

Una comparación de programas de modelación de cambios de cobertura / uso del suelo

Jean-François Mas¹

Melanie Kolb²

Thomas Houet³

Martin Paegelow³

María Teresa Camacho Olmedo⁴

¹ Centro de Investigaciones en Geografía Ambiental
Universidad Nacional Autónoma de México (UNAM)
Antigua Carretera a Pátzcuaro 8701, Col. Ex-Hda de S. José de La Huerta
C.P. 58190 Morelia Michoacán México
jfm@ciga.unam.mx

² Comisión Nacional para el Conocimiento y Uso de la Biodiversidad
Liga Periférico - Insurgentes Sur, Núm. 4903, Col. Parques del Pedregal
Delegación Tlalpan, 14010 México, D.F. Posgrado en Geografía – UNAM México
melanesien@gmail.com

³ Laboratoire GEODE Maison de la Recherche de l'Université du Mirail
5, Allées A. Machado - 31058 TOULOUSE Cedex 1 Francia
paegelow@univ-tlse2.fr

⁴ Departamento de Análisis Geográfico Regional y Geografía Física
Facultad de Filosofía y Letras Universidad de Granada
Campus de Cartuja s/n. 18071 Granada España
camacho@ugr.es

Abstract. Land use/cover changes (LUCC) are significant to a range of issues central to the study of global environmental change and have thus received growing attention by decision makers and scientists. Over the last decades, a range of models of LUCC have been developed to meet land management needs, and to better understand, assess and project the future role of LUCC in the functioning of the earth system. This study intends to compare the possibilities and the limits of four modelling approaches: CLUE, DINAMICA EGO, CA_MARKOV and Land Change Modeler (both available in IDRISI). First, a review of methods and tools available for each model was done taking into account how the model carry out the different procedures involved in the modelling process (Estimation of the quantity of changes, finding of the relationship between the explanatory variables and the changes in order to assess the degree of change potential, change allocation, simulation of spatial patterns of changes, model evaluation). The four models were applied to simple case studies and model outputs were compared.

Palavras-chave: Land use / land cover change, modelling, GIS.

1. Introducción

En las últimas décadas, una gran cantidad de modelos de cambios de cobertura / uso del suelo (CCUS) enfocados a la simulación de procesos de cambio han sido desarrollados. Los CCUS pueden modelarse empíricamente mediante un análisis de los cambios pasados para desarrollar un modelo matemático que estima la probabilidad de cambio en función de un conjunto de variables explicativas. En general, el análisis espacial de los cambios se lleva a cabo a través de la comparación de dos mapas de cobertura/uso del suelo (CUS) de dos fechas anteriores. Esta comparación permite estimar los patrones y procesos de cambio (tipos de transiciones y tasas de cambio). El análisis de los cambios pasados en relación con las

variables explicativas permite mapear la probabilidad de las diferentes transiciones. Otros procedimientos, aplicados con el fin de crear un mapa prospectivo de CUS, involucran técnicas para asignar los cambios en el espacio y, finalmente, para reproducir los patrones espaciales de los paisajes. Por último, se lleva usualmente a cabo una evaluación del desempeño del modelo.

Diferentes paquetes de modelación tienen funciones y herramientas con requisitos y supuestos distintos, emplean diferentes tipos de algoritmos que los vuelve más o menos adecuados dependiendo de los datos de entrada y el propósito de la modelación. Existen muy pocos estudios enfocados a comprender los beneficios y limitaciones de los modelos mediante la evaluación y la comparación de sus herramientas. Este estudio tiene como objetivo la evaluación de cuatro modelos que presentan un amplio abanico de enfoques y métodos:

- CA_MARKOV en IDRISI (Eastman, 2009).
- CLUE-S (Verburg y Overmars, 2009)
- DINAMICA EGO (Soares-Filho et al., 2002, 2009).
- Land Change Modeler (LCM), disponible en IDRISI y como extensión de ARC-GIS (Eastman, 2009).

En una primera sección, hacemos una revisión de los métodos y herramientas que ofrece cada modelo para realizar la simulación teniendo en cuenta las principales tareas en la modelación espacial. Posteriormente, examinamos la posibilidad de desarrollar modelos más sofisticados, la facilidad de uso y la disponibilidad de materiales de apoyo.

2. Revisión de los modelos

El procedimiento de modelación puede ser sub-dividido en cinco pasos: 1) un procedimiento no espacial que calcula el área que de cada transición, 2) un procedimiento espacial que determina la probabilidad de cambio, 3) un componente que asigna la ubicación de los cambios, 4) eventualmente un módulo espacial que simula los patrones espaciales de los cambios y, por último, 5) un procedimiento de evaluación que permite comparar el mapa simulado con el mapa de referencia de la misma fecha.

2.1. Estimación de la cantidad de cambios

En CA_MARKOV, DINAMICA y LCM, la cantidad de cambios se calcula con base en una matriz de Markov obtenida generalmente a través de la comparación de mapas de CUS de dos fechas. En DINAMICA, la matriz de transición se transforma para dar las tasas anuales de transición a fin de proyectar las tendencias de cambio sobre una base anual aplicando una ecuación de cálculo matricial. En IDRISI (CA_MARKOV y LCM), se obtienen realizando una corrección lineal simple de las probabilidades de transición. En CLUE, la cantidad de categorías de ocupación del suelo es proporcionada por el usuario para cada año simulado. IDRISI propone además una corrección de los valores de probabilidad de la matriz que toma en cuenta la fiabilidad de los mapas de CUS con el fin de corregir el sesgo relacionado con errores cartográficos. Consiste en disminuir las probabilidades más elevadas ($P \geq$ probabilidad de permanencia de cada categoría) proporcionalmente al error y modificar los demás valores de probabilidades para que la suma de las columnas sea uno.

La tabla 1 presenta las matrices de transición y de probabilidad de cambio. Las matrices generadas por DINAMICA e IDRISI (sin correcciones) son muy similares. Al contrario, la corrección realizada por IDRISI modifica todas las probabilidades de transición. La corrección tiende a disminuir las probabilidades de permanencia y aumentar las de las otras transiciones. Sin embargo, se podría esperar que los errores de clasificación lleven a una sobreestimación de las transiciones de cambio. Por lo tanto, la corrección podría exacerbar los errores en la matriz en vez de disminuirlos. En nuestro ejemplo, después de esta corrección, ciertas transiciones que no se observaron (CUS 2 a 1 y 3) presentan una probabilidad de 7,5%.

Tabla 1. Matriz de transición en número de píxeles ($T = 3$ años) y matrices de probabilidad de transición ($T = 1$ año) generadas por IDRISI (b: sin corrección, c: con corrección para un error de 15%) y DINAMICA (d).

a				b					
		t + 3					t + 1		
t		CUS 1	CUS 2	CUS 3	t		CUS 1	CUS 2	CUS 3
CUS 1		243971	47265	3385	CUS 1		0.9692	0.0244	0.0064
CUS 2		0	40628	0	CUS 2		0.0000	1.0000	0.0000
CUS 3		2909	961	259	CUS 3		0.3923	0.0647	0.5430

c				d					
		t + 1					t + 1		
t		CUS 1	CUS 2	CUS 3	t		CUS 1	CUS 2	CUS 3
CUS 1		0.8238	0.1396	0.0366	CUS 1		0.9712	0.0244	0.0043
CUS 2		0.0750	0.8500	0.0750	CUS 2		0.0000	1.0000	0.0000
CUS 3		0.4622	0.0763	0.4616	CUS 3		0.2660	0.0518	0.6822

2.2. Evaluación de la probabilidad de cambio

CLUE y CA_MARKOV usan mapas que expresan la aptitud de un área para cada una de las categorías de CUS mientras DINAMICA y LCM calculan la probabilidad de cada transición. En CA_MARKOV los mapas de aptitud son generados por una evaluación multicriterio. CLUE utiliza modelos de regresión logística que deben elaborarse en un programa externo. DINAMICA utiliza el método de los pesos de evidencia, los cuales pueden eventualmente ser modificados por un algoritmo genético que mejora el ajuste entre los mapas de probabilidad y el mapa de CUCS utilizado para la calibración del modelo. LCM utiliza una red neuronal (perceptrón multicapa) para producir el mapa de probabilidad y presenta también la opción de utilizar regresiones logísticas. Estos métodos implican diferentes supuestos y pre-procesamiento de las variables explicativas:

Los pesos de evidencia se basan en variables categóricas y DINAMICA tiene una herramienta para optimizar la transformación de variables continuas en categóricas. El perceptrón multicapa y los modelos de regresión logística utilizan de preferencia variables continuas. IDRISI permite convertir mapas categóricos en mapas continuos con base en probabilidades condicionales.

Los modelos de regresión logística y de los pesos de evidencia se basan en la hipótesis de la independencia entre las variables explicativas. Para ello, DINAMICA e IDRISI disponen de herramientas para evaluar la correlación entre los mapas.

Los diferentes modelos tienen varias maneras de ajustar la relación entre las variables explicativas y la probabilidad de transición. Las redes neurales y los modelos de regresión logística toman en cuenta todas las variables explicativas simultáneamente mientras que los pesos de evidencia se calculan de manera independiente para cada variable explicativa y modelan un efecto sumatorio de la acción de cada variable. Las redes neuronales y los algoritmos genéticos permiten manejar funciones no lineales, teniendo en cuenta las sinergias o efectos inhibitorios entre las variables.

Los métodos también difieren en su flexibilidad para modelar las relaciones entre la probabilidad de cambio y las variables explicativas. Modelos de regresión logística solo pueden modelar correctamente una función sigmoidea. El cálculo de un peso de evidencia para cada categoría permite elaborar una función muy compleja. Las redes neurales son capaces de ajustar funciones no-lineales complejas. Sin embargo, la capacidad para ajustar una función compleja puede conducir a un sobre-ajuste a características del periodo de calibración y disminuir la capacidad del modelo para proyecciones a futuro.

Estos métodos ofrecen también diferentes grados de integración de conocimiento experto. La evaluación multicriterio (CA_MARKOV) toma en cuenta el conocimiento de expertos

mientras que la regresión logística y aún más las redes neuronales o los algoritmos genéticos son muy restringidos en este aspecto. DINAMICA permite visualizar la relación entre las variables explicativas y los pesos de evidencia y, eventualmente modificarlos, ajustando así el nivel de integración del conocimiento experto desde un enfoque totalmente estadístico (sin modificación de los pesos) a un enfoque completamente basado en conocimiento experto (modificación importante de los pesos por los expertos).

Para evaluar algunas de las características de los diferentes enfoques, se aplicaron los modelos a un caso muy sencillo en el cual los cambios de uso 1 a uso 2 ocurren más frecuentemente cerca de las carreteras pero únicamente en el tipo de suelo 1 (figura 1).




Figura 1. Distribución de los cambios de uso1 a uso2 en función de la distancia a la carretera y el tipo de suelo (izquierda). Distribución de los CCUS a CUS 3 con respecto a la elevación. Los cambios se presentaron en un rango altitudinal óptimo (derecha).

Como se puede observar en la figura 2, la regresión logística y las redes neuronales (a y b) fueron capaces de modelar el efecto combinado de las variables suelo y distancia a carreteras. En el caso de los pesos de evidencia, las probabilidades en el suelo 2 no son nulas y dependen de la distancia a las carreteras (c). Sin embargo, el efecto inhibitor del suelo 2 puede ser modelado por este método utilizando una combinación entre distancia a carretera y suelo (d).




Figura 2. Mapas de probabilidad de cambio obtenidos con los diferentes métodos evaluados.

Para evaluar la capacidad de ajuste se modelaron los cambios de uso1 a uso3 con base en la elevación, y los cambios de uso1 a uso2 con base en la distancia a las carreteras. El cambio de uso1 a uso3 ocurre únicamente en un rango de elevación óptimo (figura 1).




Figura 3. Probabilidad de cambio en función de la elevación (izquierda) y la distancia a la carretera (derecha).

Como se puede observar en la figura 3, solo los pesos de evidencia fueron capaces de crear una función que modele el rango de elevación óptimo. Sin embargo, en el caso de la distancia a las carreteras los pesos de evidencia modelaron el ruido mientras las redes neuronales (LCM) y la regresión logística (CLUE) suavizaron la relación entre distancia y probabilidad creando curvas más verosímiles.

2.3. Asignación de la ubicación del cambio

La asignación del cambio es un proceso de decisión que selecciona los píxeles que van a experimentar cierto cambio con base en los mapas de probabilidad de cambio. CA_MARKOV y LCM seleccionan los píxeles con los valores de probabilidad más altos. Debido a que hay normalmente una competencia entre diferentes transiciones (el mismo sitio puede ser candidato a transiciones diferentes), utilizan un procedimiento de asignación multi-objetivo. CLUE utiliza un enfoque alternativo basado en un proceso iterativo. DINAMICA utiliza dos funciones de autómatas celulares. Los píxeles son clasificados de acuerdo a su probabilidad de cambio y son seleccionados al azar de mayor a menor potencial. Un parámetro permite controlar la cantidad de cambios simulados en áreas menos propensas al cambio.

2.4. Reproducción de los patrones temporales y espaciales

CA_MARKOV y DINAMICA utilizan autómatas celulares (AC) con el fin de obtener un efecto de proximidad. En CA_MARKOV, el AC reduce la aptitud de las áreas alejadas de áreas existentes de la categoría de CUS considerada usando un filtro de 5x5 píxeles. El mismo AC se aplica a todas las transiciones. DINAMICA utiliza dos AC complementarios: uno se dedica a la expansión o contracción de los parches anteriores de una determinada categoría mientras el otro genera nuevos parches a través de un mecanismo de siembra. El usuario puede ajustar parámetros para controlar el tamaño de los parches, la variación del tamaño y la isometría para cada transición. CLUE no tiene AC, pero presenta la opción de modificar el mapa de probabilidad utilizando una regresión logística adicional que tome en cuenta la distancia a los parches existentes a través de filtros espaciales. Como se puede observar en la figura 4, la simple selección de los píxeles con los valores de probabilidades de cambio más altos no conduce a la producción de patrones espaciales verosímiles. El CA de CA_MARKOV solo permitió el crecimiento de parches ya existentes. Con DINAMICA se

podieron crear nuevas parches de cambio respectando las diferencias en el tamaño de los parches de uso 2 y uso 3.




Figura 4. Mapas de CUS prospectivos elaborados por LCM, CA_Markov y DINAMICA. Los mapas fueron elaborados con base en los mismos mapas de probabilidad de cambio.

Características adicionales diseñadas para reproducir patrones espacio-temporales incluyen la posibilidad de modelar el tiempo de permanencia durante las transiciones, efectos de la saturación y el uso de variables dinámicas. DINAMICA permite cambiar la matriz de Markov en los pasos específicos de la simulación. Algunas transiciones como sucesiones vegetales son deterministas y dependen del tiempo de permanencia de la sucesión vegetal. Sólo CLUE y DINAMICA permiten establecer un tiempo de permanencia de cada transición. Algunas transiciones se detienen cuando la cantidad de cambio alcanza un determinado nivel. En CA_MARKOV y DINAMICA, procedimientos para controlar los tiempos de estancia y el efecto de saturación pueden ser fácilmente implementados. Debido a su estructura fija, dicha aplicación no es posible en LCM. En CLUE, el efecto de saturación se puede modelar a expensas de otro patrón espacial porque el usuario puede utilizar sólo una regresión logística adicional para cada transición.

El uso de zonas de restricción o incentivo permite ajustar el cambio potencial a determinadas regulaciones de uso del suelo que no se pueden derivar de las variables explicativas. LCM y DINAMICA permitir el uso de zonas de restricción o de incentivo a un cierto paso de tiempo. En CLUE, estas áreas se aplican para la simulación completa (todos los pasos de tiempo). En CA_MARKOV, la incorporación de las zonas de restricción o incentivo puede hacerse a través de la elaboración de mapas de aptitud que tomen en cuenta estas áreas.

2.5. Evaluación del modelo

En general, la evaluación de los modelos se basa en la comparación entre el mapa simulado y un mapa observado que sirve de referencia. La evaluación puede enfocarse en el o los mapa(s) de probabilidad de cambio o el mapa de CUS prospectivo. En el primer caso se compara un mapa continuo (probabilidades) con un mapa categórico (mapa de CUS observado), en el segundo se comparan dos mapas categóricos (mapas de CUS observado y simulado). IDRISI ofrece una forma de evaluar los resultados de la simulación para cada caso (análisis ROC e índice Kappa). DINAMICA permite calcular un índice de similitud difuso (Hagen, 2003) que permite comparar los mapas de CUS simulado y observado con una cierta tolerancia respecto a la coincidencia espacial. En CLUE, la evaluación de las regresiones logísticas se basa generalmente en un análisis ROC que se lleva a cabo en otro programa.

Se puede notar que los métodos de evaluación están todos enfocados en evaluar la coincidencia espacial entre los cambios simulados y los cambios observados. Este enfoque puede sesgar las evaluaciones hacia una sobrevalorización de los métodos donde los cambios corresponden a los píxeles con los valores más altos de probabilidad de cambio debido a que la reproducción de los patrones espaciales del paisaje se hace a las expensas de la

coincidencia espacial. En caso de aplicaciones en las cuales el patrón espacial de los paisajes en los mapas simulados es importante, se recomienda evaluar este aspecto, por ejemplo a través del cálculo de índices de fragmentación (Mas et al., 2010). IDRISI permite calcular varios índices. En DINAMICA, un script disponible en los tutoriales permite también el cálculo de algunos de ellos.

2.6. Opciones avanzadas

La elaboración de modelos más sofisticados involucra el manejo de sub-regiones que pueden presentar diferentes dinámicas. En CLUE el usuario puede proporcionar un mapa de las regiones. DINAMICA también tiene la opción de dividir el área de estudio en regiones con especificaciones particulares e interactuando entre ellas.

Otro aspecto es la integración de diferentes patrones de CUCS en el tiempo. Esto puede hacerse fácilmente con DINAMICA que permite la substitución de las matrices de transición, junto con las variables explicativas en un momento dado de la simulación. La herramienta de IDRISI para desarrollar modelos (macro modeler) puede utilizarse para llevar a cabo tales procedimientos de modelado utilizando CA_MARKOV. LCM permite cambiar algunas variables durante el modelado (carreteras, infraestructura e incentivos previstos / limitaciones). LCM puede utilizar una matriz de transición fija de un modelo exterior en lugar de la matriz de Markov. DINAMICA puede utilizar un modelo externo que calcula tasas dinámicas de transición.

Con el fin de reproducir los patrones espaciales de deforestación tropical, donde la red de carreteras es un fuerte predictor de la deforestación, pero no existe cartografía de los caminos "espontáneos", DINAMICA y LCM ofrecen un modelo predictivo de la evolución de las carreteras. Además LCM proporciona herramientas destinadas a evaluar el impacto del cambio para la sostenibilidad ecológica y la planificación de la conservación.

2.7. Consideraciones adicionales

Los programas que ofrece más flexibilidad para desarrollar modelos personalizados son CA_MARKOV y DINAMICA. Los modelos pueden ser construidos aprovechando la gran cantidad de herramientas y operadores disponibles en estos programas. Por otra parte, la programación es fácil, incluso para usuarios sin experiencia previa en programación, gracias a una interfaz gráfica amigable. Al contrario, LCM y CLUE presentan una estructura rígida, que define un flujo fijo de procedimientos.

Los programas de IDRISI son tal vez los más fáciles de usar porque están bien documentados, todas las operaciones se ejecutan en un entorno gráfico, pueden automatizarse y las operaciones previas a la modelación (clasificación de imágenes) puede llevarse a cabo en el mismo entorno. DINAMICA también presenta una interfaz de programación intuitiva y está muy bien documentado (manual, lista de discusión). CLUE también está bien documentado (guía y una gran cantidad de publicaciones científicas), pero requiere operaciones laboriosas (edición de archivos de texto para introducir los parámetros) y muchas operaciones tienen que llevarse a cabo con programas externos (regresión logística, despliegue de los mapas, evaluación).

3. Discusión y conclusión

Los paquetes revisados utilizan diferentes enfoques para producir mapas prospectivos. Algunos se basan en los datos con métodos de calibración automáticos (LCM) mientras otros se basan más en conocimiento experto (CA_MARKOV). DINAMICA permite escoger niveles intermediarios entre ambos enfoques.

En regiones con altas dinámicas de CCUS, los enfoques de calibración basados en métodos capaces de producir funciones que se ajustan mucho a los datos de entrenamiento

(redes neurales, algoritmos genéticos, pesos de evidencia sin edición) pueden resultar contraproducentes debido a las variaciones en los patrones de cambio durante el tiempo. En estos casos, la integración de algún grado de conocimiento experto es recomendable.

La reproducción de los patrones del paisaje puede ser importante por ejemplo para evaluar el impacto de los CCUS sobre la fragmentación de los paisajes y la conservación de la biodiversidad. Solo DINAMICA logró reproducir estos patrones. En CA_MARKOV se podrían realizar operaciones adicionales para mejorar este aspecto.

Finalmente, es importante tomar en cuenta la posibilidad de desarrollar modelos que se adecuen a las necesidades del usuario y de acoplarlos con otros modelos (modelos económicos, emisión de carbono, conservación de especies, modelos hidrológicos...). LCM tiene módulos para evaluar aspectos de conservación. Sin embargo, su estructura rígida no permite salir del entorno ya establecido. En este aspecto es sin duda DINAMICA que presenta más potencial por su gran flexibilidad y sus posibilidades de interacción con otras herramientas.

Agradecimientos

Este estudio se llevó a cabo en el ámbito del proyecto *Simulaciones geomáticas para modelizar dinámicas ambientales. Avances metodológicos y temáticos* (BIA2008-00681).

Referencias

Eastman, R. **Idrisi Taiga, Guide to GIS and Image Processing**, manual version 16.02, Clark University, 342 p, 2009.

Hagen, A. Fuzzy set approach to assessing similarity of categorical maps. **International Journal of Geographical Information Science**, v. 17, n. 3, p. 235–249, 2003.

Mas, J.F.; Pérez Vega, A.; Clarke, K. Assessing simulated land use/cover maps using similarity and fragmentation indices, In: ASPRS Annual Conference, April 26-30, San Diego, CA (CD), 2010, **Proceedings** Disponible em: <<http://www.csr.ufmg.br/csr/publicacoes/Masetal2010asprs.pdf>>. Acesso em: 17 nov. 2010.

Soares-Filho, B.S.; Pennachin, C.L.; Cerqueira, G. DINAMICA – a stochastic cellular automata model designed to simulate the landscape dynamics in an Amazonian colonization frontier. **Ecological Modelling**, v. 154, n. 3, p. 217-235, 2002.

Soares-Filho, B.S.; Rodrigues, H. O.; Costa, W.L.S. **Modelamiento de Dinámica Ambiental con Dinamica EGO**, Centro de Sensoriamento Remoto/Universidade Federal de Minas Gerais. Belo Horizonte, Brazil, 2009. Disponible em: <<http://www.csr.ufmg.br/dinamica/>>. Acesso em: 17 nov. 2010.

Verburg, P.H.; Overmars, K.P. Combining top-down and bottom-up dynamics in land use modeling: exploring the future of abandoned farmlands in Europe with the Dyna-CLUE model. **Landscape Ecology**, v. 24, n.9, p. 1167-1181, 2009.