológica de este trabajo. Finalmente, se demostró la potencia de CHRISTALLER® para simular la expansión de ciudades de gran tamaño. Los experimentos demostraron que CHRISTALLER® tiene un alto desempeño procesando una enorme cantidad de información numérica y visual, y es robusto en su arquitectura y su conexión con el SIG.

El futuro de CHRISTALLER® es incrementar sus capacidades para que logre modelar ciudades con un mayor grado de realismo. Esto implica modelos de AC más complejos, criterios de vecindad más amplios y Reglas de Transición más complejas. Ya estamos trabajando en esto. Sin embargo, debemos ser cuidadosos de no caer en el “*espejismo de la precisión*”.

Abundan en la literatura diversas sugerencias, algunas muy sofisticadas, de cómo construir modelos de AC. Estas aportaciones son muy valiosas en tanto abren preguntas de investigación que resultan seductoras en el mundo académico, pero que con frecuencia producen el efecto colateral que aquí llamamos “*el espejismo de la precisión*”, que complica y encarece la instrumentación habitual de estos modelos en el mundo real. Habrá que cuidar que los modelos de AC de CHRISTALLER® sean verdaderamente útiles en la investigación, la docencia, la planeación, y no enmarañadas, pesadas y costosas estructuras metodológicas que terminan por ser irrelevantes para mejorar nuestras ciudades.

Nuestra propuesta es que la investigación aplicada que llevamos a cabo en nuestros países emergentes, deben lograr un *delicado balance* entre teoría, método, técnica, costo y utilidad, con el fin de diseñar métodos de análisis realmente útiles, que puedan ser manejados de manera cotidiana por los planificadores de nuestros países, y contribuyan a mejorar efectivamente el futuro de las ciudades. En nuestros países debemos evitar a

toda costa el costoso “*espejismo de la precisión*”, porque limita seriamente la utilidad social de nuestras investigaciones.

Al final, se demostró que la combinación de altas matemáticas, ciencias computacionales y geografía, pueden generar instrumentos complejos, pero amigables, para el análisis urbano. Esperemos que una vez que CHRISTALLER[®] esté disponible en acceso abierto (en el primer trimestre de 2018) sea ampliamente utilizado para estudiar y conducir mejor nuestras ciudades latinoamericanas.

BIBLIOGRAFÍA

Abraira, V. (2001). El índice kappa. **Semergen-Medicina de Familia**. 27(5), 247-249.

Aliaga, G. (2006). Juan Peña Llopis. Sistemas de Información Geográfica aplicados a la gestión del territorio. **Revista de Geografía Norte Grande**. (36), 97-101.

Aguilera, F. (2006). Predicción del crecimiento urbano mediante sistemas de información geográfica y modelos basados en autómatas celulares. **GeoFocus. Revista Internacional de Ciencia y Tecnología de la Información Geográfica**. (6), 81-112.

Aguilera Ontiveros, A. (2002). **Ciudades como tableros de ajedrez. Introducción al modelado de dinámicas urbanas con autómatas celulares**. *Colsan. San Luis Potosí*.

Al-kheder, S.; Wang, J.; Shan, J. (2008). Fuzzy inference guided cellular automata urban-growth modelling using multi-temporal satellite images. **International Journal of Geographical Information Science**. 22(11-12), 1271-1293.

Arsanjani, J. J.; Helbich, M.; Kainz, W.; Boloorani, A. D. (2013). Integration of logistic regression, Markov chain and cellular automata models to simulate urban expansion. **International Journal of Applied Earth Observation and Geoinformation**. 21, 265-275.

Barredo, J. I.; Kasanko, M.; McCormick, N.; Lavalle, C. (2003). Modelling dynamic spatial processes: simulation of urban future scenarios through cellular automata. **Landscape and urban planning**, 64(3), 145-160.

Batty, M.; Xie, Y. (1996). Preliminary evidence for a theory of the fractal city. **Environment and Planning A**, 28(10), 1745-1762.

Batty, M. (1997). Virtual geography. **Futures**, 29(4), 337-352.

Batty, M.; Longley, P. A. (1994). **Fractal cities: a geometry of form and function**. Academic press. UK.

Batty, M. (2007). *Cities and complexity: understanding cities with cellular automata, agent-based models, and fractals*. The MIT press. Massachusetts, USA.

Batty, M.; Xie, Y.; Sun, Z. (1999). Modeling urban dynamics through GIS-based cellular automata. **Computers, environment and urban systems**, 23(3), 205-233.

Baxendale, C. A.; Buzai, G. D. (2011). Dinámica de crecimiento urbano y pérdida de suelos productivos en el Gran Buenos Aires (Argentina), 1869-2011. Análisis espacial basado en sistemas de información geográfica. **Serie Geográfica**. 17 (2011), 77 - 95

Benenson, I.; Torrens, P. M. (2004). **Geosimulation: Automata-based modeling of urban phenomena**. John Wiley & Sons. USA.

Berling-Wolff, S.; Wu, J. (2004). Modeling urban landscape dynamics: a case study in Phoenix, USA. **Urban ecosystems**. 7(3), 215-240.

Brown, D. G.; Riolo, R.; Robinson, D. T.; North, M.; Rand, W. (2005). Spatial process and data models: Toward integration of agent-based models and GIS. **Journal of Geographical System**. 7(1), 25-47.

Buzai, G. D. (2007). Actualización de cálculos y distribuciones espaciales a través de cadenas de

Markov y autómatas celulares: Pérdida de suelos en el área metropolitana de Buenos Aires–2001. **Panorama de la Ecología de Paisajes en Argentina y Países Sudamericanos**. Buenos Aires: INTA. 433-450.

Cavada Benech, C. (2007). Aplicación de autómatas celulares en la predicción del movimiento de precios de bienes raíces. **Tesis**. Chile.

Coombes, S. (2009). The geometry and pigmentation of seashells. **Techn. Ber. Department of Mathematical Sciences**. University of Nottingham.

Couclelis, H. (1985). Cellular worlds: a framework for modeling micro—macro dynamics. **Environment and planning A**. 17(5), 585-596.

Couclelis, H. (1997), From cellular automata to urban models: new principles for model development and implementation, **Environment and planning B: Planning and design**. 24 (2), 165-174.

Chopard, B. (2009). Cellular automata modeling of physical systems. **In Encyclopedia of Complexity and Systems Science**. Springer New York. 865-892

Clarke, K. C.; Gaydos, L. J. (1998). Loose-coupling a cellular automaton model and GIS: long-term urban growth prediction for San Francisco and Washington/Baltimore. **International journal of geographical information science**. 12(7), 699-714.

Crooks, A.; Castle, C.; Batty, M. (2008). Key challenges in agent-based modelling for geo-spatial simulation. **Computers, Environment and Urban Systems**. 32(6), 417-430.

Deep, S.; Saklani, A. (2014). Urban sprawl modeling using cellular automata. **The Egyptian Journal of Remote Sensing and Space Science**. 17(2), 179-187.

Dietzel, C.; Clarke, K. (2006). The effect of disaggregating land use categories in cellular automata during model calibration and forecasting. **Computers, Environment and Urban Systems**. 30(1), 78-101.

de Almeida, C. M.; Batty, M.; Monteiro, A. M. V.; Câmara, G.; Soares-Filho, B. S.; Cerqueira, G.

C.; Pennachin, C. L. (2003). Stochastic cellular automata modeling of urban land use dynamics: empirical development and estimation. **Computers, Environment and Urban Systems**. 27(5), 481-509.

de Ullibarri Galparsoro, L.; Pita Fernández, S. (1999). Medidas de concordancia: el índice de Kappa. **Cad Aten Primaria**, 6, 169-171.

Feng, Y. (2017). Modeling dynamic urban land-use change with geographical cellular automata and generalized pattern search-optimized rules. **International Journal of Geographical Information Science**, 31(6), 1198-1219.

Garrocho, C.; Buzai, G. D. (Coords.). (2015). Geografía aplicada en Iberoamérica: avances, retos y perspectivas. **El Colegio Mexiquense**. CDMX.

Garrocho, C.; Chávez, T. L. (2018). La Estación de Inteligencia Territorial: CHRISTALLER[®]. **GeoSig**. En prensa.

Goodchild, M. F.; Mark, D. M. (1987). The fractal nature of geographic phenomena. **Annals of the Association of American Geographers**. 77(2), 265-278.

Gorostiaga Marin, G. (2010). Autómatas celulares y su aplicación. **Revista de Información, Tecnología y Sociedad**. 9, 9-11

Hoyo, A. (2006), Simulación de tráfico vehicular con autómatas celulares unidimensionales. **Memorias del Congreso ASME USB 2006**: Caracas – Venezuela.

León, M. O. G.; Villalobos, H. L. R. (2014) Predicción y modelación del crecimiento urbano de Ciudad Cuauhtémoc, Chihuahua del 2010, usando autómatas celulares (SLEUTH). **Revista Internacional de Contaminación Ambiental**.

Linares, S. (2016). Evolución histórica sobre la modelización del espacio urbano en geografía. **Sociedade e Território**, 28(2), 23-41.

Liu, X.; Li, X.; Shi, X.; Wu, S.; Liu, T. (2008). Simulating complex urban development using kernel-based non-linear cellular automata. **Ecological modelling**. 211(1), 169-181.

Li, X.; Yeh, A. G. O. (2000). Modelling sustainable urban development by the integration of constrained cellular automata and GIS. **International Journal of Geographical Information Science**. 14(2), 131-152.

Macrae, N. (1999). **John Von Neumann: The Scientific Genius who Pioneered the Modern Computer, Game Theory, Nuclear Deterrence, and Much More**. American Mathematical Soc.

Mandelbrot, B. B.; Pignoni, R. (1983). **The fractal geometry of nature** (Vol. 1). New York: WH Freeman.

Padilla, O.; Pérez, P.; Cruz, M.; Huilcamaigua, S.; Astudillo, S. (2015). Utilización de autómatas celulares como técnica de modelamiento espacial para determinación el cambio de uso de suelo y cobertura vegetal. **Ciencias Espaciales**, 8(1), 310-326.

Pérez-Miranda, R.; Valdez Lazalde, J. R.; Moreno Sánchez, F.; González Hernández, A.; Valdez

Hernández, J. I. (2011). Predicción espacial de cambios del uso de suelo en Texcoco, Estado de México. **Revista mexicana de ciencias forestales**. 2(5), 59-72.

Polidori, M. C.; Saraiva, M. V. P.; Peres, O. M.; Toralles, C. P.; Tomiello, F. (2015). Los bordes de la ciudad y la simulación del crecimiento urbano con autómatas celulares. **Ciencias Espaciales**. 8(2), 357-370.

Real, R. (1999). Tables of significant values of Jaccard's index of similarity. **Miscel·lania Zoologica**, 22(1), 29-40.

Reyes, P. R.; Torres-Florez, J. P. (2009). Diversidad, distribución, riqueza y abundancia de condrictios de aguas profundas a través del archipiélago patagónico austral, Cabo de Hornos, Islas Diego Ramírez y el sector norte del paso Drake. **Revista de biología marina y oceanografía**. 44(1), 243-251.

Stevens, D.; Dragičević, S. (2007). A GIS-based irregular cellular automata model of land-use change. **Environment and Planning B: Planning and Design**. 34(4), 708-724.

Tobler, W. R. (1979). Cellular geography. **In Philosophy in geography**. Springer Netherlands.

Torrens, P. M. (2000). How cellular models of urban systems work. **CASA working paper series**. 28.

Unibazo C. M.; Suazo P. B. (2009). Metodología fractal como estrategia de crecimiento urbano. In *5th International Conference Virtual City and Territory, Barcelona 2009*. **Centre de Política de Sòl i Valoracions**. 201-214.

López, M. V.; Sánchez, N. E. L. (2013). Un modelo de simulación computacional integrado a SIG para explorar la dinámica de crecimiento de la Zona Metropolitana de la Ciudad de México (1998-2008). **Estudios Demográficos y Urbanos**, 593-644.

Viera, A. J.; Garrett, J. M. (2005). Understanding interobserver agreement: the kappa statistic. **Fam Med**. 37(5), 360-363.

White, R.; Engelen, G. (1993). Cellular automata and fractal urban form: a cellular modelling approach to the evolution of urban land-use patterns. **Environment and planning A**, 25(8), 1175-1199.

White, R. (1998). Cities and cellular automata. **Discrete dynamics in Nature and Society**. 2(2), 111-125.

White, R.; Engelen, G. (2000). High-resolution integrated modelling of the spatial dynamics of urban and regional systems. **Computers, environment and urban systems**, 24(5), 383-400.

White, S. H.; Del Rey, A. M.; Sánchez, G. R. (2007). Modeling epidemics using cellular automata **Applied Mathematics and Computation**. 186(1), 193-202.

Wolfram, S. (1984). Cellular automata as models of complexity. **Nature**.311(5985), 419-424.

Wolfram, S. (1994). **Cellular automata and complexity: collected papers** (Vol. 1). Reading, MA: Addison-Wesley.

Wu, F.; Webster, C. J. (1998). Simulation of land development through the integration of cellular automata and multicriteria evaluation. **Environment and Planning B: Planning and design**. 25(1), 103-126.

Wu, F. (2002). Calibration of stochastic cellular automata: the application to rural-urban land conversions. **International Journal of Geographical Information Science**. 16(8), 795-818.

© Eduardo Jiménez López; Tania Chávez Soto y Carlos Garrocho.

Jiménez López, E.; Chávez Soto, T.; Garrocho, C. 2018. Modelando la expansión urbana con autómatas celulares: aplicación de la estación de inteligencia territorial (CHRISTALLER). **Geografía y Sistemas de Información Geográfica (GeoSIG)**. 10(12)Sección II:1-26

On-line: www.revistageosig.wixsite.com/geosig

Recibido: 28 de noviembre de 2017

Aceptado: 17 de octubre de 2018